



Securities & Exchange Organization, Research, Development & Islamic Studies (RDIS)  
Journal of Securities and Exchange, Fall 2025, V. 18, No.71, pp. 359-400

## A New Model for Conducting High-Frequency Trading Using Collaborative Cellular Learning Automata Algorithm and External Optimization (CLA-EC-EO)<sup>1</sup>

Seyed Alireza Ahmadi<sup>2</sup>, Seyed Ali Paytekhti Oskooe<sup>3</sup>, Yunes Badavar Nahandi<sup>4</sup>

Receive Date: 12 February 2023

Revise Date: 14 April 2023

Research Paper

Accept Date: 10 September 2023

Publish Date: 23 October 2025

### Highlights

- High-frequency trading is a trading method that uses powerful computer programs to execute a large number of orders in a fraction of a second. High-frequency trading is the opposite of traditional long-term investing.
- Using a dynamic method that can adapt to the environment and prevent mistakes in the process of making trading decisions seems very necessary.
- The effectiveness of technical analysis variables and economic variables used to make trades. In addition to the fact that each share has its own specific conditions, these variables have specific criteria for each economy and a single version cannot be used for all societies.
- The presented model increases the level of confidence in entering a buy transaction and the level of confidence in entering a sell transaction.
- The created model has the power to adapt to all capital markets.

### Abstract

At the same time as the speed of financial exchanges increases, many complications are also added to it, and the amount of attention paid to the role of human actors in it has faded, and the method of high-frequency trading is over time. In this research, a model for HFT has been presented in order to dynamically adapt to environmental changes in addition to cost reduction. The method of conducting the research is to use the algorithm of colleagues' cellular automata and external optimization, and from fundamental analysis books, technical and economic analysis indicators and daily stock information as used and Statistical community of the symbols available in the Tehran Stock Exchange market in August 2016 to August 2021. The confusion matrix model has been used to evaluate the model. The results of the research led to the modification of the effect range of technical analysis variables as well as economic variables for trading symbols, and a dynamic model for stock market trading was presented, which is able to adapt to changing environmental conditions in order to reduce the trading risk.

**Keywords:** High Frequency Trading, Cellular Automata, External Optimization, Confusion Matrix

**JEL Classification:** D53, G17, H54.

1. doi: 10.22034/JSE.2023.12180.2110

2. Ph.D. Student, Department of Financial Engineering, Faculty of Economics, Tabriz Branch, Islamic Azad University, Tabriz, Iran. (A\_Ahmadi44@yahoo.com).

3. Associate Professor, Department of Economics, Tabriz Branch, Islamic Azad University, Tabriz, Iran. (Corresponding Author). (oskooe@iaut.ac.ir).

4. Assistant Professor, Department of Accounting, Tabriz Branch, Islamic Azad University, Tabriz, Iran. (nahandi@iaut.ac.ir).



Copyright © 2025 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.

**Cite This Article:** Ahmadi, Seyed Alireza; Paytekhti Oskooe, Seyed Ali; Badavar Nahand, Yunes. (2025). A New Model for Conducting High-Frequency Trading Using Collaborative Cellular Learning Automata Algorithm and External Optimization (CLA-EC-EO). *Journal of Securities Exchange*, 18 (71), 359-400. <http://10.22034/JSE.2023.12180.2110>.

## Introduction

We live in an era where technology has entered the smallest parts of human individual and social life and it is impossible to avoid it. Among the markets that have realized the inevitability of this fact for several years are financial markets. At the same time as the speed of financial transactions has increased, many complexities have also been added to it and the role of human actors has been greatly reduced. Algorithmic and high-frequency trading has become part of financial markets due to the convergence of several factors. These factors include the growth of the role of technology in the market, the increase in the complexity of financial instruments, and the relentless movement towards greater efficiency in executing transactions and reducing transaction costs. High-frequency trading takes place at an extremely high speed, and this speed has increased the effectiveness of trading strategies in today's trading environment (2021, Beldoff and Molnar). The share of high-frequency trading in stock trading has expanded significantly across financial markets. For example, in the United States, approximately 52 percent of all stock trading in 2018 was high-frequency trading (Zaharodin et al; 2021). Over the past few decades, many methods have been implemented to forecast the capital market. In most of these studies, researchers have tried to predict stock price fluctuations by using complex modeling and making numerous assumptions. However, due to the complexities and numerous variables affecting the price trend of the capital market, most of them have had a high error rate or at least have not been valid in all markets (Ghorbani, 2016). The current research aims to use the characteristics of learning cellular automata and limit optimization to present a model for high-frequency trading that can dynamically adapt to environmental changes while reducing the risk caused by price fluctuations.

## Methodology

The present study is a fundamental research in terms of method, correlation and causality and based on the purpose, and since historical information is used for this research, it is considered a post-event research. While in terms of the type of study; it is a field-library. The statistical population of this study is the stocks of companies traded on the Tehran Stock Exchange and the statistical sample is all symbols traded on the Tehran Stock Exchange from 2016/07/22 to 2021/07/22, which have been collected daily.

Since high-frequency trading is highly competitive, it means that systems must constantly evolve. Although this type of trading is successful in most cases, sometimes months of hard work and research can be wasted as a result of a change in the structure of the stock exchanges, or the adoption of a new law, or a competitor overtaking your processing speed.

Therefore, it seems very necessary to use a dynamic method that can adapt to the environment and prevent mistakes in the process of trading decisions. For this reason, the use of a learning method called reinforcement learning has been considered. Reinforcement learning is neither a subset of neural networks nor an alternative to them. Rather, it is an orthogonal approach to solving different and more difficult problems. One of the reinforcement learning methods is the stochastic learning automaton. On the other hand, many problems cannot be solved using a single learning automaton, but the real power of learning automata is revealed when they are used as a collective group. Considering this problem, the cellular learning automata model is proposed. The dynamics of a cellular learning automata are obtained by repeatedly applying the local law to the learning automata of all cells.

One of the models that combines the concepts of evolution and learning is the CLA-EC model. In this model, each genome is assigned to one of the cells of the cellular learning automata. The set of actions selected by the automata of each cell is assigned to the genomic sequence of that cell. Based on the local law, a signal vector is generated and given to the set of learning automata residing in that cell. Each of the learning automata adjusts its internal structure based on the received signal and the learning algorithm. The process of selecting actions and adjusting the internal structure is repeated until a predetermined criterion is satisfied. This model can be used to solve optimization problems. This algorithm, despite the appropriate search of the problem domain, does not produce highly accurate answers. Therefore, by combining this model with the marginal external optimization algorithm, this problem will also be solved. As a result, by using the properties of learning cellular automata and marginal optimization, the threat of environmental fluctuations can be overcome and a dynamic model can be designed that adapts to environmental changes.

The variables used in this model are categorized into four groups as follows.

*Table (I) Reserch variables*

Fundamental analysis parameters(A)	Daily stock trading information(B)	Technical analysis indicators(C)	Economic variables(D)
Earnings per share price-to-earnings	Daily trading volume Number of registered transactions Time of transaction Order execution day	Exponential Moving Average Bollinger bands Relative strength index Degree of change Stochastic Money Flow Index	Gold price Exchange rate Inflation rate Stock index growth rate

The information collected through Delphi software and using high-frequency trading algorithms and combining it with the learning cellular automata algorithm and marginal optimization, has been analyzed in five steps as follows.

1. First, using the variables of group A, we select stocks that have a high p/e in the desired industry compared to the industry average. In this step, the symbols are first categorized in their respective industries and the p/e of the symbols is extracted, the p/e that has an unusual difference compared to other stocks in that industry is eliminated. Then, the symbols that are lower than the average p/e in each group are given priority for selection.
2. The selected stocks are entered into the processing process as initial data for a 20-day period (working).
3. The selected stocks with the variables of group B are entered into the automata algorithm and processed.
4. The selected stocks with variables from group C are entered into the automata algorithm and processed.
5. The selected stocks with variables from group D are entered into the automata algorithm and processed.
6. The output data from steps 3, 4, and 5 will be processed through the finite optimization algorithm as described.
  - a) We calculate the fit for each variable.
  - b) We rank all the fits and select the variable with the lowest fit.
  - c) The value of the selected variable is replaced by another value in its neighborhood.
  - d) The created solution is considered the current solution.
  - e) If the current solution is better than the best solution, it is also selected as the best solution.
  - f) We repeat step 2 until the desired solution is reached.
  - g) The best solution is selected as the output of the function.

## Results

The fit of the extracted data for all symbols was measured with the confusion matrix model. The results were obtained based on the average of all symbols as shown in the table below.

*Table (II) Fitting result for the overall index*

AV_CR	AV_Recall	AV_Precision	AV_Accuracy	AV_F1
0.66	0.58	0.78	0.94	0.67

Based on the findings of Table II, the model accuracy was 0.94, the model recall was 0.58, the model accuracy was 0.78, and the model overlap was 0.67, which were based on the average place value of 0.66, which is related to the average of all trading symbols on the Tehran Stock Exchange.

The results for the average of each industry were obtained in Table (III), which were different for different industries based on these findings. For example, for the chemical products industry group (row 37 of Table III), the model accuracy was 0.83, the model recall was 0.55, the model accuracy was 0.75, and the model overlap was 0.62, which were based on the average place value of 0.57. Therefore, the same analysis is also valid for rows 1 to 41.

**Table (III) Fitting result for each industry group**

Row	Industry Group	AV_CR	AV_Recall	AV_Precision	AV_Accuracy	AV_F1
1	Coal mining	%92	%55	%75	%76	%63
2	Other mining	%70	%52	%67	%77	%58
3	Oil, gas and related services, except exploration	%64	%52	%75	%79	%61
4	Metal ore mining	%54	%54	%76	%80	%63
5	Information and communications	%44	%48	%59	%84	%52
⋮	⋮	⋮	⋮	⋮	⋮	⋮
36	Wood products	%74	%57	%65	%74	%60
37	Chemical products	%57	%54	%75	%83	%62
38	Food and beverages except sugar	%64	%55	%70	%82	%61
39	Paper products	%65	%54	%73	%79	%61

Row	Industry Group	AV_CR	AV_Recall	AV_Precision	AV_Accuracy	AV_F1
40	Telecommunications	%55	%54	%71	%84	%59
41	Pharmaceutical products	%60	%52	%71	%84	%59

One of the results of the research, which is given in Table IV, can be a turning point of this study. In the aforementioned table, the results for each symbol are displayed on a daily basis. For example, for the symbol Fakhas (row 1 of Table IV), the model accuracy was 0.60, the model recall was 0.60, the model precision was 0.86, and the model overlap was 0.98. These results were based on the average spatial value of 0.86, which is specific to the day 2021/02/13. Therefore, the same analysis is also valid for rows 2 to 7286.

*Table (IV) Daily fitting QD result for each symbol*

Row	Symbol	date	CR	Recall	Precision	Accuracy	F1_Score
1	Fakhas	2021.02.13	%86	%60	%86	%60	%98
2	Wapasar	2021.02.27	%78	%63	%78	%63	%98
3	Fakhas	2021.02.13	%75	%60	%75	%60	%98
4	Fakhas	2021.02.14	%69	%60	%69	%60	%98
5	Bekam	2021.02.28	%60	%97	%60	%97	%98
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
7282	Paksho	2021.04.24	%32	%11	%32	%11	%17
7283	Fasepa	2021.02.13	%58	%60	%58	%60	%15
7284	Sacrum	2021.04.21	%49	%58	%49	%58	%13
7285	Our	2021.04.04	%41	%62	%41	%62	%13
7286	Khorasan	2021.03.15	%54	%56	%54	%56	%12

## Conclusion

As mentioned, high-frequency trading is the opposite of traditional long-term investment, in which instant buying and selling of stocks and other securities, as well as arbitrage and market making activities, are common activities of this trading method. It was also stated that in fact, high-frequency trading is the execution of thousands of orders in the fastest possible time, and its goal is to identify low profits in each transaction, which is often possible due to the difference in the price of the same share or asset in different markets. Therefore, the purpose of this research was to answer this important question: What is the high-frequency trading model of stocks in the Tehran Stock Exchange?

To answer this question, the influential variables in technical analysis, economic variables, and daily trading information of symbols in the stock market were processed and modeled under the learning cellular automaton algorithm and the external optimization algorithm. For the index, a specific industry group trading pattern was obtained for each symbol, which reflects the impact of economic events (Badri, 2016), political events (Mari et al; 2006), and behavioral finance theories (Prosad et al; 2015) on trading, specifically for each symbol.

## Author Contributions

“Conceptualization, Paytekhti oskooe.A. and Ahmadi.A.; methodology, Paytekhti oskooe.A; badavar nahandi.Y and Ahmadi.A.; software, Ahmadi.A.; validation, Paytekhti oskooe.A; badavar nahandi.Y and Ahmadi.A.; formal analysis, Ahmadi.A.; investigation, Ahmadi.A.; resources, Ahmadi.A.; data curation, Ahmadi.A.; writing—original draft preparation, Ahmadi.A.; writing—review and editing, Ahmadi.A.; visualization, Ahmadi.A.; supervision, Paytekhti oskooe.A. and badavar nahandi.Y; project administration, Paytekhti oskooe.A. and badavar nahandi.Y; All authors have read and agreed to the published version of the manuscript.”

**Data Availability Statement**

Not applicable.

**Ethical Considerations**

The authors avoided data fabrication, falsification, and plagiarism, and any form of misconduct.

**Funding**

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

**Conflict of Interest**

The authors declare no conflict of interest.





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

فصلنامه بورس اوراق بهادار، سال هجدهم، شماره ۷۱، پاییز ۱۴۰۴، صص ۴۰۰-۳۵۹

## ارایه مدلی برای انجام معاملات سهام با بسامد بالا، با استفاده از الگوریتم اتوماتای سلولی یادگیرنده و بهینه سازی حدی (CLA-EC-EO)<sup>۱</sup>

سیدعلیرضا احمدی<sup>۲</sup>، سیدعلی پایتختی اسکویی<sup>۳</sup>، یونس بادآور نهندی<sup>۴</sup>

تاریخ دریافت: ۱۴۰۱/۱۱/۲۳ تاریخ بازنگری: ۱۴۰۲/۰۱/۲۵

تاریخ پذیرش: ۱۴۰۲/۰۶/۱۹ تاریخ انتشار: ۱۴۰۴/۰۸/۰۱

مقاله پژوهشی

### نکات برجسته

- معاملات با فرکانس بالا، روشی معاملاتی است که از برنامه‌های کامپیوتری قدرتمند برای اجرای تعداد زیادی سفارش در کسری از ثانیه استفاده می‌کند. معاملات با فرکانس بالا نقطه مقابل سرمایه‌گذاری بلندمدت سنتی است.
- استفاده از روشی پویا که بتواند با محیط سازگار شود و از بروز اشتباه در فرآیند تصمیم‌گیری معاملاتی جلوگیری کند، بسیار ضروری به نظر می‌رسد.
- اثربخشی متغیرهای تحلیل تکنیکال و متغیرهای اقتصادی مورد استفاده برای انجام معاملات علاوه بر اینکه هر سهم شرایط خاص خود را دارد، این متغیرها برای هر اقتصاد معیارهای خاصی دارند و نمی‌توان از یک نسخه واحد برای همه جوامع استفاده کرد.
- مدل ارائه شده، سطح اطمینان برای ورود به معامله خرید و سطح اطمینان برای ورود به معامله فروش را افزایش می‌دهد.
- مدل ایجاد شده قدرت تطبیق با همه بازارهای سرمایه را دارد.

### چکیده

همزمان با افزایش سرعت تبادلات مالی، پیچیدگی‌های زیادی نیز به آن اضافه شده و به میزان چشمگیری نقش بازیگران انسانی در آن کم رنگ شده و شیوه معاملات با تواتر بالا یا به عرصه معاملات گذارده است. در این پژوهش مدلی برای معاملات با بسامد بالا ارائه شده است تا افزون بر کاهش ریسک معاملات، توانایی سازگاری با تغییرات محیطی را بصورت پویا داشته باشد. روش انجام پژوهش بهره‌گیری از الگوریتم اتوماتای سلولی یادگیرنده و بهینه سازی حدی بوده و از پارامترهای تحلیل بنیادی، اندیکاتورهای تحلیل تکنیکال، متغیرهای اقتصادی و اطلاعات معاملات روزانه سهام به عنوان متغیر استفاده شده و جامعه آماری نمادهای معامله شده در بازار بورس اوراق بهادار تهران از مرداد ۱۳۹۵ تا مرداد ۱۴۰۰ است همچنین از الگوی ماتریس درهم ریختگی به منظور ارزیابی الگوی بدست آمده استفاده شده است. نتایج پژوهش به اصلاح دامنه اثرگذاری متغیرهای تحلیل تکنیکال و نیز متغیر اقتصادی برای نمادهای معاملاتی منجر شد و نیز الگویی پویا برای معاملات بازار سهام ارائه شد که قادر به سازگاری با تغییر شرایط محیطی به منظور کاهش ریسک معاملات است.

**واژه‌های کلیدی:** معاملات با بسامد بالا، اتوماتای سلولی، بهینه سازی حدی، ماتریس درهم ریختگی.

**طبقه‌بندی موضوعی:** D53, G17, H54

10.22034/JSE.2023.12180.2110 :doi

۱. دانشجوی دکتری، گروه مهندسی مالی، دانشکده اقتصاد واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران. (a\_ahmadi44@yahoo.com).
۲. دانشیار، گروه اقتصاد، واحد تبریز، دانشگاه آزاد اسلامی، ایران. (نویسنده مسئول). (oskooe@iaut.ac.ir).
۳. دانشیار، گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، ایران. (nahandi@iaut.ac.ir).

حق انتشار این مستند متعلق به نویسندگان آن است. © ۱۴۰۴. 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/)

**استناد:** احمدی، سیدعلیرضا؛ پایتختی اسکویی، سیدعلی؛ بادآور نهندی، یونس. (۱۴۰۴). ارایه مدلی برای انجام معاملات سهام با بسامد بالا، با استفاده از الگوریتم اتوماتای سلولی یادگیرنده و بهینه سازی حدی (CLA-EC-EO). *فصلنامه بورس اوراق بهادار*. ۱۸ (۷۱)، ۳۵۹-۴۰۰. <https://10.22034/JSE.2023.12180.2110>

## مقدمه

در عصری زندگی می‌کنیم که تکنولوژی تا ریزترین بخش‌های زندگی فردی و اجتماعی انسان وارد شده است و اجتناب از آن امکان‌پذیر نیست. از جمله بازارهایی که چند سالی می‌شود به اجتناب‌ناپذیر بودن این حقیقت پی برده‌اند بازارهای مالی هستند. با ظهور فناوری‌های نوین در حوزه رایانه و ورود تکنولوژی‌های جدید به جامعه، سبک زندگی انسان‌ها بسیار متفاوت‌تر از گذشته شده و چالش‌های تازه‌ای نیز فرا روی بشر قرار گرفته است. در همین راستا بازارهای مالی و نیز مدیریت بر بازارهای مالی و همچنین شیوه‌های تجزیه و تحلیل و تصمیم‌گیری در مسایل مالی نیز دستخوش تحول و دگرگونی شده است. دیگر در بازارهای سرمایه استفاده صرف از تحلیل‌های بنیادی و یا تکیه بر تحلیل‌های تکنیکال منجر به ایجاد امنیت و کاهش ریسک سرمایه‌گذاری نمی‌شود (رستگار و دستپاک، ۱۳۹۴). به گفته والتر ماتلی<sup>۱</sup> (۲۰۱۸) ورود بازار سرمایه به عصر تکنولوژی با معاملات الگوریتمی اتفاق افتاده است. پیشرفت‌های تکنولوژیک در علوم مالی، به خصوص آن‌هایی که مربوط به معاملات الگوریتمیک می‌شوند چهره و فضای تبادلات مالی در جهان را دچار تغییرات اساسی کرده‌اند. همزمان با افزایش سرعت تبادلات مالی، پیچیدگی‌های زیادی نیز به آن اضافه شده و تا حدود زیادی نقش بازیگران انسانی در آن کاسته شده است. معاملات الگوریتمی و فرکانس بالا به دلیل همگرایی با چندین فاکتور، تبدیل به بخشی از بازارهای مالی شده‌اند. این فاکتورها شامل رشد نقش تکنولوژی در بازار، افزایش پیچیدگی ابزارهای مالی و حرکت بدون توقف به سمت کارایی بیشتر در اجرای معاملات و کاهش هزینه‌های تراکنش می‌شود. رشد در تکنولوژی معاملات اتوماتیک بازاریابی اوراق بهادار را تغییر داده است. سیستم‌های کامپیوتری جایگزین تالارهای بزرگ معاملاتی شده‌اند و کامپیوترهای پرسرعت نقش واسطه بین بازارهای مالی و معامله‌گران بازار را به عهده گرفته‌اند (ژو و پتکو<sup>۲</sup>، ۲۰۱۸). معاملات فرکانس بالا با سرعت فوق‌العاده بالایی صورت می‌گیرد و این سرعت اثر بخشی استراتژی‌های معاملاتی در فضای تجاری امروزی را افزایش داده است (۲۰۲۱، بلداف و مولنر<sup>۳</sup>). معاملات با فرکانس بالا جدیدترین و یکی از مضمولان تکنولوژیکی مهم در بسترهای معاملاتی مدرن است. سهم معاملات فرکانس بالا در معاملات سهام به طور چشمگیری در سراسر بازارهای مالی توسعه یافته است به عنوان مثال، در

1. Mattli Walter  
 2. Hao Zhou, Petko S. Kalev  
 3. Baldauf and Mollner

ایالات متحده آمریکا، کمابیش ۵۲ درصد از کل معاملات سهام در سال ۲۰۱۸ از روش معاملات با بسامد بالا بوده است (۲۰۲۱، زهارودین و همکاران<sup>۱</sup>). در طول چند دهه گذشته، روش‌های بسیاری برای پیش‌بینی بازار سرمایه پیاده‌سازی شده است. در بیشتر این پژوهش‌ها، پژوهشگران با مدل‌سازی‌های پیچیده و قراردادن فرضیه‌های متعددی سعی در پیش‌بینی نوسانات قیمت سهام کرده‌اند. ولی به علت پیچیدگی‌ها و متغیرهای فراوان تاثیرگذار در روند قیمتی بازار سرمایه، بیشتر دارای ضریب خطای بالایی بوده و یا لاقبل در همه بازارها صادق نبوده‌اند (قربانی، ۱۳۹۵). تلاش پژوهش حاضر اینست که با استفاده از خصوصیات اتوماتای سلولی یادگیرنده و بهینه‌سازی حدی مدلی برای انجام معاملات با بسامد بالا ارائه کند که بتواند بر کاهش ریسک ناشی از نوسانات قیمتی، بصورت پویا خود را با تغییرات محیطی سازگار کند.

### مبانی نظری و سابقه پژوهش

معامله بسامد بالا در نقطه مقابل سرمایه‌گذاری سنتی بلند مدت است که خرید و فروش‌های آتی سهام و سایر اوراق بهادار و همچنین فعالیت‌های آربیتراژی و بازارگردانی از کارهای معمول معاملات با بسامد بالا است. این نوع معاملات در دوره‌های زمانی بسیار کوچک، قبل از اینکه اختلاف قیمت شناسایی شده از بین برود، اجرا می‌شوند. در واقع معاملات فرکانس بالا، اجرای هزاران سفارش با سریع‌ترین زمان ممکن می‌باشد و هدف آن شناسایی سود کم در هر معامله است که اغلب با اختلاف قیمت سهم یا دارایی یکسان در بازارهای مختلف، این امر میسر می‌شود. از سوی دیگر استفاده از معاملات با بسامد بالا باعث افزایش نقدشوندگی در بازار شده و همچنین از بروز فرصت‌های آربیتراژی در معاملات جلوگیری می‌کند.

در رابطه با معاملات با بسامد بالا به برخی از پژوهش‌های صورت گرفته در زیر اشاره می‌شود: کوراجسیزکا و مورفی<sup>۲</sup> (۲۰۱۸) با استفاده از یک روش طبقه‌بندی، به بررسی نقدینگی معاملات با بسامد بالا در بازار سرمایه کانادا پرداختند. با استفاده از معرفی مالیات مبتنی بر پیام IIROC<sup>۳</sup> به عنوان یک شوک خارجی در معاملات فرکانس بالا، پژوهشگران نشان دادند که تاثیر میانگین قیمت معاملات سرمایه‌گذاری بزرگ پس از شوک، ۱۵٪ کاهش یافت.

- 
1. Zaharudin et al
  2. Korajczyk and Murphy
  3. Investment Industry Regulatory Organization of Canada

منکدلو و زویکان<sup>۱</sup> (۲۰۱۷) معامله گران با فرکانس بالا، دلالان (یا سفته بازان) با فرکانس بالا و معامله گران را در یک بازی تجاری در یک دارایی پر ریسک سهیم کردند. بازی در یک فاصله زمانی ثابت تکرار می‌شد و سفته بازان و معامله گران با بسامد بالا تنها در آغاز یا پایان هر فاصله زمانی، درخواست‌ها را ارسال یا لغو می‌کردند. در طول این بازه زمانی، هر دو گروه معامله کننده اجازه دسترسی به بازار را نداشتند اما کارگزاران بازار می‌توانستند تصمیم بگیرند که آیا هزینه نظارت را پرداخت کنند یا خیر. افزون بر این، معامله گران ممکن است به قیمت‌هایی که بازارگردانان ارائه می‌شود، تمکین کنند، درحالی که اخبار می‌توانند تغییراتی در قیمت سهام ایجاد کنند.

جارو و پورتر<sup>۲</sup> (۲۰۱۵) مزایای سرعت نسبی معامله از طریق روش فرکانس بالا را در یک محیط دارای آربیتراژ بررسی کردند. پژوهش گران یک اقتصاد متعادل را با معامله گران عادی، معامله گران پیشرفته و معامله گران با فرکانس بالا مدل کردند. معامله گران با فرکانس بالا مجاز به معامله به طور مداوم به دلیل استفاده از سرعت خود هستند، در حالی که معامله گران عادی و معامله گران پیشرفته در بازه‌های زمانی بصورت گسسته در نظر گرفته می‌شوند. ایشان دریافتند که در شرایط بدون کنترل، معاملات با بسامد بالا می‌تواند با اجرای دستورات معاملاتی در قیمت‌های محدود سود برده و نیز می‌تواند با ارسال درخواست محدود، درخواست بازار را کندتر اجرا کند. هاگسترومر، نوردن و ژانگ<sup>۳</sup> (۲۰۱۴) به تحلیل ابزار نظارت بر بازار سازان فرکانس بالا، معامله گران آربیتراژ با فرکانس بالا و معامله گران با سرعت کم پرداختند. طبقه‌بندی معامله گران با استفاده از تمرکز بر روی شناسه معامله گران بورس سهام نزدیک<sup>۴</sup> انجام می‌شد. حساب‌های معامله گران سپس به معامله گران سازمانی و معامله گران آربیتراژ فرکانس بالا تقسیم می‌شدند. پژوهشگران نشان دادند که معامله گران با فرکانس بالا، هنگامی که تقاضا برای خرید گسترده است، نقدینگی بیشتری عرضه می‌کنند.

هندرشوت، جونز و منکولد (۲۰۱۱) دریافتند که معاملات الگوریتمی<sup>۵</sup> موجب بهبود نقدینگی و کشف قیمت می‌شود. پشت پرده معامله گران فرکانس بالا دارای سرعت واکنش

1. Menkveld and Zoican
2. Jarrow & Protter
3. Hagströmer, Nordén, and Zhang
4. Nasdaq
5. Algorithmic trading

بالاتر هستند و می‌توانند بازار را به طور موثر نظارت کنند. بنابراین، معاملات با بسامد بالا می‌تواند کارگزاران سنتی را تقویت کرده و نقدینگی را بهبود بخشد.

در مطالعه‌ای که توسط انگل و همکاران<sup>۱</sup> (۲۰۱۰) انجام شد، کیفیت بازار از ابعاد مختلف مانند تغییرات در طول زمان، مورد بررسی قرار گرفت. آنها نشان دادند که معاملات الگوریتمیک تقریباً بر تمام ابعاد بازار تاثیرگذار بوده است. آنها با بررسی منابع داده‌ای متفاوت نشان دادند که سرعت اجرای معاملات کاهش پیدا کرده در عوض امکان پایش کیفیت اجرا افزایش پیدا کرده است. همچنین کمیسیون معاملات کاهش پیدا کرده و همچنان در حال کاهش است. اختلاف قیمت میان خرید و فروش به طرز چشم‌گیری کاهش پیدا کرده و همچنان در پایین‌ترین سطح خود باقی مانده و عمق بازار به طرز چشم‌گیری افزایش یافته است. همچنین مطالعات آنها نشان داد که هزینه تراکنش‌های سرمایه‌گذاران نهادی همچنان پایین‌ترین هزینه در سطح جهان است.

سونگ کویولی و یونگ رو مون<sup>۲</sup> (۲۰۰۹)، هاگسترومر، نوردن و ژانگ<sup>۳</sup> (۲۰۱۴)، به تحلیل ابزار نظارت بر بازار سازان فرکانس بالا، معامله‌گران آربیتراژ با فرکانس بالا و معامله‌گران عادی (سرعت کم) پرداختند. طبقه‌بندی معامله‌گران با استفاده از تمرکز بر روی شناسه معامله‌گران بورس سهام نزدیک<sup>۴</sup> انجام می‌شد. حساب‌های معامله‌گران سپس به معامله‌گران سازمانی و معامله‌گران آربیتراژ فرکانس بالا تقسیم می‌شدند. پژوهشگران نشان دادند که معامله‌گران با فرکانس بالا، هنگامی که تقاضا برای خرید گسترده است، نقدینگی بیشتری عرضه می‌کنند. بسیاری از الگوریتم‌ها بر کیفیت داده‌های بازار و سیستم‌های اطلاعات معاملاتی متکی هستند. این ارتقاء زیرساخت‌ها به طور چشمگیر به افزایش معاملات سیستمی<sup>۵</sup> کمک می‌کند.

منکدلو و زویکان<sup>۶</sup> (۲۰۱۷)، معامله‌گران با فرکانس بالا، دلالات (یا سفته‌بازان) با فرکانس بالا و معامله‌گران را در یک بازی معاملاتی در یک دارایی پر ریسک سهام کردند. بازی در یک فاصله زمانی ثابت تکرار می‌شد و سفته‌بازان و معامله‌گران با بسامد بالا تنها در آغاز یا پایان هر فاصله زمانی، سفارشات را ارسال یا لغو می‌کردند. در طول این بازه زمانی، هر دو گروه معامله‌کننده اجازه دسترسی

1. Angel
2. Seung-Kyu Lee & Byung-Ro Moon
3. Hagströmer, Nordén, and Zhang
4. Nasdaq
5. Computerized Trading
6. Menkveld and Zoican

به بازار را نداشتند، اما کارگزاران بازار می‌توانستند تصمیم بگیرند که آیا هزینه نظارت را پرداخت کنند یا خیر. افزون بر این، معامله گران ممکن است به قیمت‌هایی که بازارگردانان ارائه می‌شود، تمکین کنند، درحالی که اخبار می‌توانند تغییراتی در قیمت سهام ایجاد کنند.

کوراجسیزکا و مورفی<sup>۱</sup> (۲۰۱۹)، با استفاده از یک روش طبقه‌بندی، به بررسی میزان نقدینگی در بازار سرمایه کانادا که از معاملات با بسامد بالا استفاده می‌کنند، پرداختند. پژوهشگران نشان دادند که وضع مالیات توسط سازمان تنظیم مقررات کانادا<sup>۲</sup> به عنوان یک شوک خارجی در معاملات فرکانس بالا، این نوع معاملات را تا ۱۵٪ کاهش می‌دهد.

وی شی و چن<sup>۳</sup> (۲۰۲۰)، به بررسی رابطه بین معاملات با فرکانس بالا و ریسک نقدینگی و چگونگی تأثیر این نوع معاملات بر نقدینگی بازار آتی شاخص سهام چین با استفاده از مدل ارزش در معرض خطر تعدیل شده<sup>۴</sup> پرداختند، یافته‌های آنها نشان می‌دهد که معاملات با فرکانس بالا بازده سرمایه‌گذاری را بهبود می‌بخشد و ریسک نقدینگی را به میزان چشمگیری کاهش می‌دهد.

بلداف و مولنر<sup>۵</sup> (۲۰۲۱)، مدل تعامل بین معامله گرانی که از الگوی معاملات با بسامد بالا استفاده می‌کنند و سرمایه‌گذارانی که از روش تحلیل بنیادی بهره می‌برند را، در بورس‌های متعدد را ارایه کردند. این دو پژوهشگر استدلال می‌کنند که پیش‌بینی رفتار معاملات پر نوسان، مانع کسب اطلاعاتی می‌شود که از طریق آن بتوان قیمت‌داری‌ها را مدل کرد.

بن عمار و هلارا<sup>۶</sup> (۲۰۲۲) به بررسی رابطه بین معاملات با فرکانس بالا، نوسانات سهام و سقوط روزانه سهام در بازار الکترونیکی بورس اوراق بهادار اروپا<sup>۷</sup> پرداختند. آنها به این نتیجه رسیدند که در شرایط ثبات بازار، معاملات با فرکانس بالا منجر به کاهش نوسان قیمت سهام می‌شود. با این حال، در طول دوره‌های سقوط روزانه، معاملات سریع بین الگوریتم‌های این نوع معاملات منجر به نرخ بالای لغو سفارش و خروج همزمان معامله‌گران با فرکانس بالا از صف سفارشات می‌شوند.

1. Korajczyk and Murphy
2. Investment Industry Regulatory Organization of Canada
3. GuangWei Shi, Yun Chen
4. LVaR
5. Baldauf and Mollner
6. Imen Ben Ammar, Slaheddine Hellara
7. Euronext

خو و ژانگ<sup>۱</sup> (۲۰۲۳) مدل پیش‌بینی حجم معاملات با فرکانس بالا با استفاده از شبکه‌های عصبی را مطرح کردند. مطالعه آنها بر روی بازارهای شانگهای و شنزن<sup>۲</sup> بود نتایج نشان داد که یک مدل نسبتاً ساده مبتنی بر ده نورون پنهان و سی تأخیر منجر به نتایج پیش‌بینی پایدار و دقیق براساس اندازه‌گیری میانگین مربعات خطای ریشه نسبی می‌شود.

### روش‌شناسی پژوهش

پژوهش حاضر از دیدگاه روش همبستگی و علی و بر اساس هدف، یک پژوهش بنیادی است و از این جهت که از اطلاعات تاریخی برای این پژوهش استفاده می‌شود بنابراین از پژوهش‌های پس رویدادی به شمار می‌رود. در حالی که از دیدگاه نوع مطالعه، میدانی-کتابخانه‌ای است. جامعه آماری این پژوهش سهام شرکت‌های مورد معامله در بورس اوراق بهادار تهران است و نمونه آماری کلیه نمادهای معامله شده در بورس اوراق بهادار تهران از تاریخ ۱۳۹۵/۰۵/۰۱ الی ۱۴۰۰/۰۵/۰۱ است که بصورت روزانه جمع‌آوری شده‌اند. از آنجایی که معاملات فرکانس بالا بسیار رقابتی است، به این معنا که به طور مداوم سیستم‌ها باید در حال تکامل باشند. گرچه این نوع معاملات در بیشتر موارد نتیجه بخش هستند اما گاه در نتیجه تغییر ساختار بورس‌ها یا تصویب یک قانون جدید یا سبقت گرفتن یک رقیب از سرعت پردازش شما، باعث می‌شود که ماه‌ها کارسخت و پژوهش به هدر رود. بنابراین بهره‌گیری از روشی پویا که بتواند خود را با محیط سازگار کرده و مانع از بروز اشتباه در روند تصمیم‌گیری‌های معاملاتی شود بسیار ضروری به نظر می‌رسد. به همین علت استفاده از یک روش یادگیری بنام یادگیری تقویتی مورد توجه قرار گرفته است. یادگیری تقویتی نه زیر مجموعه‌ی شبکه‌های عصبی است و نه انتخابی بجای آنها محسوب می‌شود. بلکه رویکردی متعادل<sup>۳</sup> برای حل مسائل متفاوت و مشکل‌تر بشمار می‌رود. یادگیری تقویتی، از ترکیب برنامه‌نویسی پویا و یادگیری نظارتی برای دستیابی به یک سیستم قدرتمند یادگیری ماشین استفاده می‌کند. در یادگیری تقویتی هدفی برای عامل یادگیر مشخص می‌شود تا به آن دست یابد. آنگاه عامل مذکور یاد می‌گیرد که چگونه با آزمایش‌های صحیح و خطا با محیط خود، به هدف تعیین شده برسد. در یادگیری تقویتی یک عامل یادگیرنده در طی یادگیری با فعل و

1. Xiaojie Xu, Yun Zhang  
2. CSI 300  
3. Orthogonal

انفعالات<sup>۱</sup> مکرر با محیط، به یک سیاست کنترل بهینه می‌رسد. کارایی این فعل و انفعالات با محیط بوسیله پیشینه (کمینه) بودن پاداش (جریمه) عددی که از محیط گرفته می‌شود، ارزیابی می‌شود. افزون بر این در روش‌های یادگیری تقویتی، نخست استفاده از یادگیری روش ساده، سیستماتیک و واقعی برای رسیدن به یک جواب تقریباً بهینه را بیان می‌کند (پیدا کردن این جواب بهینه با استفاده از روش‌های سنتی بسیار مشکل است). دوم، دانشی که در طی فرایند یادگیری بدست می‌آید، در یک مکانیزم نمایش دانش مانند شبکه عصبی یا جدول مراجعه ذخیره می‌شود که از طریق آن می‌توان با محاسبات اندک و با کارایی بالایی عمل تخصیص کانال را انجام داد. سوم، از آنجاییکه این روش یادگیری در محیطی بلادرنگ در حال انجام است، می‌توان آنرا همزمان با فعالیت محیط (مانند شبکه سلولی) انجام داد. که در این حالت با تمام رخدادهای پیش‌بینی نشده بصورت یک تجربه جدید برخورد می‌شود که می‌توان از آنها برای بهبود کیفیت یادگیری استفاده کرد. برتری اصلی یادگیری تقویتی نسبت به سایر روشهای یادگیری عدم نیاز به هیچگونه اطلاعاتی از محیط (بجز سیگنال تقویتی) است. یکی از روشهای یادگیری تقویتی، اتوماتای یادگیر تصادفی است. اتوماتای تصادفی بدون هیچگونه اطلاعاتی درباره اقدام بهینه (یعنی با در نظر گرفتن احتمال یکسان برای تمامی اقدامهای خود در آغاز کار) سعی در یافتن پاسخ مساله دارد. یک اقدام اتوماتا بصورت تصادفی انتخاب می‌شود، در محیط اعمال می‌شود. سپس پاسخ محیط دریافت شده و احتمال اقدامها بر طبق الگوریتم یادگیری به روز می‌شوند و روال بالا تکرار می‌شود. اتوماتای تصادفی که بصورت بالا در جهت افزایش کارایی خود عمل کند، یک اتوماتای یادگیر تصادفی گفته می‌شود. از طرفی بسیاری از مسایل را نمی‌توان با استفاده از یک اتوماتای یادگیر تکی حل کرد بلکه قدرت اصلی اتوماتای یادگیر زمانی آشکار می‌شود که آنها به صورت دسته جمعی بکار روند. با توجه به این مساله مدل اتوماتای یادگیر سلولی<sup>۲</sup> پیشنهاد می‌شود. اتوماتای یادگیر سلولی (CLA) از ترکیب اتوماتاهای یادگیر (LA) و (CA) حاصل شده است و مدلی برای سیستم‌هایی است که اجزاء ساده‌ای تشکیل شده‌اند و رفتار هر جزء بر اساس رفتار همسایگانش و نیز تجربیات گذشته‌اش تعیین و اصلاح می‌شود. هر اتوماتای یادگیر سلولی، از یک اتوماتای سلولی تشکیل شده است که هر سلول آن به یک یا چند اتوماتای یادگیر مجهز است که وضعیت سلول

- 
1. Interaction
  2. Cellular automata

را مشخص می‌سازند. در اتوماتای سلولی، قانون محلی به طور مستقیم وضعیت سلول را مشخص می‌کند ولی در اتوماتای یادگیر سلولی این قانون تعیین می‌کند که آیا عمل انتخاب شده توسط یک اتوماتای یادگیر یک سلول بایستی پاداش داده شود و یا جریمه شود، عمل دادن پاداش و یا جریمه، منجر به بروزرسانی ساختار اتوماتای یادگیر سلولی به منظور نیل به یک هدف مشخص می‌شود. پویایی اتوماتای یادگیر سلولی از به کارگیری مکرر قانون محلی بر روی اتوماتاهای یادگیر تمام سلول‌ها حاصل می‌شود.

یکی از مدل‌هایی که از ترکیب مفاهیم تکامل و یادگیری بدست آمده است مدل CLA-EC می‌باشد که ترکیبی از مدل CLA و محاسبات تکاملی (EC) است. در مدل CLA-EC هر ژنوم به یکی از سلول‌های اتوماتای یادگیر سلولی اختصاص می‌یابد. مجموعه اعمال انتخاب شده توسط اتوماتاهای هر سلول، به رشته ژنومی آن سلول اختصاص می‌یابد. براساس قانون محلی، یک بردار سیگنال تقویتی ایجاد می‌شود و به مجموعه اتوماتاهای یادگیر مستقر در آن سلول داده می‌شود. هر یک از اتوماتاهای یادگیر، براساس سیگنال دریافت شده و الگوریتم یادگیری، ساختار داخلی خود را به‌هنگام می‌کنند. فرایند انتخاب عمل‌ها و به‌هنگام درآوردن ساختار داخلی تا زمانی که یک معیار از پیش تعیین شده ارضاء نشود، تکرار می‌شود. این مدل می‌تواند برای حل مسائل بهینه‌سازی استفاده شود. نشان داده شده است که CLA-EC ساده در حل مسایل بهینه‌سازی در مقایسه با CLA و یا الگوریتم‌های ژنتیکی از کارایی بالاتری برخوردار است. سرعت همگرایی و دقت این مدل در حل مسایل بهینه‌سازی بستگی زیادی به انتخاب مناسب پارامترهای این مدل دارد. انتخاب مقادیر نامناسب برای این پارامترها ممکن است منجر به سرعت همگرایی پایین و یا به دام افتادن در بهینه‌های محلی شود. اگر نرخ یادگیری اتوماتاهای یادگیر مستقر در سلولهای CLA بالا باشد، سرعت همگرایی افزایش می‌یابد ولی در عوض ممکن است الگوریتم در جوابهای بهینه محلی به دام افتد و اگر از نرخ یادگیری پایین استفاده شود، الگوریتم از دقت خوبی برخوردار می‌شود ولی سرعت همگرایی به شدت کاهش می‌یابد. برای حل این مشکل در این تحقیق ما از مدل CLA-EC همکارانه استفاده خواهیم کرد. از سوی دیگر مطالعات بر روی الگوریتم بهینه‌سازی CLA-EC نشان می‌دهند که این الگوریتم با وجود جستجوی مناسب دامنه مساله، جواب‌هایی با دقت بالا تولید نمی‌کند بنابراین با ترکیب این الگو با الگوریتم بهینه‌سازی حدی این مشکل نیز برطرف خواهد شد. در نتیجه با استفاده از

خصوصیات اتوماتای سلولی یادگیرنده و بهینه سازی حدى می توان بر تهدید نوسانات محیطی غلبه کرد و مدلی پویا طراحی کرد که با تغییرات محیطی خود را سازگار کند. متغیرهایی که در این مدل مورد استفاده قرار می گیرند در چهار گروه بصورت زیر دسته بندی می کنیم.

جدول ۱. متغیرهای پژوهش

متغیرهای تحلیلی بنیادی (گروه A)	وضعیت معاملات روزانه (گروه B)	متغیرهای تحلیل تکنیکال (گروه C)	متغیرهای اقتصادی (گروه D)
۱. نسبت سود هر سهم	۱. حجم معاملات روزانه	۱. میانگین متحرک نمایی	۱. قیمت طلا
۲. نسبت قیمت سهم به درآمد آن	۲. تعداد معاملات ثبت شده	۲. بولینگر باندز	۲. نرخ ارز
	۳. ساعت انجام معامله	۳. شاخص قدرت نسبی	۳. نرخ تورم
	۴. روز انجام سفارش	۴. درجه تغییرات	۴. نرخ رشد شاخص سهام
		۵. استوکاستیک	۵. قیمت نفت خام
		۶. شاخص جریان مالی	۶. حجم نقدینگی
			۷. رشد تولید

ملاک انتخاب متغیرهای پژوهش در چهار گروه:

- از آنجایی که معاملات با بسامد بالا در حداقل ترین زمان صورت می گیرد بنابراین هر چه نمادهایی که به عنوان مقدار اولیه به الگوریتم داده می شود شانس بیشتری برای انتخاب داشته باشند سرعت اجرای الگوریتم افزایش می یابد بنابراین متغیرهای گروه A به این موضوع کمک خواهد کرد.
- به منظور استخراج الگوی معاملاتی، رصد لحظه ای وضعیت نماد در طی روز بسیار مهم است که این امر علت انتخاب متغیرهای گروه B است که البته این متغیرها از پایه های طراحی معاملات با بسامد بالا در هر بازاری به شمار می روند.
- بر اساس گفته های وایزمن<sup>۱</sup> (۲۰۰۵) و مورفی<sup>۲</sup> (۱۹۹۹) در خصوص اهمیت این متغیرها و همچنین سایر پژوهش های انجام شده، متغیرهای گروه C انتخاب شده اند.
- تغییرات در شاخص بورس به دلیل ارتباط تنگاتنگ این بخش از اقتصاد با دیگر قسمت ها، نه تنها اقتصاد یک کشور، بلکه اقتصاد جهانی را تحت تأثیر قرار می دهد بنابراین شاخص های تاثیرگذاری که در اغلب پژوهش ها داخلیمورد بررسی قرار گرفته اند در این پژوهش در قالب متغیرهای گروه D بررسی شده اند.

1. Weissman, Richard L

2. Murphy, J. J

## روش تجزیه و تحلیل داده‌ها

اطلاعات گردآوری شده از طریق نرم افزار دلفی و با استفاده از الگوریتم های معاملات با بسامد بالا و ترکیب آن با الگوریتم اتوماتای سلولی یادگیرنده و بهینه سازی حدی، طی پنج مرحله بشرح زیر مورد تجزیه و تحلیل قرار گرفته است.

۱. ابتدا با استفاده از متغیرهای گروه a به انتخاب سهم‌هایی که در صنعت مورد نظر دارای p/e بالایی نسبت به میانگین صنعت هستند اقدام می‌کنیم. در این مرحله ابتدا نمادها در صنعت مربوطه خود دسته بندی شده و p/e نمادها استخراج می‌شود، p/e هایی که دارای اختلاف نامتعارفی نسبت به دیگر سهام موجود در آن صنعت هستند حذف می‌شوند. سپس نمادهایی که در هر گروه نسبت به میانگین خود دارای p/e پایین تری هستند در اولویت انتخاب قرار داده می‌شوند.

۲. سهام منتخب برای یک بازه زمانی ۲۰ روزه (کاری) به عنوان داده‌های اولیه وارد پروسه پردازش می‌شوند.

۳. سهام انتخاب شده با متغیرهای گروه b وارد الگوریتم اتوماتا شده و پردازش می‌شوند.

۴. سهام انتخاب شده با متغیرهای گروه c وارد الگوریتم اتوماتا شده و پردازش می‌شوند.

۵. سهام انتخاب شده با متغیرهای گروه d وارد الگوریتم اتوماتا شده و پردازش می‌شوند.

۶. اطلاعات خروجی از مراحل ۳ و ۴ و ۵ از طریق الگوریتم بهینه‌سازی حدی<sup>۱</sup> بشرح مورد پردازش قرار خواهد گرفت.

۱. برازش را برای هر متغیر محاسبه می‌کنیم.

۲. همه برازش‌ها را مرتب کرده و متغیری که دارای کمترین برازش است را انتخاب می‌کنیم.

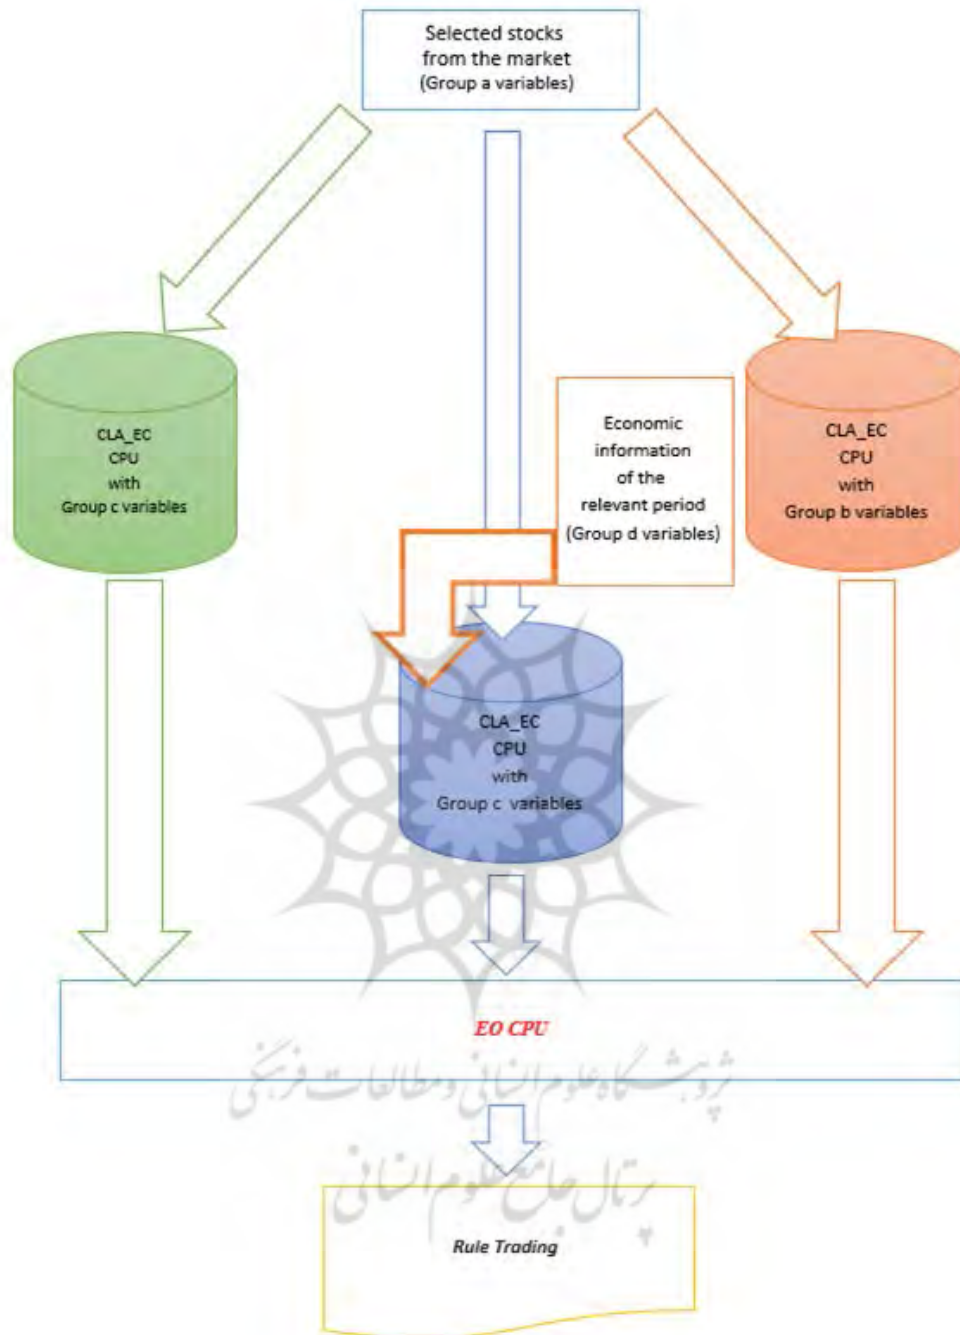
۳. مقدار متغیر انتخابی با مقدار دیگری در همسایگی آن جایگزین می‌شود.

۴. راه حل ایجاد شده به عنوان راه حل جاری در نظر گرفته می‌شود.

۵. در صورتی که راه حل جاری بهتر از بهترین جواب باشد به عنوان بهترین راه حل نیز انتخاب می‌شود.

۶. مرحله ۲ را تا رسیدن به راه حل مطلوب تکرار می‌کنیم.

۷. بهترین جواب به عنوان خروجی تابع انتخاب می‌شود.



شکل ۱. مدل مفهومی پژوهش

## روش پژوهش

یک اتوماتای یادگیر را می‌توان بصورت یک شیء مجرد که دارای تعداد متناهی اقدام است، در نظر گرفت. اتوماتای یادگیر با انتخاب یک اقدام از مجموعه اقدام‌های خود و اعمال آن بر محیط، عمل می‌کند. اقدام یادشده توسط یک محیط تصادفی ارزیابی می‌شود و اتوماتا از پاسخ محیط برای انتخاب اقدام بعدی خود استفاده می‌کند. در طی این فرآیند اتوماتا یاد می‌گیرد که اقدام بهینه را انتخاب کند. چگونگی استفاده از پاسخ محیط به اقدام انتخابی اتوماتا که در جهت انتخاب اقدام بعدی اتوماتا استفاده می‌شود، توسط الگوریتم یادگیری اتوماتا مشخص می‌شود. در بخش بعد جزئیات قسمتهای یک اتوماتای با ساختار متغیر<sup>۱</sup> معرفی می‌شود.

الگوریتم یادگیری T بصورت  $P(n+1) = T(p(n), \alpha(n), \beta(n))$  نشان داده می‌شود. اگر T یک عملگر خطی باشد، الگوریتم یادگیری تقویتی، خطی نامیده می‌شود. در غیر اینصورت الگوریتم یادگیری غیرخطی نامیده می‌شود. ایده اصلی تمام الگوریتم‌های یادگیری بصورت زیر است.

اگر اتوماتای یادگیر در تکرار n ام، یک اقدام خود مانند  $\alpha_i$  را انتخاب کند و یک پاسخ مطلوب<sup>۲</sup> از محیط دریافت کند،  $p_i(n)$  (احتمال اقدام  $\alpha_i$ ) افزایش و احتمال سایر اقدام‌ها کاهش می‌یابد. بالعکس در صورت نامطلوب بودن پاسخ دریافتی از محیط، احتمال اقدام  $\alpha_i$  کاهش و احتمال سایر اقدام‌های اتوماتا افزایش می‌یابد. در هر حال، تغییرات به گونه ای صورت می‌گیرد تا حاصل جمع  $p_i(n)$  ها همواره ثابت و مساوی یک باقی بماند. تغییر احتمال اقدام‌ها بصورت زیر است.

الف- پاسخ مطلوب از محیط

$$p_i(n+1) = p_i(n) + \sum_{\substack{j=1 \\ j \neq i}}^r f_j [p_j(n)] \quad \text{رابطه (۱)}$$

$$p_j(n+1) = p_j(n) - f_j [p_j(n)] \quad \forall j, j \neq i$$

ب- پاسخ نامطلوب از محیط

1. Variable Structure Learning Automata
2. Favorable

$$p_i(n+1) = p_i(n) - \sum_{\substack{j=1 \\ j \neq i}}^r g_j[p_j(n)] \quad \text{رابطه (۲)}$$

$$p_j(n+1) = p_j(n) - g_j[p_j(n)] \quad \forall j, j \neq i$$

توابع  $f_j$  و  $g_j$  دو تابع غیر منفی هستند که بترتیب توابع پاداش و جریمه نامیده می‌شوند. از آنجایی که الگوریتم‌های یادگیری خطی از لحاظ ریاضی ساده‌تر هستند، بررسی‌های زیادی بر روی آنها انجام شده است. در یک الگوریتم یادگیری تقویتی خطی (در اتوماتایی با چند اقدام) توابع  $f_j$  و  $g_j$  بصورت زیر تعریف شده‌اند.

$$f_j[p_j(n)] = ap_j(n) \quad 0 < a < 1 \quad \text{رابطه (۳)}$$

$$g_j[p_j(n)] = \frac{b}{r-1} - bp_j(n) \quad 0 \leq b < 1 \quad \text{رابطه (۴)}$$

که  $r$  تعداد اقدامهای اتوماتا،  $a$  پارامتر پاداش و  $b$  پارامتر جریمه هستند. با استفاده از رابطه (۳) و (۴) شکل عمومی الگوریتم یادگیری بصورت زیر است. اگر در گام  $n$ ام اقدام  $\alpha_i$  انتخاب شده باشد، سپس در گام  $n+1$ ام خواهیم داشت:

الف- پاسخ مطلوب از محیط

$$\begin{aligned} p_i(n+1) &= p_i(n) + a[1 - p_i(n)] \\ p_j(n+1) &= (1-a)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad \text{رابطه (۵)}$$

ب- پاسخ نامطلوب از محیط

$$\begin{aligned} p_i(n+1) &= (1-b)p_i(n) \\ p_j(n+1) &= \frac{b}{r-1} + (1-b)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad \text{رابطه (۶)}$$

نویزگیری (نرمال سازی): یکی از اصول علم پایگاه داده‌ها از بین بردن افزونگی است. افزونگی به این معناست یک اطلاع خاص در چند محل مختلف پایگاه ذخیره شود. این امر موجب می‌شود خطری بالقوه به وجود آید که داده‌ها هر لحظه با هم در تضاد قرار گیرند و استخراج واقعیت از آنها غیرممکن شود به بیان دیگر فرایندی است که بر اساس آن داده‌ها و اطلاعات در واحدهای منطقی به نام جدول به شکلی توزیع می‌شود که افزون بر حفظ موجودیت داده‌ها از ایجاد پدیده افزونگی جلوگیری بعمل می‌آورد به این منظور فرم‌های نرمال متعددی

تعریف و مورد استفاده قرار می‌گیرد، در این مدل نوین‌گیری در واقع همان نرمال سازی داده‌ها خواهد بود که بطور همزمان حین اجرای گام اولیه‌ی الگوریتم اتوماتا منظور می‌شود. تابعی که برای این منظور استفاده می‌شود تحت عنوان "Read\_Of\_Pxls\_Pm" نامگذاری شده است. محاسبه اولیه: در این مرحله با استفاده از اطلاعات معاملات محاسبه شاخص‌ها صورت می‌گیرد. نکته چشمگیر در این بخش این است که نمادهایی که روزهای معاملاتی آن‌ها بصورت متوالی نبوده و شاید نماد بسته‌ای در بین نمادها وجود داشته باشد از پروسه انجام محاسبات کنار گذاشته خواهد شد و به محض باز شدن نماد و پر شدن تعداد روزهای معاملاتی، در محاسبه شرکت داده خواهد شد. بنابراین این شبیه که اطلاعات نادرستی در روند انجام محاسبات وارد شود، مردود خواهد شد. تابعی که برای این منظور استفاده می‌شود تحت عنوان "Active\_Co\_2" نامگذاری شده است.

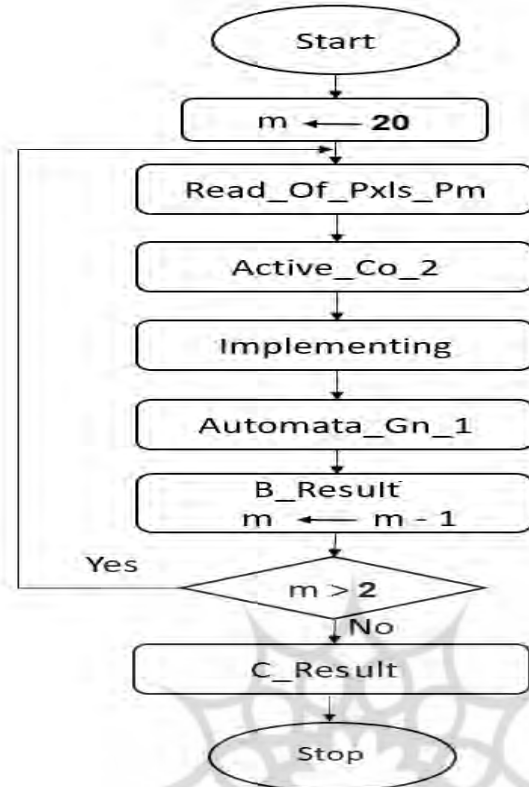
جایگذاری: هر گروه از متغیرها بصورت آرایه‌ای از سلول‌های اتوماتا در نظر گرفته می‌شوند. بنابراین در هر مرحله ما چهار آرایه داریم که شامل یک آرایه دو عضوی (متغیرهای گروه a)، یک آرایه چهار عضوی (متغیرهای گروه b)، یک آرایه شش عضوی (متغیرهای گروه c) و همچنین یک آرایه هفت عضوی (متغیرهای گروه d) به عنوان سلول‌های اتوماتا که هر کدام در آرایه‌ای از سلول‌های همسایه‌ی خود بصورت جداگانه پردازش می‌شوند. تابعی که برای این منظور استفاده می‌شود تحت عنوان "Implementing" نامگذاری شده است.

نسل اول: در این مرحله ما اقدام به محاسبه نسل ۱ از حالات رخ داده برای هر اندیکاتور می‌کنیم. در واقع نخستین قدم از ایجاد نسل‌های بهینه برداشته می‌شود. تابعی که برای این منظور استفاده می‌شود تحت عنوان "Automata\_Gn\_1" نامگذاری شده است.

ایجاد قانون: پس از تولید نسل اول از داده‌های اولیه (حرکت از نسل ۰ به نسل ۱)، زمان تبدیل کردن خروجی تابع قبل به قوانین باینری و شماره گذاری قوانین است. تابعی که برای این منظور استفاده می‌شود تحت عنوان "B\_Result" نامگذاری شده است.

نسل‌های بعدی از طریق جایگذاری و تولید نسل جدید ساخته می‌شود و سرانجام استخراج جواب بهینه از قوانین موجود صورت می‌گیرد. تابعی که برای این منظور استفاده می‌شود تحت عنوان "C\_Result" نامگذاری شده است.

فلوچارت اجرایی الگوریتم بصورت شکل (۲) آورده شده است.



شکل ۲. فلوچارت اجرایی الگوریتم

توابع و جدول‌های استفاده شده:

جدول ۲. توابع و جداول استفاده شده

نام جدول	نام تابع	ردیف
Master_Tbl	Read_Of_Pxls_Pm	۱
Selected_Tbl	Active_Co_۲	۲
A_Result_Tbl	implementing	۳
Calc_Tbl	Automata_Gn_۱	۴
B_Result_Tbl	B_Result	۵
C_Result_Tbl	C_Result	۶

تعداد نمادهای شرکت داده شده در محاسبات:

جدول ۳. تعداد شرکت ها و روزهای معاملاتی

ردیف	بورس	تعداد شرکت ها	تعداد روزهای معاملاتی/نماد
۱	بورس اوراق بهادار تهران	۴۳۵	۴۱۴۹۷۸

محاسبات انجام شده برای هر گروه

تعداد محاسبات انجام شده برای گروه a:

جدول (۴) تعداد شرکت ها و روزهای معاملاتی متغیرهای گروه a

ردیف	بورس	تعداد شرکت ها (n)	متوسط معاملات برای نماد / روز (d)	کل محاسبات انجام شده (T <sub>ca</sub> )
۱	بورس اوراق بهادار تهران	۴۳۵	۹۴۵	۸۲۲۱۵۰

$$T_{ca} = d * n * 2$$

رابطه (۷)

تعداد محاسبات انجام شده برای گروه b:

m = تغییرات روزهای محاسباتی

i<sub>b</sub> = متغیرهای گروه b

جدول ۵. تعداد شرکت ها و روزهای معاملاتی متغیرهای گروه b

ردیف	بورس	تعداد شرکت ها (n)	متوسط معاملات برای نماد / روز (d)	کل محاسبات انجام شده (T <sub>cb</sub> )
۱	بورس اوراق بهادار تهران	۴۳۵	۹۴۵	۴۶۳۱۷۰۶۰

$$T_{cb} = \sum_{m=2}^{20} ((d - m) * i * n)$$

رابطه (۸)

تعداد محاسبات انجام شده برای گروه c:

m = تغییرات روزهای محاسباتی

i<sub>c</sub> = متغیرهای گروه c

جدول ۶. تعداد شرکت ها و روزهای معاملاتی متغیرهای گروه c

ردیف	بورس	تعداد شرکت ها (n)	متوسط معاملات برای نماد / روز (d)	کل محاسبات انجام شده (T <sub>cc</sub> )
۱	بورس اوراق بهادار تهران	۴۳۵	۹۴۵	۲۷۸۴۴۸۲۸۰

$$T_{cc} = \sum_{m=2}^{90} ((d - m) * i * n) \quad \text{رابطه (۹)}$$

تعداد محاسبات انجام شده برای گروه d:

k = تعداد انجام محاسبه در هر روز برای هر نماد

ic = متغیرهای گروه d

جدول ۷. تعداد شرکت ها و روزهای معاملاتی متغیرهای گروه d

ردیف	بورس	تعداد شرکت ها (n)	متوسط معاملات برای نماد / روز (d)	کل محاسبات انجام شده (T <sub>cd</sub> )
۱	بورس اوراق بهادار تهران	۴۳۵	۹۴۵	۱۷۲۶۵۱۵۰۰

$$T_{cd} = d * n * k * i \quad \text{رابطه (۱۰)}$$

پس از گرفتن خروجی از گروه متغیرهای چهار گانه نوبت به ترکیب و بهینه سازی پاسخها با استفاده از الگوریتم بهینه سازی حدی می رسد. الگوریتم های مبتنی بر بهینه سازی حدی بر خلاف دیگر الگوریتم های بهینه سازی نظیر الگوریتم ژنتیک که همواره از مجموعه ای از جوابها (جمعیت) تشکیل شده اند، در هر لحظه تنها یک جواب در اختیار دارند و در هر مرحله این جواب را بهبود می بخشند. بهبود جواب با انتخاب یکی از اجزای جواب و جایگزین کردن مقدار آن با مقداری جدید انجام می شود. برای انتخاب جزء تعویضی، الگوریتم از شایستگی محلی اجزا استفاده می کند بنابراین این الگوریتم ها افزون بر تابع شایستگی کلی جواب، به تابعی برای ارزیابی شایستگی اجزای جواب (شایستگی محلی) نیز احتیاج دارند. روشن است که این تابع وابسته به نوع مساله بوده و برای هر مساله باید به صورت جداگانه تعریف و پیاده سازی شود.

پس از اجرای الگوریتم آتوماتا بر روی متغیرهای گروه b، c و d نتایج در جدولی بنام IR\_BUY\_SEL\_TBL به منظور تهیه داده های ورودی الگوریتم بهینه سازی حدی



هر اندازه مقدار Sel\_Rate بزرگتر باشد دقت پیش بینی برای فروش بیشتر خواهد بود.


برای شکل (۳) نرخ محاسبه شده برای فروش بصورت زیر است:

$$Sel\_Rate = 50\%$$

همان گونه که دیده می شود توابع Buy\_Rate و Sel\_Rate ارزش محاسبه شده را به طور مساوی برمی گرداند به بیان دیگر برای متغیرهای بیست و دو گانه ارزش واحدی برای اتخاذ تصمیم در نظر می گیرد که این همان نکته مهمی است که در الگوریتم آتوماتا مورد ملاحظه است. درست است که آتوماتای سلولی برای هر متغیر مقداری را محاسبه کرده و در تصمیمات خرید منفردا دخیل می کند که ممکن است برای آن متغیر مقدار بهینه باشد ولی در تصمیمات خرید یا فروش ممکن است درصد بالایی را نتواند پیش بینی کند و این موضوع برای تک تک متغیرهایی که درصد پیش بینی برای تصمیم گیری آتوماتا محاسبه شده، صادق است.

وقتی این درصد پیش بینی (Buy\_Rate و Sel\_Rate) بطور مساوی ارزش گذاری شوند ممکن است نتایج فاجعه بار باشد بنابراین از الگوریتم بهینه سازی حدی کمک می گیریم که در قالب تابع Bs\_Rate\_E در این پژوهش آورده شده است.

۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱
۷۶/۱۷٪	۷۹/۴۵٪	۱۰۰/۰۰٪	۱۰۰/۰۰٪	۲۰/۰۰٪	۱۸/۰۰٪	۱۰۰/۰۰٪	۱۸/۰۰٪	۱۷/۰۰٪	۷۷/۳۶٪	۷۴/۹۰٪



۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸	۱۹	۲۰	۲۱	۲۲
۷۷/۳۶٪	۵/۳۶٪	۷۶/۱۷٪	۵/۱۸٪	۷۰/۲۴٪	۸۲/۲۸٪	۸۲/۲۸٪	۸۲/۲۸٪	۸۲/۲۸٪	۸۲/۲۸٪	۸۰/۹۲٪

شکل ۴. ارزش متغیرها پس از اجرای الگوریتم بهینه سازی حدی

وظیفه این تابع ارزش گذاری متغیرها با استفاده از ضریب وزنی است که پیشتر توسط الگوریتم آتوماتا محاسبه شده است و این ضرایب میزان اثرگذاری هر متغیر برای هر نماد در بازه های زمانی مختلف، مشخص می شود و بنابراین قدرت پیش بینی با ترکیب و ارزش گذاری متغیرها، بالا خواهد رفت. در فرایند تصمیم گیری ارزش های  $V$  بروز شده و پس از محاسبه توسط الگوریتم آتوماتا، به منظور تشکیل یک ترکیب بهینه وارد الگوریتم بهینه سازی حدی شده و پاسخ ها بهینه می گردد و مقادیر بهینه شده افزون بر شرکت در فرایند اتخاذ تصمیمات معاملاتی دوباره به عنوان ورودی الگوریتم آتوماتا برای ایجاد ترکیب بهینه و همسو شدن با تغییرات اقتصادی، سیاسی، فرهنگی و ...، بکار می رود و این چرخه ادامه دار است و در هر لحظه توابع خرید و فروش (رابطه ۱۴ و رابطه ۱۵) بروزرسانی خواهند شد.

تابع خرید

$$Buy\_Rate\_E = \sum_{i=0}^n \frac{1}{n} Buy_i * v_{ind-i} dx \quad \text{رابطه (۱۴)}$$

براساس داده های موجود در شکل ۴ و رابطه ۱۴ ارزش خرید برابر ۲۶ خواهد بود

$$Buy\_Rate_E = \%26$$

تابع فروش

$$Sel\_Rate\_E = \sum_{i=0}^n \frac{1}{n} Sel_i * v_{ind-i} dx \quad \text{رابطه (۱۵)}$$

براساس داده های موجود در شکل ۴ و رابطه ۱۵ ارزش فروش برابر ۳۷ خواهد بود

$$Sel\_Rate\_E = \%37$$

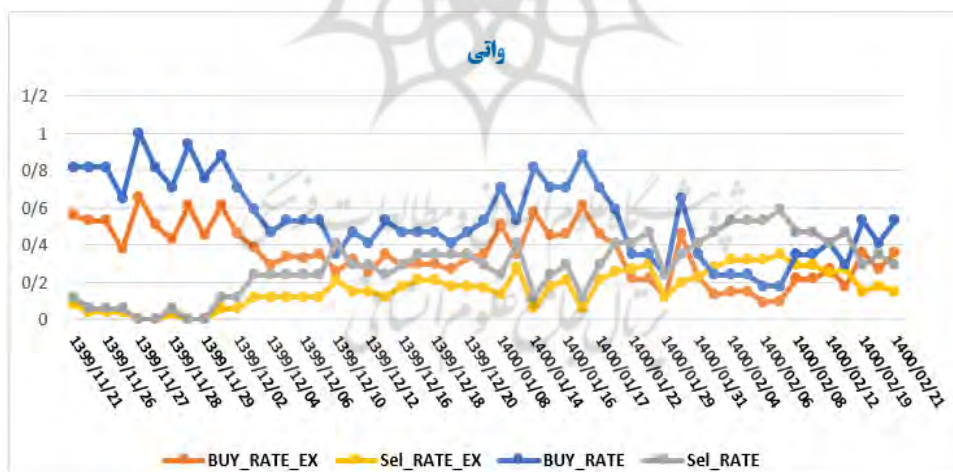
### نتایج اجرای الگوریتم بهینه سازی حدی

بهینه سازی حدی بر روی خروجی متغیرهای گروه D,C,B برای هر نماد بصورت اختصاصی اجرا شده و نتایج در سه گروه ارائه می شود. گروه اول در قالب هر نماد بصورت

تکی (جدول ۹ و جدول ۱۰)، گروه دوم در قالب گروه صنعت (جدول ۱۱) و گروه سوم در قالب کل شاخص (جدول ۱۲)، آورده شده است.

نتایج اجرای الگوریتم بهینه سازی حدی تعدیل سطح اطمینان ورود به انجام معامله در هر نماد را بصورت زیر بیان نمود که در اینجا به شرح ردیف ۱ می‌پردازیم، پر واضح است که تحلیل ردیف ۲ تا ۵۱ نیز مشابه ردیف اول خواهد بود.

برای نماد واتی در تاریخ ۱۳۹۹/۱۱/۲۱ سطح اطمینان در انجام معامله خرید موفق ۰/۸۲٪ و سطح اطمینان ورود به معامله فروش ۰/۱۲٪ است که این نسبت‌ها پس از بهینه سازی به ترتیب به ۰/۵۶٪ در خرید و ۰/۸٪ در فروش می‌رسد. این نماد در تاریخ ۱۳۹۹/۱۱/۲۵ سطح اطمینان در انجام معامله خرید موفق ۰/۸۲٪ و سطح اطمینان ورود به معامله فروش ۰/۰۶٪ است که این نسبت‌ها پس از بهینه سازی به ترتیب به ۰/۵۳٪ در خرید و ۰/۰۴٪ در فروش می‌رسد. همان‌طوری که در جدول مشاهده می‌شود هر روز معاملاتی نرخ خاص خود را دارد که وقتی این نسبت‌ها با قیمت، حجم معامله هر نماد در طی ساعات معاملاتی روزانه، در نظر گرفته شود به معامله گر در انجام بهینه معامله کمک شایانی خواهد نمود. این تحلیل برای ردیف‌های ۳ تا ۵۱ نیز صادق است.



نمودار ۱. نماد واتی شرایط خرید و فروش قبل و بعد از بهینه سازی

جدول ۸. نماد واتنی نرخ معامله قبیل و بعد از بهینه سازی

ردیف	نماد	تاریخ	نرخ خرید (پیش از بهینه سازی)	نرخ خرید (پس از بهینه سازی)	نرخ فروش (پیش از بهینه سازی)	نرخ فروش (پس از بهینه سازی)
۱	واتنی	۱۳۹۹/۱۱/۲۱	۰/۸۲	۰/۵۶	۰/۱۲	۰/۰۸
۲	واتنی	۱۳۹۹/۱۱/۲۵	۰/۸۲	۰/۵۳	۰/۰۶	۰/۰۴
۳	واتنی	۱۳۹۹/۱۱/۲۶	۰/۸۲	۰/۵۳	۰/۰۶	۰/۰۴
۴	واتنی	۱۳۹۹/۱۱/۲۶	۰/۶۵	۰/۳۸	۰/۰۶	۰/۰۴
۵	واتنی	۱۳۹۹/۱۱/۲۷	۱	۰/۶۶	۰	۰
⋮	⋮	⋮	⋮	⋮	⋮	⋮
۴۵	واتنی	۱۴۰۰/۰۲/۰۸	۰/۳۵	۰/۲۲	۰/۴۷	۰/۲۹
۴۶	واتنی	۱۴۰۰/۰۲/۱۱	۰/۳۵	۰/۲۲	۰/۴۷	۰/۲۹
۴۷	واتنی	۱۴۰۰/۰۲/۱۲	۰/۴۱	۰/۲۷	۰/۴۱	۰/۲۵
۴۸	واتنی	۱۴۰۰/۰۲/۱۳	۰/۲۹	۰/۱۸	۰/۴۷	۰/۲۷
۴۹	واتنی	۱۴۰۰/۰۲/۱۹	۰/۵۳	۰/۳۶	۰/۲۹	۰/۱۵
۵۰	واتنی	۱۴۰۰/۰۲/۲۰	۰/۴۱	۰/۲۷	۰/۳۵	۰/۱۸
۵۱	واتنی	۱۴۰۰/۰۲/۲۱	۰/۵۳	۰/۳۶	۰/۲۹	۰/۱۵

به عنوان نمونه جدول نمادها (۸) به همراه روزهای معاملاتی و نسبت های آن آورده شده که تحلیل قبلی برای ردیف های ۱ تا ۲۰۹۰۱ نیز صادق خواهد بود.

جدول ۹. نرخ معامله خرید برای کلیه نماد ها قبیل و بعد از بهینه سازی

ردیف	نماد	تاریخ	نرخ خرید قبل از بهینه سازی	نرخ خرید بعد از بهینه سازی
۱	واتنی	۱۳۹۹/۱۱/۲۷	۱/۰۰	۰/۶۶
۲	ویشهر	۱۴۰۰/۰۱/۰۸	۰/۹۴	۰/۶۶
۳	تاصیکو	۱۴۰۰/۰۱/۱۴	۰/۹۴	۰/۶۵
۴	سخوز	۱۴۰۰/۰۱/۱۵	۰/۹۴	۰/۶۵
۵	سفارس	۱۴۰۰/۰۱/۱۷	۰/۹۴	۰/۶۵
۶	قشیر	۱۳۹۹/۱۲/۰۶	۰/۹۴	۰/۶۵
۷	لسرما	۱۳۹۹/۱۲/۰۵	۰/۹۴	۰/۶۵
۸	پارسیان	۱۳۹۹/۱۱/۲۸	۰/۹۴	۰/۶۴
۹	سمازن	۱۳۹۹/۱۲/۱۹	۰/۹۴	۰/۶۴
۱۰	شخارک	۱۳۹۹/۱۲/۰۲	۰/۹۴	۰/۶۴
⋮	⋮	⋮	⋮	⋮
۲۰۸۹۴	دزهرایخ	۱۳۹۹/۱۲/۲۰	۰/۱۲	۰/۰۴
۲۰۸۹۵	وخارزمج	۱۴۰۰/۰۱/۲۹	۰/۱۲	۰/۰۴
۲۰۸۹۶	وخارزمج	۱۴۰۰/۰۱/۳۰	۰/۱۲	۰/۰۴
۲۰۸۹۷	قجامج	۱۳۹۹/۱۲/۲۰	۰/۰۶	۰/۰۳
۲۰۸۹۸	قجامج	۱۴۰۰/۰۱/۲۹	۰/۰۶	۰/۰۳
۲۰۸۹۹	قجامج	۱۴۰۰/۰۱/۳۰	۰/۰۶	۰/۰۳
۲۰۹۰۰	کایتا	۱۴۰۰/۰۱/۲۹	۰/۰۶	۰/۰۳
۲۰۹۰۱	کایتا	۱۴۰۰/۰۱/۳۰	۰/۰۶	۰/۰۳

در جدول ۹ نرخ معامله خرید برای نمادهای بورسی در طی روزهای مختلف آورده شده است. به عنوان نمونه ردیف ۱ از جدول ۹ نرخ خرید برای نماد واتی قبل از بهینه سازی ۱ و بعد از بهینه سازی ۰,۶۶ برای روز ۱۳۹۹/۱۱/۲۴ استخراج شده است که مشابه همین تحلیل برای ردیف های ۲ الی ۲۰۹۰۱ و همچنین برای جدول ۱۰ که شرایط فروش برای قبل و بعد از بهینه سازی آورده شده، نیز صادق خواهد بود.

جدول ۱۰. نرخ معامله فروش برای کلیه نماد ها قبل و بعد از بهینه سازی

ردیف	نماد	تاریخ	نرخ فروش قبل از بهینه سازی	نرخ فروش بعد از بهینه سازی
۱	فنورد	۱۳۹۹/۱۲/۱۲	۰/۷۶	۰/۴۸
۲	شسپا	۱۳۹۹/۱۲/۱۳	۰/۷۶	۰/۴۷
۳	ثفارس	۱۳۹۹/۱۲/۲۰	۰/۷۶	۰/۴۲
۴	شکرین	۱۳۹۹/۱۲/۲۰	۰/۷۶	۰/۴۶
۵	حکشتیج	۱۳۹۹/۱۲/۲۰	۰/۷۶	۰/۵۰
:	:	:	:	:
۲۰۸۹۶	کرماش	۱۳۹۹/۱۲/۱۱	۰/۶۵	۰/۴۵
۲۰۸۹۷	تاصیکو	۱۳۹۹/۱۲/۱۱	۰/۶۵	۰/۴۶
۲۰۸۹۸	ما	۱۳۹۹/۱۲/۱۱	۰/۶۵	۰/۳۶
۲۰۸۹۹	پترول	۱۳۹۹/۱۲/۱۱	۰/۶۵	۰/۴۴
۲۰۹۰۰	های وب	۱۳۹۹/۱۲/۱۱	۰/۶۵	۰/۳۸
۲۰۹۰۱	کروی	۱۳۹۹/۱۲/۱۲	۰/۶۵	۰/۴۵

نتایج اجرای الگوریتم بهینه سازی حدی، تعدیل سطح اطمینان ورود به انجام معامله در گروه صنعت را بصورت زیر بیان کرد که در اینجا به شرح ردیف ۱ از جدول (۱۱) می پردازیم، پر واضح است که تحلیل ردیف ۲ تا ۴۱ نیز مشابه ریف اول خواهد بود. برای گروه استخراج زغال سنگ سطح اطمینان در انجام معامله خرید موفق ۵۱٪ و سطح اطمینان ورود به معامله فروش ۲۴٪ است که این نسبت ها پس از بهینه سازی به ترتیب به ۳۲٪ در خرید و ۱۳٪ در فروش می رسد. این نسبت ها به این مهم اشاره دارد که همه نمادهای گروه استخراج زغال سنگ را نمی توان در تصمیم گیری معاملاتی بصورت یکسانی ارزیابی کرد.

## جدول ۱۱. نرخ معامله خرید و فروش برای صنایع قبل و بعد از بهینه سازی

ردیف	گروه صنعت	نرخ خرید (قبل از بهینه سازی)	نرخ خرید (پس از بهینه سازی)	نرخ فروش (قبل از بهینه سازی)	نرخ فروش (پس از بهینه سازی)
۱	استخراج زغال سنگ	۰/۵۱	۰/۳۲	۰/۲۴	۰/۱۳
۲	استخراج سایر معادن	۰/۵۶	۰/۳۴	۰/۲۶	۰/۱۳
۳	استخراج نفت گاز و خدمات جنبی جز اکتشاف	۰/۵۶	۰/۳۷	۰/۳۷	۰/۲۱
۴	استخراج کانه های فلزی	۰/۵۱	۰/۳۴	۰/۳۹	۰/۲۴
۵	اطلاعات و ارتباطات	۰/۴	۰/۲۳	۰/۵	۰/۲۶
:	:	:	:	:	:
۳۶	محصولات شیمیایی	۰/۵۲	۰/۳۳	۰/۳۶	۰/۲۱
۳۷	محصولات غذایی و آشامیدنی به جز قند و شکر	۰/۵	۰/۲۹	۰/۳۱	۰/۱۶
۳۸	محصولات کاغذی	۰/۵۲	۰/۲۹	۰/۳۱	۰/۱۷
۳۹	مخابرات	۰/۵۲	۰/۳۶	۰/۳۷	۰/۲۳
۴۰	منسوجات	۰/۴۸	۰/۳	۰/۲۵	۰/۱۳
۴۱	مواد و محصولات دارویی	۰/۵۲	۰/۳۳	۰/۳۲	۰/۱۹

در جدول ۱۲ برای روزهای معاملاتی، وضعیت شاخص قبل و بعد از بهینه سازی در جدول (۱۱) نمایش داده می شود. بطوری که در روز ۱۳۹۹/۱۱/۲۱ (ردیف ۱ جدول ۱۲) نرخ خرید و فروش قبل و بعد از بهینه سازی به ترتیب ۰,۳۷, ۰,۳ و ۰,۲ و بدست آمد که این تحلیل برای ردیف های ۲ تا ۴۶ جدول ۱۲ صادق است.

## جدول ۱۲. نرخ معامله خرید و فروش برای شاخص قبل و بعد از بهینه سازی

ردیف	تاریخ	نرخ خرید قبل از بهینه سازی	نرخ خرید بعد از بهینه سازی	نرخ فروش قبل از بهینه سازی	نرخ فروش بعد از بهینه سازی
۱	۱۳۹۹/۱۱/۲۱	۰/۶۱	۰/۳۷	۰/۳	۰/۲
۲	۱۳۹۹/۱۱/۲۵	۰/۶۳	۰/۳۸	۰/۲۸	۰/۱۸
۳	۱۳۹۹/۱۱/۲۶	۰/۶۲	۰/۳۸	۰/۲۷	۰/۱۷
۴	۱۳۹۹/۱۱/۲۷	۰/۶۳	۰/۳۹	۰/۲۶	۰/۱۶
۵	۱۳۹۹/۱۱/۲۸	۰/۶۱	۰/۳۸	۰/۲۶	۰/۱۶
:	:	:	:	:	:
۴۰	۱۴۰۰/۰۲/۰۸	۰/۴۴	۰/۲۷	۰/۳۶	۰/۲
۴۱	۱۴۰۰/۰۲/۱۱	۰/۴۳	۰/۲۶	۰/۳۶	۰/۲
۴۲	۱۴۰۰/۰۲/۱۲	۰/۴	۰/۲۵	۰/۳۶	۰/۲
۴۳	۱۴۰۰/۰۲/۱۳	۰/۴	۰/۲۵	۰/۳۷	۰/۲
۴۴	۱۴۰۰/۰۲/۱۹	۰/۴۲	۰/۲۵	۰/۳۴	۰/۱۸
۴۵	۱۴۰۰/۰۲/۲۰	۰/۴۴	۰/۲۷	۰/۳۵	۰/۲
۴۶	۱۴۰۰/۰۲/۲۱	۰/۴۶	۰/۲۹	۰/۳۵	۰/۲

### نتایج ارزیابی الگوریتم

برازش داده‌های استخراج شده برای تمامی نمادها با الگوی ماتریس درهم‌ریختگی که دقت - بازخوانی - صحت مدل را براساس رابطه‌های جدول ۱۳ مورد سنجش قرار می‌دهد انجام شد و نتایج براساس میانگین کل نمادها (جدول ۱۴)، برای میانگین هر صنعت (جدول ۱۵)، میانگین هر نماد (جدول ۱۶) و برازش روزانه هر نماد (جدول ۱۷) بدست آمد.

جدول ۱۳. مولفه های برازش

ردیف	مولفه	فرمول	
۱	دقت ( Accuracy )	$\frac{TP+TN}{N}$	$\frac{\text{تشیخ های درست}}{\text{کل داده ها}}$
۲	بازخوانی ( Recall )	$\frac{TP}{TP+FN}$	$\frac{\text{تعداد نمونه های تشیخی درست مثبت}}{\text{کل نمونه های واقعا مثبت}}$
۳	صحت ( Precision )	$\frac{TP}{TP+FP}$	$\frac{\text{تعداد نمونه های تشیخی درست مثبت}}{\text{کل نمونه های تشیخی مثبت}}$
۴	همپوشانی ( F1-Score )	$\frac{2}{\frac{1}{\text{Recall}} + \frac{1}{\text{Precision}}}$	$2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$
۵	ارزش مکانی ( CR )	$\sum_{i=1}^n \frac{1}{n} (Buy_i    Sel_i)$	

نتایج براساس میانگین کل نمادها

جدول ۱۴. نتیجه برازش براساس میانگین کل نمادها

AV_CR	AV_Recall	AV_Precision	AV_Accuracy	AV_F1
۰/۶۶	۰/۵۸	۰/۷۸	۰/۹۴	۰/۶۷

براساس یافته‌های جدول ۱۴ دقت مدل ۰,۹۴، بازخوانی مدل ۰,۵۸، صحت مدل ۰,۷۸ و همپوشانی مدل ۰,۶۷ بدست آمد که این نتایج براساس میانگین ارزش مکانی ۰,۶۶ بوده که مربوط به میانگین تمامی نمادهای معاملاتی در بورس اوراق بهادار تهران است.

نتایج برای میانگین هر صنعت بصورت جدول (۱۵) است که براساس این یافته‌ها برای صنایع مختلف متفاوت بود به عنوان مثال برای گروه صنعت محصولات شیمیایی (ردیف ۳۷ از جدول ۱۵) دقت مدل ۰,۸۳، بازخوانی مدل ۰,۵۵، صحت مدل ۰,۷۵ و همپوشانی مدل ۰,۶۲ بدست آمد که این نتایج براساس میانگین ارزش مکانی ۰,۵۷ بود. بنابراین همین تحلیل برای ردیف‌های ۱ الی ۴۱ نیز صدق می‌کند.

جدول (۱۵) نتیجه برآزش برای گروه هر صنعت

ردیف	گروه صنعت	AV_CR	AV_Recall	AV_Precision	AV_Accuracy	AV_F1_Score
۱	استخراج زغال سنگ	۹۲٪	۵۵٪	۷۵٪	۷۶٪	۶۳٪
۲	استخراج سایر معادن	۷۰٪	۵۲٪	۶۷٪	۷۷٪	۵۸٪
۳	استخراج نفت گاز و خدمات جنبی جز اکتشاف	۶۴٪	۵۲٪	۷۵٪	۷۹٪	۶۱٪
۴	استخراج کانه های فلزی	۵۴٪	۵۴٪	۷۶٪	۸۰٪	۶۳٪
۵	اطلاعات و ارتباطات	۴۴٪	۴۸٪	۵۹٪	۸۴٪	۵۲٪
:	:	:	:	:	:	:
۳۶	محصولات چوبی	۷۴٪	۵۷٪	۶۵٪	۷۴٪	۶۰٪
۳۷	محصولات شیمیایی	۵۷٪	۵۴٪	۷۵٪	۸۳٪	۶۲٪
۳۸	محصولات غذایی و آشامیدنی به جز قند و شکر	۶۴٪	۵۵٪	۷۰٪	۸۲٪	۶۱٪
۳۹	محصولات کاغذی	۶۵٪	۵۴٪	۷۱٪	۸۱٪	۶۱٪
۴۰	مخابرات	۵۵٪	۵۴٪	۷۳٪	۷۹٪	۶۱٪
۴۱	مواد و محصولات دارویی	۶۰٪	۵۲٪	۷۱٪	۸۴٪	۵۹٪

نتایج برای میانگین هر نماد بصورت جدول (۱۶) است که براساس این یافته‌ها برای نمادهای مختلف نتایج متفاوت است. به عنوان مثال برای نماد فینتا (ردیف ۱ از جدول ۱۶) دقت مدل ۰,۹۱، بازخوانی مدل ۰,۸۳، صحت مدل ۰,۹۴ و همپوشانی مدل ۰,۸۷ بدست آمد که این نتایج براساس میانگین ارزش مکانی ۰,۵۸ بود. بنابراین همین تحلیل برای ردیف‌های ۱ الی ۳۸۴ نیز صدق می‌کند.

جدول ۱۶. نتیجه برآزش برای میانگین هر نماد

ردیف	نماد	AV_CR	AV_Recall	AV_Precision	AV_Accuracy	AV_F1
۱	فیتنا	۵۸٪	۸۳٪	۹۴٪	۹۱٪	۸۷٪
۲	ویاسار	۶۳٪	۸۲٪	۹۳٪	۹۰٪	۸۷٪
۳	سکارون	۵۰٪	۸۶٪	۸۶٪	۹۸٪	۸۶٪
۴	فخاسج	۵۸٪	۸۶٪	۸۶٪	۹۹٪	۸۶٪
۵	پلوه	۶۰٪	۸۳٪	۸۸٪	۹۳٪	۸۵٪
:	:	:	:	:	:	:
۳۸۰	خاور	۶۳٪	۳۵٪	۵۴٪	۷۲٪	۴۲٪
۳۸۱	خموتور	۵۰٪	۴۱٪	۴۳٪	۷۸٪	۴۲٪
۳۸۲	سصفها	۴۶٪	۳۹٪	۴۵٪	۸۴٪	۴۲٪
۳۸۳	فمراد	۴۸٪	۳۶٪	۴۴٪	۷۵٪	۴۰٪
۳۸۴	کساپا	۵۶٪	۶۰٪	۳۰٪	۹۶٪	۴۰٪

همانطوری که می‌دانیم هدف از معاملات با بسامد بالا، انجام معاملات در کسری از ثانیه در ساعات معاملاتی است پس مهم است که از شرایط و وضعیت نمادها بصورت روزانه اطلاع داشته باشیم بنابراین یکی نتایج حاصل از پژوهش که در جدول ۱۷ آورده شده است می‌تواند نقطه عطف این مطالعه باشد. در جدول یاد شده نتایج برای هر نماد بصورت روزانه نمایش داده شده است. بطور مثال برای نماد فخاس (ردیف ۱ از جدول ۱۷) دقت مدل ۰٫۶۰، بازخوانی مدل ۰٫۶۰، صحت مدل ۰٫۸۶ و همپوشانی مدل ۰٫۹۸ بدست آمد که این نتایج براساس میانگین ارزش مکانی ۰٫۸۶ بود که مختص روز ۱۳۹۹/۱۱/۲۵ است. بنابراین همین تحلیل برای ردیف‌های ۲ الی ۷۲۸۶ نیز صدق می‌کند.

جدول ۱۷. نتیجه برآزش روزانه برای هر نماد

ردیف	نماد	تاریخ	CR	Recall	Precision	Accuracy	F1-Score
۱	فخاس	۱۳۹۹/۱۱/۲۵	۸۶٪	۶۰٪	۸۶٪	۶۰٪	۹۸٪
۲	ویاسار	۱۳۹۹/۱۲/۰۹	۷۸٪	۶۳٪	۷۸٪	۶۳٪	۹۸٪
۳	فخاس	۱۳۹۹/۱۱/۲۵	۷۵٪	۶۰٪	۷۵٪	۶۰٪	۹۸٪
۴	فخاس	۱۳۹۹/۱۱/۲۶	۶۹٪	۶۰٪	۶۹٪	۶۰٪	۹۸٪
۵	یکام	۱۳۹۹/۱۲/۱۰	۶۰٪	۹۷٪	۶۰٪	۹۷٪	۹۸٪
:	:	:	:	:	:	:	:
۷,۲۸۲	پاکشو	۱۴۰۰/۰۲/۰۴	۳۲٪	۱۱٪	۳۲٪	۱۱٪	۱۷٪
۷,۲۸۳	فسپا	۱۳۹۹/۱۱/۲۶	۵۸٪	۶۰٪	۵۸٪	۶۰٪	۱۵٪
۷,۲۸۴	سکرما	۱۴۰۰/۰۲/۰۱	۴۹٪	۵۸٪	۴۹٪	۵۸٪	۱۳٪
۷,۲۸۵	ما	۱۴۰۰/۰۱/۱۵	۴۱٪	۶۲٪	۴۱٪	۶۲٪	۱۳٪
۷,۲۸۶	خراسان	۱۳۹۹/۱۲/۲۵	۵۴٪	۵۶٪	۵۴٪	۵۶٪	۱۲٪

### بحث، نتیجه‌گیری و پیشنهادها

همانطوری که عنوان شد معامله بسامد بالا در نقطه مقابل سرمایه‌گذاری سنتی بلند مدت است که خرید و فروش‌های آنی سهام و سایر اوراق بهادار و همچنین فعالیت‌های آربیتراژی و بازارگردانی از کارهای معمول این روش معاملات است. همچنین بیان شد که در واقع معاملات فرکانس بالا، اجرای هزاران سفارش با سریع‌ترین زمان ممکن است و هدف آن شناسایی سود کم در هر معامله است که بیشتر با اختلاف قیمت سهم یا دارایی یکسان در بازارهای مختلف، این امر میسر می‌شود. بنابراین هدف این تحقیق به دنبال پاسخ به این سوال مهم بود که، مدل معاملات با بسامد بالای سهام در بورس اوراق بهادار تهران چگونه است؟

برای پاسخ به این سوال متغیرهای تاثیرگذار در تحلیل تکنیکال، متغیرهای اقتصادی و اطلاعات معاملات روزانه نمادها در بازار بورس تحت الگوریتم اتوماتای سلولی یادگیرنده و الگوریتم بهینه‌سازی حدی مورد پردازش و الگوسازی قرار گرفتند و برای شاخص، گروه صنعت خاصه برای هر نماد الگوی معاملاتی مخصوص به همان نماد بدست آمد که گویای تاثیر اتفاقات اقتصادی (بدری<sup>۱</sup>، ۱۳۹۵)، سیاسی (ماری و همکاران<sup>۲</sup>، ۲۰۰۶) و نیز نظریه‌های مالی رفتاری (پروساد و همکاران<sup>۳</sup>، ۲۰۱۵) برای انجام معاملات، خاصه هر نماد است.

پیشنهاد می‌شود شرکت‌های سرمایه‌گذاری و سبدگردان‌ها به منظور کاهش ریسک و افزایش بازده پرتفوی خود به دامنه نوسان و نیز ضرایب استخراج شده برای هر نماد و صنعت، توجه لازم را داشته باشند و نیز برای طرح ریزی معاملات الگوریتمی خود از متغیرهای تاثیرگذار در این پژوهش استفاده کنند. همچنین در حوزه ایجاد و توسعه معاملات الگوریتمی خاصه معاملات با تواتر بالا به منظور کسب بازده مطلوب تر، سرمایه‌گذاری کنند. معامله‌گران حقیقی بورس بهتر است به این نکته مهم توجه داشته باشند که بر اساس نتایج حاصله از این پژوهش تاثیرگذاری متغیرهای تحلیل تکنیکال که برای انجام معاملات از آن استفاده می‌کنند افزون بر اینکه برای هر سهمی شرایط خاص خود همان سهم را دارد، این متغیرها برای هر

1. Badri, 2016

2. Marie-Claude Beaulieu, Jean-Claude Cosset, Naceur Essaddam

3. Jaya M. Prosad, Sujata Kapoor and Jhumur Sengupta

اقتصادی معیارهای مخصوص همان اقتصاد را دارد و نمی‌توان برای همه جوامع یک نسخه واحدی بکار برد. با توجه به اینکه انجام معاملات با تواتر بالا کمک شایانی به بهبود روند انجام معاملات در بازار سهام خواهد کرد بنابراین پیشنهاد می‌شود نسبت به ایجاد زیرساخت لازم برای توسعه روش‌های معاملاتی با بسامد بالا اقدامات بایسته را در برنامه‌های توسعه‌ای خود داشته باشد.

در مسیر انجام این پژوهش محدودیت‌های نیز وجود داشته که از جمله محدودیت‌های موجود می‌توان به دسترسی محدود و پرهزینه به داده‌ها و نیز مشکل واکنشی اطلاعات معاملات از سامانه بورس اوراق بهادار تهران به دلیل نامناسب بود زیرساخت مخابراتی و فنی که فرایند پردازش لحظه‌ای داده‌ها را با مشکل روبرو می‌کرد، اشاره کرد. همچنین عدم ارایه اطلاعات صحیح توسط شرکت‌ها و نبود شفافیت اطلاعاتی، از جمله اطلاعات نسبت درآمد به سهم<sup>۱</sup> و قیمت به سود هر سهم<sup>۲</sup> نمادها در سایت بورس اوراق بهادار تهران نیز یکی دیگر از محدودیت‌های این پژوهش بود. افزون بر این موارد از آنجایی که یکی از اساسی‌ترین و مهمترین مساله برای ارائه الگوهایی که برپایه هوش مصنوعی در حجم کل نمادهای بورسی مطرح می‌شود خصوصاً وقتی پای معاملات با بسامد بالا به میان می‌آید موضوع زمان پردازش داده‌ها و نیز مبحث سخت‌افزاری مطرح است که در این پژوهش به واسطه ضعیف بودن قدرت پردازنده و طولانی شدن زمان پردازش، نتیجه‌گیری را با چالش روبرو می‌ساخت.

## ملاحظات اخلاقی

### پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت کرده‌اند و این موضوع مورد تأیید همه آنهاست.

### مشارکت نویسندگان

احمدی.ا: تهیه و آماده‌سازی نمونه‌ها، انجام آزمایش و گردآوری داده‌ها، انجام محاسبات، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج، تهیه پیشنویس مقاله؛

1. EPS

2. P/E

پایتختی اسکویی.ا: طراحی پژوهش، نظارت بر مراحل انجام پژوهش، بررسی و کنترل نتایج، اصلاح، بازبینی و نهایی سازی مقاله؛  
 بادآور نهندی.ی: مشارکت در طراحی پژوهش، نظارت بر پژوهش، مطالعه و بازبینی مقاله.

### تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.



## References

- Angel, J; & McCabe, D. M. (2011). Fairness in Financial Markets: The Case of High Frequency Trading. McCabe. <http://dx.doi.org/10.2139/ssrn.1737887>.
- Anvari-Rostami, A.-A. K. (2006). A comparative study of ranking top companies based on profitability ratios and Tehran Stock Exchange indices. *Accounting and Auditing Reviews*, 25-43, [https://acctgrev.ut.ac.ir/article\\_18489.html](https://acctgrev.ut.ac.ir/article_18489.html) ( In Persian )
- Badri, A. (2016). Investigating the impact of macroeconomic variables on stock market performance. *Financial Management Perspectives*, 9-35, [https://jfmfp.sbu.ac.ir/article\\_94794.html](https://jfmfp.sbu.ac.ir/article_94794.html). ( In Persian ).
- BALDAUF, M; & MOLLNER, J. (2021). High-Frequency Trading and Market Performance. *Finance*, 1495-1526, 75 (3). doi: <https://doi.org/10.1111/jofi.12882>
- Ebrahimpur, A; & Ahmadpur, M. (2017). Investigating the effect of the main financial and economic indicators on profitability (companies admitted to the Tehran Stock Exchange). *Accounting and auditing reviews*, 1-14, [https://acctgrev.ut.ac.ir/article\\_25032.html](https://acctgrev.ut.ac.ir/article_25032.html). ( In Persian )
- Ghorbani, A; Zadehfar, Y; Ali, C; & Seyed, M. (2019). Predicting Stock Trading Signals Using Colored Petri Nets and Genetic Algorithm (Case Study: Tehran Stock Exchange). *Executive Management Research*, 206, doi: [10.22080/jem.2020.17593.3034](https://doi.org/10.22080/jem.2020.17593.3034) ( In Persian )
- GuangWei Shi, Y. C. (2020). High-Frequency Trading and Its Impact on Exogenous Liquidity Risk of China's Stock Index Futures Market before and after Trading Restrictions. *Hindawi Complexity*, <https://doi.org/10.1155/2020/9192841>
- Hagströmer, B; Norden, L. L; & Zhang, D. (2014). How Aggressive are High-Frequency Traders? *Financial Review*, 395-419, 49 (2). <https://doi.org/10.1111/fire.12041>
- HENDERSHOTT, T; JONES, C. M; & MENKVELD, A. J. (2011). Does Algorithmic Trading Improve Liquidity? *Finance*, 66 (1). <https://doi.org/10.1111/j.1540-6261.2010.01624.x>
- Hirabayashi, A; Aranha, C; & Iba, H. (2009). Optimization of the trading rule in foreign exchange using genetic algorithm. Conference: Genetic and Evolutionary Computation Conference. Montreal, Québec, Canada. <https://doi.org/10.1145/1569901.1570106>
- Imen Ben Ammar, S. H. (2022). High-frequency trading, stock volatility, and intraday crashes. *The Quarterly Review of Economics and Finance*, 334-337, 84. <https://doi.org/10.1016/j.qref.2022.03.004>
- Jaya M. Prosad, S. K. (2015). Theory of Behavioral Finance. doi:10.4018/978-1-4666-7484-4.ch001
- Korajczyk, & Murphy. (2018). High Frequency Market Making to Large Institutional Trades. *Economics Market Structure*. doi:10.2139/ssrn.2567016

- Korajczyk, R; & Murphy, D. (2019). High Frequency Market Making to Large Institutional Trades. *Financial Studies*, 1034-1067, 32 (3). <http://dx.doi.org/10.2139/ssrn.2567016>
- Lee, S.-K; & Moon, B. R. (2009). Finding attractive rules in stock markets using a modular genetic programming. Conference: Genetic and Evolutionary Computation Conference. Montreal, Québec, Canada,. doi:10.1145/1569901.1570244
- MacKenzie, D. (2018). Material Signals: A Historical Sociology of High-Frequency Trading. The University of Chicago, 1635-1683, 123, <https://www.sps.ed.ac.uk/sites/default/files/assets/pdf/material-signals.pdf>
- Marie-Claude Beaulieu, Jean-Claude Cosset, Naceur Essaddam. (2006). Political uncertainty and stock market returns. *Canadian Journal of Economic*, 621-641, <http://dx.doi.org/10.2139/ssrn.841344>
- Mattli, W. (2008). Global Algorithmic Capital Markets: High Frequency Trading, Dark Pools, and Regulatory Challenges Global Algorithmic Capital Markets : High Frequency Trading, Dark Pools, and Regulatory Challenges. <https://doi.org/10.1093/oso/9780198829461.003.0009>
- Menkveld, A. J; & Zoican, M. (2017). Need for Speed? Exchange Latency and Liquidity. *Financial Studies*, 1188-1228, <http://dx.doi.org/10.2139/ssrn.2442690>
- Moon; S.-k. L.-R. (2009). Finding attractive rules in stock markets using a modular genetic programming. In GECCO .
- Murphy, J. J. (1999). Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications. New York Institute of Finance. [https://docs.preterhuman.net/John\\_J.\\_Murphy\\_-\\_Technical\\_Analysis\\_of\\_the\\_Financial\\_Market](https://docs.preterhuman.net/John_J._Murphy_-_Technical_Analysis_of_the_Financial_Market).
- Rastegar, M; & Dastpak, M. A. (2015). Presenting a high-repetition trading model in Tehran Stock Exchange. *Scientific Research Quarterly of Investment Knowledge*, 71-88, <https://sanad.iau.ir/Journal/jik/Article/844005> ( In Persian )
- Robert Jarrow, P. P. (2015). The Effect of Trading Futures on Short Sale Constraints. *Mathematical Finance*, 311-388, 25 (2), doi:<http://dx.doi.org/10.1111/mafi.12013>
- Samadi, S; Shirani Fakhr, Z; & Davrzadeh, M. (2007). Investigating the effectiveness of stock price index of Tehran Stock Exchange on global oil and gold prices (modeling and forecasting). *Quarterly Journal of Economic Reviews*, 25-51, <https://ensani.ir/file/download/article/20100913103819-p0348200130251-DA3GA4.pdf> (In Persain ).
- Shahadai, S. M. (2020). Fundamental analysis in Iran's capital market. *Challenge*. <https://chalesh.ir/product/fundamental/>. (In Persian)
- Taghavi, M; & Mohammadzadeh, A. (2002). Capital Market Reaction to Macroeconomic Variables. *Economic Research Journal*, 13-66, 14, [https://joer.atu.ac.ir/article\\_3112.html](https://joer.atu.ac.ir/article_3112.html) (In Persian)

- Weissman, R. L. (2005). *Mechanical Trading Systems: Pairing Trader Psychology with Technical Analysis*. WILEY. <https://www.wiley.com/en-us/Mechanical+Trading+Systems%3A+Pairing+Trader+Psychology+with+Technical+Analysis-p-9780471730972>
- Xiaojie Xu, Y. Z. (2023). A high-frequency trading volume prediction model using neural networks. *Decision Analytics*. <https://doi.org/10.1016/j.dajour.2023.100235>
- Zaharudin, Khairul Zharif, Martin R. Young, and Wei-Huei Hsu. (2021). High-frequency trading: Definition, implications, and controversies. *Journal of Economic Surveys*, 75-107. <https://doi.org/10.1111/joes.12434>.
- Zhou, H; & Kalev, P. S. (2018). Algorithmic and high frequency trading in Asia-Pacific, now and the future. *Pacific-Basin Finance Journal*. [doi:10.1016/j.pacfin.2018.10.006](https://doi.org/10.1016/j.pacfin.2018.10.006)

