Journal of Intelligent Financial Management

ISSN: 3116-0964

Presenting a Model for the Early Prediction of Price Bubble Formation in the Stock Market

Morteza Mazarei [1], Ebrahim Nasiroleslami [2*]

[1] *PhD in Financial Engineering, Kish International Campus, University of Tehran ,Kish, Iran*

[2*] *Assistant Professor, Department of Statistics, Faculty of Science, Bu-Ali Sina University, Hamedan, Iran (Coresponding autour), Email:e.nasiroleslami@basu.ac.ir*

ARTICLE INFO

Article history:
Received:12/07/2025
Received in revised form:16/08/2025
Accepted:23/09/2025
Available online:06/12/2025

Keywords:

Generalized Supremum Augmented Dickey-Fuller Test
Deep Learning
Early Warning System
Logistic Regression
Long Short-Term Memory

ABSTRACT

Objective: The overall aim of this study is to design an early warning system for predicting bubbles in selected Tehran Stock Exchange indices using a deep learning approach. Specific objectives include detecting and identifying bubble periods in the selected Tehran Stock Exchange indices and comparing the accuracy and quality of the predictions.

Method: First, monthly data for the selected Tehran Stock Exchange indices were extracted as the study variables for the period 2002 to 2023 (1381 to 1402 in the Solar Hijri calendar). Bubble periods were then identified using the Generalized Supremum Augmented Dickey-Fuller (GSADF) test, and a bubble dummy variable was created. Next, taking into account the price changes of a set of independent variables as warning indicators, together with lags of the data's price changes, the bubble variable was modeled for prediction. Using a logistic regression model and a Long Short-Term Memory (LSTM) model, an early warning system for bubble prediction was designed in order to prevent, or at least minimize, the risks arising from the collapse of bubbles.

Findings: The proposed early warning system, built with a deep learning approach, was designed with an accuracy of approximately 77 to 79 percent for the Total, Top 50 Most Active Companies, and Industry indices, with better prediction quality than for the other indices.

Results: Regarding model accuracy, the logistic regression model performed better for the Financial index, whereas the LSTM model delivered better results for the Total, Top 50 Most Active Companies, Industry, and Metals indices, with notable improvement for the Total and Industry indices. Furthermore, the confusion matrices indicate that the prediction quality of the logistic regression model for the Financial and Metals indices was considerably better than for the other indices, while the prediction quality of the LSTM model for the Total, Industry, and Top 50 Most Active Companies indices was better than for the others. Therefore, using a deep learning model is not necessarily better for all indices, and a hybrid perspective should be adopted when selecting models for the indices under consideration.

Journal of Intelligent Financial Management, 2025, Vol. 1, No.3, pp. 131- 158

Publish by:
Tolou-e Binish-e Ayandeh Scientific Institute

https://doi.org/10.25843/JIFM.2025.8563.236007

Article Type: Research Paper

©Authors

Cite: Mazarei, M. & Nasiroleslami, E. (2025). Presenting a Model for the Early Prediction of Price Bubble Formation in the Stock Market. Journal of Intelligent Financial Management, 1(3), 131-158.

نگرش های
مدیریت مالی هوشمند
Journal of Intelligent Financial Management
ISSN: 3116-0964

ارائه مدل پیش‌بینی زودهنگام شکل‌گیری حباب‌های قیمتی در بازار سهام

مرتضی مزارعی [۱]، ابراهیم نصیرالاسلامی [۲و*]

۱ – دکتری مهندسی مالی، پردیس بین المللی کیش، دانشگاه تهران، کیش، ایران

۲ و *– استادیار، گروه آمار دانشکده علوم پایه، دانشگاه بوعلی سینا، همدان، ایران (نویسنده مسئول)، ایمیل نویسنده مسئول: *e.nasiroleslami@basu.ac.ir*

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۴/۲۱

تاریخ بازنگری: ۱۴۰۴/۰۵/۲۵

تاریخ پذیرش: ۱۴۰۴/۰۷/۰۱

تاریخ انتشار: ۱۴۰۴/۰۹/۱۵

کلیدواژه‌ها:

آزمون سوپریمم عمومی دیکی فولر تعمیم یافته
یادگیری عمیق
سیستم هشدار سریع
رگرسیون لجستیک
حافظه کوتاه مدت طولانی

چکیده

هدف: هدف کلی پژوهش حاضر، طرّاحی یک سیستم هشدار سریع جهت پیش‌بینی حباب شاخص‌های منتخب بورس تهران با رویکرد یادگیری عمیق می‌باشد. از اهداف جزئی این پژوهش، کشف و شناسایی دوره‌های حبابی در شاخص‌های منتخب بورس تهران و مقایسه دقّت و کیفیت پیش‌بینی‌ها بوده است.

روش: ابتدا داده‌های ماهانه‌ی شاخص‌های منتخب بورس تهران به عنوان متغیّرهای پژوهش، طی دوره زمانی سال‌های ۱۳۸۱ تا ۱۴۰۲ استخراج و سپس به شناسایی دوره‌های حبابی توسط آزمون سوپریمم عمومی دیکی فولر تعمیم‌یافته و ایجاد متغیّر مجازی حباب پرداخته می‌شود؛ در گام بعد، با در نظر گرفتن تغییرات قیمتی مجموعه‌ای از متغیّرهای مستقل به عنوان شاخص‌های هشداردهنده و در نظر گرفتن وقفه‌های تغییرات قیمت داده‌ها، مدل‌سازی پیش‌بینی متغیّر حباب انجام شده و با به کارگیری مدل رگرسیون لجستیک و مدل حافظه کوتاه‌مدت طولانی به طرّاحی سیستم هشدار سریع جهت پیش‌بینی حباب به منظور پیشگیری یا حداقل نمودن ریسک‌های ناشی از فروپاشی حباب‌ها، پرداخته شده است.

یافته‌ها: سیستم هشدار سریع مورد نظر، با رویکرد یادگیری عمیق، با دقّت حدود ۷۷ تا ۷۹ درصد در شاخص-های کل، ۵۰ شرکت فعّال‌تر و صنعت و با کیفیت پیش‌بینی بهتری نسبت به سایر شاخص‌ها، طرّاحی شده است.

نتایج: در رابطه با دقّت مدل‌ها؛ در شاخص مالی، مدل رگرسیون لجستیک عملکرد بهتری داشته است در حالی‌که برای شاخص‌های کل، ۵۰ شرکت فعّال‌تر، صنعت و فلزّات، مدل حافظه کوتاه‌مدت طولانی نتایج بهتری ارائه کرده است و البته برای شاخص‌های کل و صنعت بهبود قابل ملاحظه‌ای را به همراه داشته است.

همچنین از طریق ماتریس‌های درهم‌ریختگی این نتیجه حاصل شده است که کیفیّت پیش‌بینی مدل رگرسیون لجستیک برای شاخص مالی و فلزّات نسبت به سایر شاخص‌ها به مراتب بهتر بوده در حالی‌که کیفیّت پیش‌بینی مدل حافظه کوتاه‌مدت طولانی برای شاخص‌های کل، صنعت و ۵۰ شرکت فعّال‌تر نسبت به سایر شاخص‌ها بهتر بوده است. بنابراین لزوماً استفاده از مدل یادگیری عمیق برای تمامی شاخص‌ها بهتر نبوده و باید نگاهی ترکیبی نسبت به انتخاب مدل‌ها برای شاخص‌های مدنظر داشته باشیم.

نشریه مدیریت مالی هوشمند، ۱۴۰۴، دوره ۱، شماره ۳، صفحه ۱۳۱-۱۵۸.

ناشر: موسسه علمی طلوع بینش آینده

https://doi.org/10.25843/JIFM.2025.8563.236007

نوع مقاله: پژوهشی

© نویسندگان

استناد: مزارعی، مرتضی و نصیرالاسلامی، ابراهیم. (۱۴۰۴). ارائه مدل پیش‌بینی زودهنگام شکل‌گیری حباب‌های قیمتی در بازار سهام. *مدیریت مالی هوشمند*،۱(۳)، ۱۳۱- ۱۵۸.

مقدمه

حباب‌های مالی یکی از پیچیده‌ترین پدیده‌های اقتصادی هستند که می‌توانند تبعات گسترده‌ای برای اقتصاد و جامعه داشته باشند. حباب‌های قیمتی وقتی رخ می‌دهند که قیمت معاملات جاری سهام از ارزش واقعی خود جدا می‌شود، این وضعیت یا از طریق واکنش بازار از بین می‌رود یا تشدید می‌شود، که حباب واقعی از حالت تشدید شونده افزایش قیمت سهام ناشی می‌شود. در حباب قیمتی، افزایش قیمت سهام همچنان ادامه می‌یابد تا به نقطه‌ای بحرانی برسد، در این نقطه آغاز توقف معاملات سهام شروع شده و در عمل گفته می‌شود حباب قیمتی در حال ترکیدن است (عبّاسیان و همکاران، ۱۳۸۹).

حباب‌های قیمت دارایی می‌توانند منجر به سرمایه‌گذاری نامناسبی شوند که کارایی هر اقتصادی را کاهش می‌دهد. یک مشخصه از فروپاشی و سقوط بزرگ در بازار سهام، اثر مالی قابل‌توجّه آن می‌باشد، ترکیدن حباب‌ها می‌تواند منجر به بحران‌های مالی گسترده شود، زیرا بسیاری از مؤسسات مالی ممکن است در معرض ریسک ورشکستگی قرار گیرند. از این رو، فروپاشی‌ها و حباب‌ها برای مدیریت ریسک پورتفوی‌های سرمایه‌گذاری از اهمیّت زیادی برخوردار هستند (کالیوا و کاسکینن[1]، ۲۰۰۷).

بحران‌های مالی و حباب‌های قیمت دارایی ارتباط بسیار نزدیکی با یکدیگر دارند. عموماً بازارهای مالی، بحران‌های مالی را تجربه کرده‌اند که منشأ آن ناشی از رشد و انفجار یک حباب قیمت دارایی بوده است. در زمانی که تعداد زیادی از معامله‌گران تصمیم به فروش دارایی بگیرند، قیمت‌ها به سرعت کاهش خواهد یافت. پس وجود حباب به معنای خطر سقوط قیمت است (گومز-گونزالز و همکاران[2]، ۲۰۱۶).

دولت‌ها و نهادهای نظارتی باید با استفاده از ابزارهای تحلیل و پیش‌بینی، وضعیت حباب‌های مالی را رصد کرده و در صورت لزوم اقدامات پیشگیرانه انجام دهند. شناسایی سریع حباب‌ها به نهادهای نظارتی فرصت می‌دهد تا با اتخاذ تدابیر مناسب، از تشدید بحران و آسیب بیشتر به اقتصاد جلوگیری کنند. بنابراین از اقدامات پیشگیرانه و مقابله با حباب‌ها می‌توان به نظارت دقیق بر بازارها با تقویت نظارت بر بازارهای مالی و شناسایی سریع نشانه‌های شکل‌گیری حباب‌ها اشاره کرد.

سیستم‌های هشدار سریع[3] در ابتدا از مسیر موضوع بحران‌های مالی به ادبیات مالی ورود کرده‌اند، لذا یک تنیدگی اولیه‌ای بین موضوع بحران‌های مالی و سیستم‌های هشدار سریع وجود دارد. با این وجود، این سیستم‌ها می‌توانند در هر منطقه‌ای که رویدادهای معمول، نشانه‌های منفی دارند به کار برده شوند و به سیستم‌های فن‌آوری، سیاست‌ها و رویه‌هایی اشاره دارد که با هدف اصلی پیش‌بینی رویداد منفی در محیط‌های مختلف استفاده می‌شود (کلوپوتان و همکاران[4]، ۲۰۱۸). سیستم‌های هشدار سریع می‌توانند مداخلات سیاستی مناسبی را پیشنهاد کنند که می‌تواند از بحران‌های شدید جلوگیری کند یا حداقل اثرات نامطلوب آن‌ها را به حداقل برساند (عبدالسلام و عبدالطیف[5]، ۲۰۲۰).

بعضی از پژوهش‌های اخیر در زمینه شناسایی حباب‌های مالی، شامل روش‌هایی هستند که می‌توانند به عنوان سیستم‌های هشدار دهندهٔ حباب‌های آتی به کار روند. این روش‌ها به دنبال کمک به فعّالان بازار جهت جلوگیری از ریسک‌های فروپاشی حباب‌ها هستند. بدیهی است که طرّاحی سیستم‌های هشدار سریع به اندازهٔ توسعهٔ ساز و کارهای قابل اتّکای شناسایی حباب، چالش‌برانگیز است. همان‌طور که فیلیپس و همکاران[6] (۲۰۱۵) اشاره می‌کنند، سیستم‌های هشدار باید درجه و میزان بالایی از شناسایی صحیح داشته باشند که از اجرای سیاست‌گذاری سریع و مؤثر آن اطمینان حاصل کرد. در عین حال، برای جلوگیری از اقدامات غیرضروری سیاست‌گذاری، باید درجه و میزان پایینی از شناسایی نادرست داشته باشند (فیلیپس و همکاران، ۲۰۱۵).

پژوهش‌گران مالی از روش‌های متعدّدی در حوزه‌ی یادگیری ماشینی نظیر محاسبات تکاملی[7] و شبکه‌ی عصبی مصنوعی برای بررسی داده‌های سری زمانی استفاده کرده‌اند. در یادگیری ماشینی از طریق به کارگیری یک سری از الگوریتم‌های خاص سعی می‌شود الگوهای پنهان بین داده‌ها کشف شود؛ در صورتی که تعداد متغیّرهای مستقل و وابسته زیاد باشد و بین آن‌ها ارتباط خطی برقرار نباشد، این روش در زمره‌ی بهترین گزینه‌ها برای پیش‌بینی است. الگوریتم‌های یادگیری عمیق توانسته‌اند در مدل-

---

[1] Kaliva & Koskinen
[2] Gomez-Gonzalez et al.
[3] Early Warning Systems (EWS)
[4] Klopotan et al.
[5] Abdelsalam and Abdel-Latif
[6] Phillips et al.
[7] Evolutionary Computations (ECs)

های یادگیری ماشین، با توانمندسازی الگوریتم‌ها، سرعت و دقّت بالاتری ایجاد کنند. توسعه سریع آن، مطالعات زیادی را در حل مسائل اقتصادی، به ویژه برای پیش‌بینی بازار دارایی‌ها، به سمت خود جلب کرده است (خلیلی عراقی و همکاران، ۱۴۰۰).

روش‌های یادگیری ماشین، به طور فزاینده‌ای، به عنوان راه حلّی امیدوارکننده، توجّه محقّقان را برای مطالعه و پژوهش طیف گسترده‌ای از مسائل مربوط به پیش‌بینی همچون پیش‌بینی بحران‌های مالی (اویانگ و لای[1]، ۲۰۲۱؛ بوتل و همکاران[2]، ۲۰۱۹؛)، پیش‌بینی‌های عدم پرداخت بدهی (فاستر و همکاران[3]، ۲۰۲۲؛ تران و همکاران[4]، ۲۰۲۳؛) یا پیش‌بینی قیمت‌های سهام (کاکیسی و همکاران[5]، ۲۰۲۳؛ دنگ و همکاران[6]، ۲۰۲۲؛ گو و همکاران[7]، ۲۰۲۰؛ ژو و همکاران[8]، ۲۰۲۳) جلب کرده است. بر اساس این مطالعات، الگوریتم‌های یادگیری ماشین نتایج بهتری نسبت به مدل‌های آماری کلاسیک در مسائل طبقه‌بندی و رگرسیون سری زمانی از خود نشان داده‌اند. با این حال، توجه به این نکته مهم است که نتایج پیش‌بینی می‌تواند به طور قابل توجّهی در بین مدل‌ها با توجّه به مجموعه داده‌های مورد استفاده متفاوت باشد و هیچ رویکرد یکسانی وجود ندارد که بتواند عملکرد برتر را تضمین کند (Tran et al, 2023).

با بررسی پژوهش‌ها می‌توان بیان کرد که در موضوع حباب، پژوهش‌ها عمدتاً متمرکز بر آزمون‌های شناسایی حباب و بررسی وجود آن‌ها، طی بازه‌های زمانی مختلف، بوده و پژوهش‌های اندکی در رابطه با پیش‌بینی حباب‌های مالی صورت گرفته است. در موضوع سیستم هشدار سریع، اکثر پژوهش‌های داخلی و خارجی، در زمینه‌ی بحران‌های مالی و اقتصادی (مالی، بانکی، ارزی و پولی) و بررسی شاخص‌های هشداردهنده بوده و در سایر زمینه‌های پیش‌بینی همچون حباب‌های مالی، مطالعات بسیار محدودی صورت گرفته است.

در موضوع روش‌های پیش‌بینی حباب و سیستم‌های هشدار سریع، استفاده از یادگیری ماشین، عمیق و سایر روش‌های ترکیبی، یک رویکرد نسبتاً جدید است و توجّه تحقیقاتی محدودی را به خود جلب کرده است. بنابراین با توجه به شکاف پژوهشی ذکر شده، ضرورت وجود یک مدل، سیستم یا برنامه‌ای که با شناسایی و پیش‌بینی سریع و به‌هنگامِ حباب‌های مالی به عنوان یک ریسک بالقوّه، بتواند هشدار مناسبی در این خصوص به سرمایه‌گذاران، سیاست‌گذاران، نهادهای نظارتی و اجرایی بدهد، اهمیّت می‌یابد.

از این رو پژوهش حاضر بر آن است تا دوره‌های حبابی شاخص‌های منتخب بورس تهران را شناسایی و مورد ارزیابی قرار داده و با لحاظ تغییرات قیمتی (بازدهی لگاریتمی) مجموعه‌ای از متغیّرهای مستقل به عنوان شاخص‌های هشداردهنده، به طرّاحی سیستمی جهت پیش‌بینی حباب در آینده با رویکرد یادگیری عمیق دست یافته و آن را مورد آزمون قرار دهد. اهداف جزئی این پژوهش، شناسایی وجود حباب و طول افق وقوع حباب بازار سهام، مقایسه دقّت روش حافظه‌ی کوتاه‌مدت طولانی (یادگیری عمیق) به کار گرفته شده در سیستم هشدار سریع با روش لجستیک رگرسیون (یادگیری ماشین) و مقایسه کیفیّت پیش‌بینی حباب شاخص‌های منتخب می‌باشد.

---

[1] Ouyang and Lai
[2] Beutel et al.
[3] Fuster et al.
[4] Tran et al.
[5] Cakici et al.
[6] Dong et al.
[7] Gu et al.
[8] Zhou et al.

مبانی نظری

پیشینهٔ نظری در این مقاله، به دو قسمت تقسیم می‌شود. قسمت نخست، حباب و آزمون‌های شناسایی حباب را و قسمت دوم، سیستم‌های هشدار سریع را مورد بررسی قرار داده است.

حباب

پژوهش‌های مربوط به حباب‌های قیمتی را می‌توان به چهار گروه تاریخی[۱]، تجربی[۲]، آزمایشی[۳] و نظری[۴] دسته‌بندی کرد. مک-کوین و ثورلی[۵] (۱۹۹۴) بیان داشتند که در بازار دارایی مالی، چهار نوع حباب قیمتی شامل حباب‌های عقلایی[۶]، حباب‌های ذاتی، حباب‌های رفتاری[۷] و حباب‌های اطّلاعاتی می‌تواند به وجود آید. از سوی دیگر، بسیاری از محقّقان از جمله شربینا و شلوشه[۸] (۲۰۱۴) با بررسی ادبیات گذشته تلاش کرده‌اند تا مروری ساختاریافته با رویکرد استاندارد از مدل‌های نظری حباب ارائه دهند و به دو گروه کلی حباب‌های عقلایی و حباب‌های رفتاری دسته‌بندی نمایند. از این منظر، حباب‌های عقلایی را می‌توان به انواع تقارن اطّلاعاتی، عدم تقارن اطّلاعاتی، حباب ذاتی و عامل بنیان دسته‌بندی کرد. حباب‌های عقلایی به دنبال توضیح و بیان رفتار انفجاری قیمت دارایی‌های مالی با فرض رفتار عقلایی تمام سرمایه‌گذاران و بر اساس انتظارات خود از درآمدهای آتی و کارا بودن بازارها می‌باشند. از سوی دیگر، مدل‌های مبتنی بر اختلاف‌نظر[۹]، معاملات بازخوردی[۱۰]، سوگیری خوداسنادی[۱۱] و سوگیری نمایندگی و محافظه‌کاری[۱۲]، نمونه‌ای از مدل‌هایی هستند که بر سوگیری‌های روانشناسانه جهت توضیح حباب‌ها تکیه دارند (Wockl, 2019).

حباب عقلایی کلاسیک در ادبیات نظری با مقالات ساموئلسون[۱۳] (۱۹۵۸)، دیاموند[۱۴] (۱۹۶۵)، بلانچارد و واتسون[۱۵] (۱۹۸۲)، تیرول[۱۶] (۱۹۸۲، ۱۹۸۵) و فروت و آبسفلد[۱۷] (۱۹۹۱) پیوند دیرینه‌ای دارد. پیرو مطالعات برانرمیر[۱۸] (۲۰۰۸)، مدل‌های حباب عقلایی را بر اساس این‌که سرمایه‌گذاران دارای اطّلاعات متقارن یا نامتقارن هستند، متمایز می‌کنیم. محقّقان پیشگام در زمینهٔ حباب عقلایی با تقارن اطّلاعاتی شامل بلانچارد (۱۹۷۹)، بلانچارد و واتسون (۱۹۸۲)، فلاد و گاربر[۱۹] (۱۹۸۰) و تیرول (۱۹۸۵) می-شود. (باربریس و همکاران[۲۰]، ۲۰۱۸).

هدف ادبیات تجربی حباب، توسعهٔ ساز و کارهایی برای شناسایی منشأ، پایان و میزان رفتار انفجاری در قیمت دارایی‌ها بر اساس معیارهای کمّی واضح و روشن می‌باشد. ادبیات مربوط به آزمون‌های شناسایی تجربی حباب‌های مالی به دو گروه کلّی روش-های شناسایی اقتصادسنجی اولیّه و روش‌های اقتصادسنجی پیشرفته تقسیم می‌گردند. پژوهش‌های اولیّه در مورد شناسایی تجربی حباب‌های عقلایی به دههٔ ۱۹۸۰ و اوایل دههٔ ۱۹۹۰ برمی‌گردد. فرومل و کروس[۲۱] (۲۰۱۲) سه نوع مدل را در گروه

---

[1] Historical
[2] Empirical
[3] Experimental
[4] Theoretical
[5] Mcqueen and Thorley
[6] Rational Bubbles
[7] Fads Bubbles
[8] Scherbina and Schlusche
[9] Disagreement-Based Bubble Models
[10] Feedback Trading
[11] Biased Self-Attribution
[12] Representative Heuristic and Conservatism Bias
[13] Samuelson
[14] Diamond
[15] Blanchard and Watson
[16] Tirole
[17] Froot and Obstfeld
[18] Brunnermeier
[19] Flood and Garber
[20] Barberis et al
[21] Frommel and Kruse

روش‌های اقتصادسنجی اولیّه قرار می‌دهند که شامل آزمون‌های کران واریانس شیلر[۱]، آزمون‌های دو مرحله‌ای وست[۲] (۱۹۸۷) و آزمون‌های مانایی استاندارد و هم‌انباشتگی[۳] می‌باشد.

مروری بر آزمون‌های اقتصادسنجی اولیّه نشان می‌دهد که این روش‌های شناسایی کشف حباب، نتایج نامطلوبی ارائه می‌دهند. رویکردهای مختلف، هنگامی که برای مجموعهٔ داده‌های مشابه اعمال می‌شوند، نه تنها به نتیجه‌گیری‌های متفاوتی منجر می‌شوند، بلکه بسیاری از آن‌ها دارای ضعف‌هایی همچون توان پایین و اعوجاج اندازه می‌باشند (Wockl, 2019).

روش‌های اقتصادسنجی پیشرفته در اوایل سال‌های ۲۰۰۰ میلادی، تمایل به شناسایی حباب‌های عقلایی، تا حدودی به دلیل ضعف‌های روش‌های آزمون‌های اولیه و نتایج غیرقطعی که ارائه می‌دادند، کاهش یافت. با این حال، بحران مالی جهانی ۲۰۰۷–۲۰۰۸، علاقهٔ اقتصاددانان تجربی را به حباب قیمت دارایی‌ها و پیامدهای بالقوّهٔ جهانی آن دوباره احیا و در عین حال فضایی غنی برای تحقیقات تجربی بیشتر فراهم کرد (فیلیپس و یو[۴]، ۲۰۱۱). تحقیقات اخیر عمدتاً بر روی روش‌های مانایی پیشرفته و مبتنی بر هم‌انباشتگی جهت تشخیص مراحل رونق و سرخوشی در بازارهای مالی متمرکز شده است. این آزمون‌ها مبتنی بر متغیّرهای بنیادی نیستند و بر سری زمانی قیمت دارایی‌ها تمرکز دارند. یکی از روش‌های مانایی پیشرفته و مبتنی بر هم‌انباشتگی که کاربرد روش‌های شناسایی حباب در سری‌های زمانی با حباب‌های در حال فروپاشی دوره‌ای را تا حد زیادی ارتقا داده است، آزمون ریشه واحد بازگشتی است که توسط فیلیپس و همکاران (۲۰۱۵) پیشنهاد شده است.

یکی از پیشرفت‌های اخیر در شناسایی حباب‌ها، توسعهٔ آزمون‌های ریشهٔ واحد بازگشتی[۵] است که توسط فیلیپس و همکاران (۲۰۱۱) برای اولین بار ایجاد و سپس اصلاح و بهبود پیدا کرد. در این آزمون‌ها، حباب‌ها با یافتن زیرنمونه‌هایی که رفتار انفجاری مشخصی دارند، شناسایی می‌شوند. با توجه به ماهیّت بازگشتی آن‌ها، این آزمون‌ها قادرند حباب‌های در حال فروپاشی دوره‌ای را از فرآیندهای ریشهٔ واحد کامل تشخیص دهند و به آن‌ها مزیّت مشخصی نسبت به آزمون‌های مانایی استاندارد و مبتنی بر هم‌انباشتگی می‌دهد. هنگامی که یک حباب در سری زمانی وجود دارد، داده‌ها ممکن است با رفتار انفجاری خفیف[۶] مشخص شوند. این رفتار انفجاری خفیف را می‌توان با یک فرآیند خودهمبسته[۷] با ریشه‌ای فراتر، اما همچنان نزدیک به ریشهٔ واحد، مدل‌سازی کرد (بوهل و همکاران[۸]، ۲۰۱۳). این آزمون‌ها به دو گروه تقسیم می‌شوند:

الف) آزمون سوپریمم دیکی فولر تعمیم‌یافته[۹]: فیلیپس و همکاران (۲۰۱۱)، این آزمون را که به عنوان روش فیلیپس، وو و یو[۱۰] نیز شناخته و مبتنی بر آزمون‌های دیکی فولر بازگشتی راست دم[۱۱] هستند را به منظور برطرف کردن انتقاد اوانس و سایر ایرادهای وارد به روش‌های پیشین کشف و ارزیابی وجود حباب‌های قیمتی در بازارهای مالی مخصوصاً آزمون‌های متعارف ریشه واحد دیکی فولر و هم انباشتگی پیشنهاد دادند. آن‌ها سرخوشی مالی[۱۲] را بر حسب رفتار خودهمبسته انفجاری تعریف کرده و شواهد تجربی سرخوشی قیمت را با کمک آزمون‌های رگرسیون بازگشتی پیشرو[۱۳] مورد ارزیابی قرار دادند. هوم و بریتانگ[۱۴] (۲۰۱۲)، این آزمون را برای تشخیص حباب‌های بازار سهام به کار بردند و پس از یک فرآیند شبیه‌سازی مونت کارلو و مقایسه معیارهای ارزیابی، دریافتند که این آزمون‌ها بهینه‌ترین روش در بین روش‌های به کار رفته است. آن‌ها نشان دادند که این روش به عنوان ساز و کار شناسایی شکست‌های ساختاری[۱۵] عملکرد رضایت‌بخشی دارد.

این روش دارای این مزیت است که ضمن آزمون فرضیه رفتار انفجاری در قیمت، به طور معناداری قدرت تفکیک و تمایز حباب‌ها را افزایش می‌دهد و قابلیت برآورد تاریخ آغاز و نیز تاریخ پایان حباب را فراهم می‌کند. این روش امکان تشخیص

---

[1] Variance Bounds Tests
[2] West (1987) Two-Step Tests
[3] Standard Stationary and Cointegration-Based Tests
[4] Phillips and Yu
[5] Recursive Unit Root Tests
[6] Mildly Explosive Behavior
[7] Autoregressive Process
[8] Bohl et al.
[9] Sup Augmented Dickey-Fuller (SADF)
[10] Philips/Wu/Yu (PWY) Method
[11] Recursive right-tailed ADF Tests
[12] Financial Exuberance
[13] Forward Recursive Regression Tests
[14] Homm and Breitung
[15] Structural Break

افزایش در قیمت دارایی‌ها را در دوره‌های تورّمی دارد. با این حال، همان‌طور که فیلیپس و همکاران (۲۰۱۵) نشان دادند، این آزمون دارای یک محدودیّت مهم است و آن این‌که برای تجزیه و تحلیل یک دوره حبابی منفرد مناسب و مؤثّر است، در حالی‌که در کاربردهای عملی و بسیاری از سری‌های زمانی، ممکن است حباب‌های متعدّدی در نمونه‌های به اندازه کافی بزرگ ظاهر شوند. این روش، حباب‌های تاریخی معروف را با موفقیّت شناسایی کرد، در حالی‌که نتوانست حباب بحران بدهی ۲۰۰۷–۲۰۰۸ را شناسایی کند.

ب) آزمون سوپریمم عمومی دیکی فولر تعمیم‌یافته[1]: فیلیپس و همکاران (۲۰۱۵)، این آزمون را که به عنوان روش فیلیپس، شی و یو[2] (۲۰۱۵) نیز شناخته می‌شود، برای داده‌های سهام اس‌اندپی۵۰۰ (۲۰۱۰–۱۸۷۱؛ داده‌های ماهانه) به کار برده و با تعمیم روش‌شناسی، به منظور غلبه بر محدودیت‌های آزمون قبل، برای شناسایی حباب‌های چندگانه پیشنهاد دادند. آن‌ها توانستند با موفقیّت، دوره‌های حبابی تاریخیِ به‌نام و شناخته شده را شناسایی کردند.

در فرآیند جدید از عرض پنجره‌های انعطاف‌پذیر در رگرسیون‌های بازگشتی[3] استفاده می‌شود. این تغییر به طور قابل توجّهی قدرت تمایز و تشخیص را در زمانی که حباب‌های چندگانه در داده‌ها رخ می‌دهد، بهبود می‌بخشد، بنابراین بر ضعف روش فیلیپس/وو/یو غلبه کرده و برای دوره‌های حباب‌های چندگانه، سرخوشی و فروپاشی، بسیار مناسب‌تر است و باعث می‌شود در بررسی سری‌های زمانی طولانی تاریخی کاربرد بیش‌تری داشته باشد.

این محقّقان، با استفاده از شبیه‌سازی، عملکرد روش خود را با عملکرد روش فیلیپس/وو/یو و همچنین آزمون مجموع تجمعی خطاهای بازگشتی[4] پیشنهادی توسط هوم و بریتانگ (۲۰۱۲) مقایسه کردند. آن‌ها نشان دادند که در زمان حباب‌های چندگانه در داده‌ها، روش فیلیپس/شی/یو به طور قابل توجّهی از هر دو روش بهتر عمل می‌کند و بر ضعف‌های کاربردهای قبلی آزمون ریشه واحد برای حباب‌های اقتصادی غلبه می‌کند. ویژگی اصلی این آزمون این است که امکان لحاظ پویایی‌های غیرخطی و شکست ساختاری را همزمان با بررسی حباب‌های چندگانه در سری زمانی فراهم می‌کند.

سیستم هشدار سریع

سیستم هشداردهنده در جهان اولین بار بعد از بحران ارزی کشورهای اروپایی در سال ۱۹۹۲–۱۹۹۳، بحران کشورهای آمریکای لاتین ۱۹۹۴–۱۹۹۵ و به طور جدّی‌تر بعد از بحران کشورهای شرق آسیا در سال ۱۹۹۷–۱۹۹۸ مطرح شد. در این برهه از زمان، نیاز به مدلی که بتواند بحران را قبل از وقوع آن تشخیص دهد و بتواند سیاست‌گذاران را از وقوع آن آگاه سازد، بیش از پیش ضروری به نظر می‌رسید. از این رو، موضوعی به نام سیستم‌های هشدار سریع، وارد ادبیات بحران‌های مالی شد. سیستم‌های هشدار سریع، می‌توانند بحران را قبل از وقوع شناسایی کرده و سیگنال مناسب را برای جلوگیری از وقوع یا کاستن اثرات آن صادر کنند (صیّادنیا، ۱۳۸۹).

سیستم‌های هشدار سریع مالی برای شناسایی بی‌ثباتی اقتصادی احتمالی و کاهش احتمال فجایع مالی ضروری هستند. بحران مالی ۲۰۰۸ نیاز به شناسایی سریع مشکلات مالی و اهمیّت اجرای اقدامات پیشگیرانه برای کاهش آثار آن را برجسته کرد. هدف از سیستم‌های هشدار سریع آن است که علائم هشداردهنده اولیه مشکلات مالی را ارائه دهند تا سیاست‌گذاران و بازیگران بازار قبل از گسترش بحران، اقدامات لازم را انجام دهند. ادبیات مربوط به سیستم‌های هشدار سریع در حوزه مالی طی چند دهه گذشته به طور چشمگیری تغییر کرده است زیرا محقّقان روش‌ها و رویکردهای مختلفی را برای ایجاد مدل‌های سیستم هشدار سریع که دقیق‌تر و کارآمدتر هستند، بررسی کرده‌اند (کلاسنس و کاس[5]، ۲۰۱۳).

تحقیقات اولیّه در زمینه سیستم‌های هشدار سریع در حوزه مالی عمدتاً به ایجاد مدل‌های اقتصادسنجی جهت پیش‌بینی بحران‌های مالی مربوط می‌شد. سیستم‌های هشدار سریع با توجه به توان و ظرفیت خود در ارائه‌ی هشدارهای اولیه مرتبط با تهدیدات بالقوّه در صنایع مختلف، اخیراً توجه زیادی را به خود جلب کرده‌اند. مدیریت ریسک اعتباری، تجزیه و تحلیل بازار سهام و سقوط‌های قریب‌الوقوع بازار، انتقال ریسک مالی، نظارت بانکی، مدیریت ریسک بازار، بیمه، نظارت و کشف تقلب و کلاه‌برداری-

---

[1] The Generalized Sup Augmented Dickey-Fuller (GSADF)
[2] Philips/Shi/Yu (PSY) Method
[3] Recursive Regressions
[4] Cumulative Sum Control Chart (CUSUM)
[5] Claessens and Kose

ها، نظارت بر رفتار بیمه‌گذاران، ارزیابی ریسک سبد وام و شناسایی نکول‌های احتمالی و شناسایی ریسک‌های بالقوّه، تعدادی از حوزه‌های صنعت مالی هستند که سیستم هشدار سریع در آن‌ها به کار رفته است. محقّقان اخیراً به دلیل پیشرفت در روش‌های جمع‌آوری و تجزیه و تحلیل داده‌ها، توانسته‌اند مدل‌های پیچیده‌تری از سیستم‌های هشدار سریع ایجاد کنند که تجزیه و تحلیل مبتنی بر شبکه، الگوریتم‌های یادگیری ماشین و تجزیه و تحلیل داده‌های بزرگ را ترکیب می‌کنند (وور و همکاران[1]، ۲۰۲۲).

تصریح مدل‌های سیستم هشدار سریع و ارزیابی آن‌ها به منظور اجرای درست طرّاحی این سیستم‌ها باید به دقت مورد بررسی قرار گیرد. به زبان اقتصادسنجی، تصریح سیستم هشدار سریع، تابعی را تعریف می‌کند که شاخص‌های پیشروی مختلفی را به وقوع اهداف مورد نظر پیوند می‌دهد، در حالی که ارزیابی سیستم‌های هشدار سریع شامل روش‌هایی است که به ارزیابی اعتبار مدل‌های هشدار سریع منتهی می‌شود. با این شرایط، تصریح تکنیکی یک مدل سیستم هشدار سریع نیازمند سه عنصر است:

الف- شناسایی و تعیین هدف و سپس بررسی دلایل آن

ب- انتخاب مجموعه‌ای از شاخص‌های هشداردهنده سیستم هشدار سریع با مراجعه به علائم پررنگ در گام اول به عنوان متغیّرهای توضیحی مدل که در ادبیات مربوطه راه‌هایی از قبیل استفاده از تئوری اقتصادی، مالی و یا رویکرد داده‌کاوی در این خصوص مطرح می‌باشد.

ج- یک ارتبط تابعی بین این شاخص‌های هشداردهنده و احتمالات وقوع هدف، این که چگونه می‌توان از روی حرکت شاخص‌های هشداردهنده، وقوع هدف را پیش‌بینی کرد و چگونه حرکتی در این متغیّرها می‌تواند هدف را به دنبال داشته باشد، نیازمند به کارگیری یک متدلوژی است که بخش مهمی از سامانه‌ی هشدار سریع را تشکیل می‌دهد.

شاخص‌های هشداردهنده سیستم[2] متغیّرهایی هستند که تغییرات در آن‌ها می‌تواند هشداری بر وقوع هدف در آینده باشد. این شاخص‌ها شامل طیف وسیعی از متغیّرهای اقتصادی و مالی می‌باشند که در مطالعات مختلف در سال‌های اخیر به کار گرفته شده‌اند و وضعیت اقتصاد را در بخش‌های حقیقی، پولی و بخش خارجی نشان داده است و بر پایه‌ی این برداشت استوارند که قبل از وقوع هر هدف در اقتصاد، برخی از این متغیّرها شروع به حرکت‌هایی نامعمول می‌کنند که از روی حرکت این متغیّرها با احتمال مشخصی می‌توان وقوع هدف را پیش‌بینی کرد (صیادنیا، ۱۳۸۹).

بنابراین تصریح یک مدل هشدار سریع نیازمند تعریف یک تابع است که شاخص‌های هشداردهنده را به وقوع هدف مرتبط می‌کند. روش‌های معمول پیش‌بینی در سیستم هشدار سریع در ادبیات مربوطه، شامل روش سیگنالی (یا روش استخراج علائم بحران از شاخص‌های پیشرو)، رویکرد لاجیت و پروبیت، روش مارکوف سوئیچینگ و شبکه‌های عصبی مصنوعی (یادگیری ماشین و عمیق) می‌باشند (یاوری و همکاران، ۱۳۹۶).

نمکی و همکاران[3] (۲۰۲۳) در بررسی جامع پایگاه‌های اطّلاعاتی دانشگاهی در زمینه سیستم‌های هشدار اولیه ضمن بیان اهمیّت فزاینده‌ی سیستم‌های هشدار سریع در ادبیات و پژوهش‌های مالی نشان داده‌اند که پژوهش‌های اخیر به سمت روش‌ها و الگوریتم‌های یادگیری ماشین تغییر کرده است و سیستم‌های هشدار سریع دائماً در حال تکامل هستند. زمینه‌ی تحقیقاتی این سیستم‌ها در این بررسی عبارتند از بحران‌های بانکی، بحران‌های ارزی، پیش‌بینی ورشکستگی و مضیقه مالی و پیش‌بینی‌ها با روش‌های یادگیری ماشین.

---

[1] Wever et al.
[2] Early Warning System Indicators
[3] Namaki et al.

پیشینهٔ پژوهش

در ادامه، به مهم‌ترین پژوهش‌های داخلی و خارجی در زمینهٔ پیش‌بینی حباب، متغیّرهای اثرگذار بر شاخص بورس تهران و حباب به منظور بهره‌گیری در انتخاب شاخص‌های هشداردهنده و سیستم‌های هشدار سریع پرداخته می‌شود.

- هنیگ و همکاران[1] (۲۰۲۳) در یک مقاله‌ی کابردی از سوی صندوق بین‌المللی پول با عنوان "پیش‌بینی بحران‌های مالی: نقش قیمت دارایی‌ها" به بررسی ویژگی‌های یک سیستم هشدار سریع با استفاده از یک نماگر ترکیبی[2] به نام "ریسک قیمت‌گذاری نادرست[3]" که از سیگنال‌های رشد قیمتی دارایی‌ها و نماگرهای تلاطم[4] طرّاحی شده است، به منظور نشان دادن پتانسیل ریسک قیمت‌گذاری نادرست در بازار دارایی‌ها پرداخته‌اند. آن‌ها نشان داده‌اند که ترکیب رشد سریع قیمت دارایی‌ها و تلاطم پایین قیمت دارایی‌ها، یک پیش‌بینی‌کننده‌ی عالی برای بحران‌های آتی می‌باشد. نتایج این محقّقان سازگار با این نظر است که اقدامات مبتنی بر قیمت دارایی‌ها می‌تواند اطّلاعات بسیار مهم و حیاتی در مورد سطوح ریسک سیستمی به سیاست‌گذاران ارائه دهد. معیار کلی این نماگر ترکیبی حاصل شش نماگر از چهار بازار دارایی (سهام، اوراق قرضه، ارز و مسکن) می‌باشد.
- پارک و ریو[5] (۲۰۲۱)، در مقاله‌ای با عنوان "سیستم هشدار سریع مبتنی بر یادگیری ماشین برای بازار مسکن و بازار سهام" با تمرکز بر حباب‌های بازار مسکن، رابطه بین بازار مسکن و سهام را تحلیل می‌کنند. با توجه به تأثیر مهمی که پویایی‌های بازار سهام بر حرکتهای قیمتی مسکن دارد، اگر اطلاعات بازار مسکن به عنوان یک سیگنال ارائه شود، حرکتهای قیمتی مسکن می‌تواند نوسانات بازار سهام را پیش‌بینی نماید. لذا آن‌ها یک سیستم هشدار سریع برای بازار مسکن با استفاده از روش حافظه‌ی کوتاه‌مدت طولانی طرّاحی می‌کنند. آن‌ها تأیید کردند این رویکرد بهتر از سایر مدل‌های معیار، جنگل تصادفی و ماشین‌بردار پشتیبان، عمل می‌کند.
- فولبران و همکاران[6] (۲۰۱۹) در پژوهشی با عنوان "طرّاحی یک سیستم هشدار سریع جهت پیش‌بینی حباب‌های سفته‌بازی قیمتی مسکن در بازارهای مسکن اروپای غربی" به شناسایی حباب‌های بازار مسکن طی سال‌های ۲۰۱۱ تا ۲۰۱۸ و طرّاحی یک سیستم هشداردهنده به منظور پیش‌بینی حباب‌های سفته‌بازی شناسایی شده با رویکرد روش لاجیت و پروبیت پرداختند. نتایج نشان داد که هیچ یک از رویکردها دقّت لازم برای پیش‌بینی حباب‌ها در بازار مسکن ندارند.
- ویرتانن و همکاران[7] (۲۰۱۷) در مقاله کاربردی خود که از سوی هیئت ریسک سیستمی اروپا[8] منتشر شد، اشاره به کاربرد روش‌های ریشه واحد در شناسایی حباب‌های مالی در قیمت دارایی‌ها در مطالعات داشته است. نتایج آن‌ها نشان داد که یک سیستم هشدار سریع مبتنی بر روش‌های ریشه واحد، امکان ارزشمندی در نظارت بر ثبات مالی فراهم می‌کند.
- سلمانی و همکاران (۱۴۰۱) در پژوهشی با عنوان "پیش‌بینی بحران‌های بانکی: سیستم هشدار زودهنگام پویا" به پیش‌بینی احتمال وقوع بحران بانکی در چارچوب سیستم هشدار سریع پرداخت. بر اساس نتایج تحقیق، شاخص پیشرو شامل متغیّرهای نسبت نقدینگی گسترده، نسبت اعتبار داخلی به GDP و شاخص قیمت سهام به عنوان هشداردهنده‌های سریع شناسایی شدند.
- پورزندی و همکاران (۱۴۰۱) در پژوهشی با عنوان "طرّاحی سیستم هشداردهنده حباب قیمتی و بحران مالی در بازار سهام ایران" به استخراج و شناسایی متغیّر بحران مالی و حباب قیمتی در بازار سرمایه پرداختند. نتایج این مطالعه بیانگر این موضوع بود که متغیّرهایی همچون تولید، نرخ تورّم، نرخ ارز، شاخص کل بازار سهام و ... تأثیر معنی‌داری بر بروز بحران مالی و احتمال رخداد حباب قیمتی در بازارهای مالی دارد.

---

[1] Hennig et al.
[2] Composite Indicator
[3] Mispricing Risk
[4] Volatility Indicators
[5] Park and Ryu
[6] Fullbrunn et al.
[7] Virtanen et al.
[8] European Systemic Risk Board (ESRB)

- مقیره و عبده[1] (۲۰۲۲)، به بررسی سنتیمنت خبرهای اقتصادی در پیش‌بینی حباب فلزات گرانبها (طلا، نقره، پالادیوم و پلاتینیوم) با استفاده از آزمون GSADF و مدل پروبیت پرداخت. او بر نقش سنتیمنت را به عنوان یک اندیکاتور پیش‌بینی حباب‌های آتی فلزات گرانبها تأکید کرد.
- نبوی چاشمی (۱۴۰۰) در مقاله‌ای با عنوان آزمون وجود حباب سهام با استفاده از تکنیک‌های سوپریمم راست دنباله و توابع عکس‌العملی و تجزیه واریانس با استفاده از داده‌های ماهانه چهار شاخص نسبت قیمت به سود هر سهم، شاخص کل قیمت بازار، نرخ ارز و نرخ تورم، ضمن تأیید رفتار انفجاری و وجود حباب‌های چندگانه در بازار سرمایه، نشان می‌دهد که به دنبال وارد کردن یک شوک به نرخ تورم و نرخ ارز، شاخص سهام دارای حباب می‌شود.
- آسیم و همکاران (۱۳۹۹) با استفاده از مدل حالت–فضا روش مارکوف سوئیچینگ به بررسی روند تشکیل حباب و ریزش آن و ایجاد الگویی برای تبیین عوامل مؤثر بر رفتار سرمایه‌گذاران قبل و بعد از حباب قیمت سهام در بورس تهران پرداخته و نشان داده که متغیّرهای کوتاه مدت و خرد مانند نوسانات بازده، اندازه شرکت و بازده سهام بر رفتار سرمایه‌گذاران اثرگذارند. همچنین شاهد افزایش تعداد معاملات و ارزش معاملات در زمان تشکیل حباب قیمت هستیم.
- ترابی و همکاران (۱۳۹۹) در مقاله‌ای به ارائه مدلی جهت برآورد احتمال ایجاد حباب قیمتی و بررسی عوامل مؤثر در بازار سرمایه پرداخته و بیان کردند که به جز متغیّرهای اندازه و شفافیت اطّلاعات که اثر معنی‌داری را بر حباب قیمتی نشان نداده‌اند، سایر متغیّرها همچون ترکیب سهامداران، نسبت قیمت به سود و سرعت نقدشوندگی دارای اثری معنی‌دار بر حباب قیمتی هستند.
- فلاح شمس و همکاران (۱۳۹۹) در مقاله‌ای با عنوان پیش‌بینی ترکیدن حباب قیمتی سهام در بورس تهران، بیان می‌کنند که در بین عوامل ایجادکننده حباب قیمتی مورد بررسی به ترتیب شوک‌های سیاسی، بازدهی در بازارهای موازی نظیر نفت ارز و طلا تأثیر داشته‌اند.
- رهنمای رودپشتی و همکاران (۱۳۹۹) در مقاله‌ای با عنوان بررسی تأثیر سرریز نوسانات در بازارهای مالی و ویژگی-های بازاری در پیش بینی ترکیدن حباب قیمت در بورس نشان داده است که سرریز نوسانات از بازارهای مالی موازی همچون نفت، نرخ ارز و طلا در قیمت سهام و ایجاد حباب های قیمتی و ایجاد نوسان در بورس نقش مهم‌تری بازی می‌کند.
- مهرآرا (۱۳۹۸) در مقاله‌ای به بررسی سرایت حباب در بازارهای ارز و اوراق بهادار تهران پرداخته و نتایج نشان می-دهد ضمن حبابی بودن هر دو بازار در تاریخ‌های مشخصی، بضاعت انتقال حباب از بازار ارز به بورس به مراتب قوی-تر از انتقال این حباب از بازار سهام به ارز بوده است.
- عبّاسیان و همکاران (۱۳۹۴) در مقاله‌ای با عنوان بی قاعدگی حباب قیمتی در بورس اوراق بهادار تهران: رویکرد محدودیت در آربیتراژ بیان کردند تورم تاثیر معناداری بر تغییرات قیمت سهام دارد. همچنین نسبت قیمت به سود هر سهم به طور مثبت با تغییرات قیمت سهام در دوره گذشته تغییر می‌کند که تأکیدی است بر این‌که افزایش سریع قیمت سهام با فروپاشی‌های بازار مرتبط می‌شود.
- عبّاسیان و همکاران (۱۳۸۷) در مطالعه‌ای به بررسی رابطه بین متغیّرهایی همچون نرخ ارز، تراز تجاری، تورم، نقدینگی و نرخ بهره با شاخص قیمت بورس تهران پرداختند. نتایج مطالعه آن‌ها نشان می‌دهد که یک رابطه تعادلی بلندمدت بین شاخص کل بورس و متغیّرهای کلان اقتصادی وجود دارد. در این پژوهش، رابطه بین شاخص قیمت بورس و متغیّرهای نرخ ارز و تراز تجاری به طور مستقیم و با متغیّرهای دیگری همچون حجم نقدینگی، نرخ بهره و نرخ تورم معکوس است.

[1] Maghyereh and Abdoh

روش‌شناسی پژوهش

این پژوهش در قالب پژوهش کاربردی می‌باشد. متغیّرهای هدف انتخاب شده در این پژوهش با بررسی‌های تطبیقی انجام شده، ۵ شاخص منتخب بورس تهران تعیین شده است که از جدول ۱ قابل ملاحظه می‌باشند. در ادامه، از داده‌های ۲۲ متغیّر مهم و اثرگذار بر بازار سهام، مطابق جدول ۲، که از میان اطّلاعات صورت‌های مالی، اطلاعات بازار، قیمت کالاها و متغیّرهای کلان اقتصادی استخراج شده‌اند، به عنوان متغیّرهای مستقل و شاخص‌های هشداردهنده استفاده شده است.

این داده‌ها از سایت‌های شرکت بورس تهران، پردازش اطّلاعات مبنا "رهاورد"، بانک مرکزی و بانک جهانی استخراج شده‌اند. متغیّرهای مجازی دوره‌های حبابی که در پی آزمون سوپریمم عمومی دیکی فولر تعمیم‌یافته راست دنباله به دست می‌آیند، به عنوان متغیّرهای وابسته در نظر می‌گیریم.

کلیه متغیّرهای مورد استفاده در این پژوهش در مقیاس کمّی و مشاهدات به صورت سری زمانی ماهانه از تاریخ ۲۹-۰۷-۱۳۸۱ الی ۲۹-۰۹-۱۴۰۲ به تعداد ۲۵۵ ماه می‌باشد که از تاریخ ۲۸-۱۲-۱۳۸۱ الی ۲۹-۰۶-۱۳۹۶ به عنوان داده‌های آموزشی جهت مدل‌سازی حباب قیمتی و از تاریخ ۳۰-۰۷-۱۳۹۶ الی ۲۹-۰۹-۱۴۰۲ به عنوان داده‌های آزمایشی جهت آزمون و ارزیابی مدل در نظر گرفته شده است. کلیه محاسبات مورد نیاز این پژوهش با استفاده از نرم افزارهای متن باز R 4.2.1 و پایتون انجام شده است.

جدول ۱. متغیّرهای وابسته و نماد آن‌ها در طول گزارش

متغیّر	نماد	توضیحات
شاخص کل	TEPIX	شاخص کل بورس اوراق بهادار تهران
شاخص ۵۰ شرکت فعّال‌تر	Index50	شاخص ۵۰ شرکت فعال‌تر
شاخص صنعت	Industry_Index	شاخص صنعت
شاخص مالی	Financial_Index	شاخص مالی
شاخص فلزات اساسی	Metal_Index	شاخص فلزات

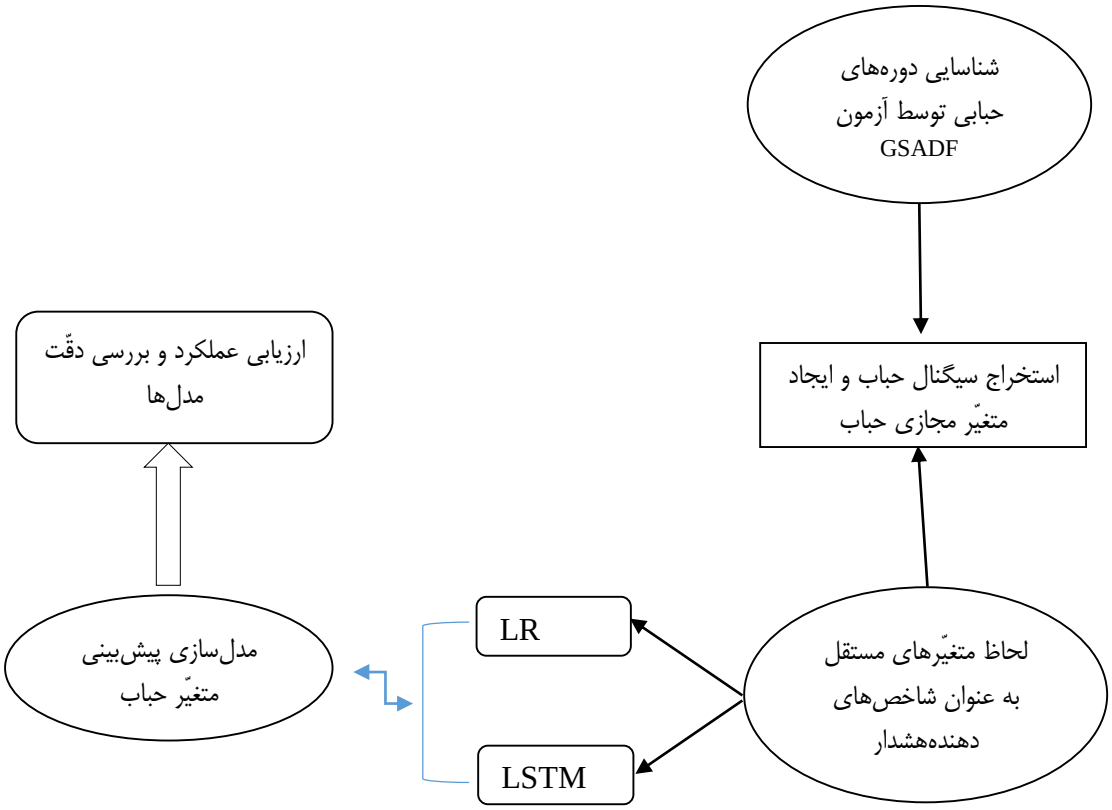
منبع: یافته‌های پژوهش

جدول ۲. شاخص‌های هشداردهنده "متغیّرهای مستقل"

طبقه‌بندی	متغیّرهای مستقل	منبع داده ها
اقتصاد کلان	شاخص قیمت مصرف کننده	بانک مرکزی ایران
اقتصاد کلان	شاخص قیمت تولید کننده	بانک مرکزی ایران
اقتصاد کلان	میانگین نرخ بهره بدون ریسک	Bourseview.com
اقتصاد کلان	نرخ ارز دلار	پردازش اطّلاعات مبنا "رهاورد"
اطلاعات بازار	ارزش معاملات	Bourseview.com
اطلاعات بازار	حجم معاملات	Bourseview.com
اطلاعات بازار	تعداد معاملات	Bourseview.com
صورت‌های مالی	نسبت قیمت به سود هر سهم P/E ttm	Bourseview.com
صورت‌های مالی	نسبت قیمت به فروش هر سهم P/S ttm	Bourseview.com
قیمت کالاها	نفت خام وست تگزاس	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	سنگ آهن عیار ۶۲ درصد چین	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	شکر خام	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	شمش آلومینیوم	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	مس	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	روی	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	انس طلا	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	انس نقره	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	گرم طلا ۱۸ عیار	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	سکه طلا جدید	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	سکه طلا قدیم	پردازش اطّلاعات مبنا "رهاورد"
قیمت کالاها	شاخص جهانی کامودیتی	بانک جهانی
قیمت کالاها	شاخص بالتیک	پردازش اطّلاعات مبنا "رهاورد"

منبع: یافته‌های پژوهش

در ادامه، شکل ۱، چارچوب مفهومی پژوهش نشان داده شده است.



شکل ۱. مدل مفهومی پژوهش

منبع: یافته‌های پژوهش

آزمون سوپریمم عمومی دیکی فولر تعمیم‌یافته

در ادبیات اقتصادسنجی شناسایی دوره‌های حبابی در داده‌های سری زمانی چالش بزرگی است. تکنیک های اقتصادسنجی اغلب دچار تورش ناشی از نمونه‌های محدود[1] هستند. برای مثال آزمون‌های هم انباشتگی و ریشه‌ی واحد سنّتی توانایی شناسایی تنها یک حباب انفجاری را می‌توانند داشته باشند امّا توانایی شناسایی چندین دوره حبابی را نخواهند داشت. زیرا آزمون‌های ریشه واحد سنّتی نمی‌توانند تغییرات داده ها از فرآیند $I(0)$ به $I(1)$ و دوباره بازگشت به فرآیندی $I(0)$ را تشخیص داده و پیگیری کنند. پدیده‌ای که در سری‌های زمانی قیمت به ویژه در بازارهای مالی ممکن است (بیابانی خامنه و همکاران، ۱۳۹۵).

در مسیر توسعه‌ی روش‌های اقتصادسنجی برای تشخیص بهینه رفتار داده‌ها و آزمون وجود حباب قیمتی مطالعات بسیاری صورت گرفته است. یکی از نوآوری‌های اخیر در آزمون‌های ریشه واحد توسط فیلیپس و همکاران (۲۰۱۵) از طریق بسط آزمون سوپریمم عمومی دیکی فولر تعمیم یافته راست‌دنباله ارائه شد. در این روش فرض صفر آزمون این است که سری زمانی قیمت P_t از یک فرآیند گام تصادفی پیروی می کند:

[1] Finite samples

رابطه ۱)

$$P_t = dT^{-\eta} + \theta P_{t-1} + \varepsilon_t$$

که در آن $\theta = 1$ ، d جمله ثابت، T اندازه نمونه و ε_t جملات خطایی هستند که توزیع یکتا و مستقل دارند. تحت فرض مقابل که $\theta > 1$ است، حباب‌های قیمتی در سری زمانی تحت بررسی وجود دارد. در گام بعدی با r_1 و r_2 نقاط شروع و پایان نمونه را نشان داده و مدل رگرسیون بازگشتی[1] ذیل را در نظر می‌گیریم:

رابطه ۲)

$$\Delta P_t = \alpha_{r_1.r_2} + \beta_{r_1.r_2} P_{t-1} + \sum_{i=1}^{k} \gamma_{r_1.r_2} \Delta P_{t-1} + \varepsilon_t$$

$$\varepsilon_t \sim i.i.d.\left(0.\sigma^2_{r_1.r_2}\right)$$

که در آن Δ عملگر تفاضل مرتبه اول و k طول وقفه است. آنگاه آماره دیکی فولر استاندارد به صورت ذیل قابل محاسبه می‌شود:

رابطه ۳)

$$ADF_{r_1.r_2} = \beta_{r_1.r_2} / se\left(\beta_{r_1.r_2}\right)$$

بر اساس این رویکرد، فرآیند شناسایی حباب‌ها به گام تقسیم می‌شود. در گام اول با محاسبه‌ی آماره‌ی آزمون GSADF حباب‌های قیمتی شناسایی می‌شوند، در گام دوم سپس با استفاده از آماره BSADF[2] دوره‌های شروع و پایان حباب‌های قیمتی شناسایی شده تاریخ‌گذاری می‌شوند.
ابتدا، آماره GSADF پس از تغییر نقاط آغازین رگرسیون یعنی r_1 از صفر تا $r_2 - r_1$ و تغییر نقطه پایانی یعنی r_2 از r_0 تا ۱ و تخمین رگرسیون برای تمام حالت‌های ممکن انجام می‌گیرد. به عبارتی دیگر آماره GSADF به صورت ذیل می‌شود:

رابطه ۴)

$$GSADF(r_0) = sup^{r_2 \in [r_0.1]}_{r_1 \in [0.r_2 - r_1]} \{ADF_{r_1.r_2}\}$$

وجود حباب در دنباله نمونه به وسیله مقایسه آماره GSADF و مقادیر بحرانی که از یک شبیه‌سازی مونت کارلو محاسبه شده، قابل استنباط است. گام دوم نیز، یعنی محاسبه دنباله آماره BSADF با به‌کارگیری آزمون ADF راست دنباله بر دنباله بسط یابنده بازگشتی نمونه و مقایسه دنباله آماره BSADF با مقادیر بحرانی محاسبه شده به روش مونت کارلو قابل انجام است. یک پنجره حداقلی برای تخمین مدل با اندازه $r_{w_0} = r_2 - r_1 + 1$ تعریف می‌شود. با شروع از اولین مشاهده نموده تا مشاهده‌ی $r_2 - r_{w_0} + 1$ و نشان دادن $BSADF_{r_2}$ به عنوان مقدار سوپریمم آماره‌های ADF بدست آمده رگرسیون بازگشتی قبلی نسبت به $r_1 \in \left[1.r_2 - r_{w_0} + 1\right]$ و نقطه پایانی ثابت r_2 ، داریم:

رابطه ۵)

$$BSADF_{r_2} = sup_{r_1 \in [1.r_2 - r_{w_0} + 1]} \{ADF_{r_1.r_2}\}$$

با اجازه دادن اینکه نقطه پایانی از r_{w_0} تا آخرین مشاهده نمونه تغییر کند، دنباله‌ای از آماره‌های BSADF را به دست می‌آوریم. در این چارچوب، تاریخ‌های شروع و پایان حباب به صورت ذیل می‌شود:

[1] Recursive
[2] Backward sup ADF

رابطه ۶)

$$\widehat{r_{1e}} = inf_{r_2 \in [r_{w_0}.T]}\left\{r_2 : BSADF_{r_2} > cv_{r_2}^{\beta}\right\}$$
$$\widehat{r_{1f}} = inf_{r_2 \in [\widehat{r_{1e}}+h.T]}\left\{r_2 : BSADF_{r_2} < cv_{r_2}^{\beta}\right\}$$

که در آن $cv_{r_2}^{\beta}$ مقدار بحرانی در سطح اطمینان β درصد آماره BSADF است. سپس بر اساس آزمون BSADF، یک متغیّر yt تعریف می‌کنیم:

رابطه ۷)

$$y_t = \begin{cases} 0. & BSADF_{r_2.t} < cv_{r_2.t}^{\beta} \\ 1. & BSADF_{r_2.t} > cv_{r_2.t}^{\beta} \end{cases}$$

بر این اساس متغیّر y در دوره t مقدار ۱ می‌گیرد اگر در زمان t حباب شناسایی شود و در غیر این‌صورت y برابر صفر است. بنابراین متغیّر y نشان دهنده دوره‌هایی خواهد بود که در شاخص‌های منتخب بورس اوراق بهادار تهران حباب قیمتی وجود داشته است.

رگرسیون لجستیک

یکی از پرکاربردترین مدل‌ها در حل مسائل یادگیری ماشین از نوع طبقه بندی دو کلاسه، مدل رگرسیون لجستیک می‌باشد که در آن متغیّر هدف تابعی خطّی از ورودی‌ها در نظر گرفته می‌شود.

رابطه ۸)

$$y(X) = w^T X + \varepsilon = \sum_{j=1}^{D} w_j x_j + \varepsilon$$

که در آن $w^T X$ ضرب ماتریسی بین بردار وزن‌ها و ماتریس طرح X می‌باشد و ε نیز خطای باقی مانده میان پیش‌بینی‌کننده خطی و مقادیر پاسخ صحیح است، که y دو مقدار ۰ و یا ۱ می تواند اختیار کند.
جهت تشریح ارتباط مدل رگرسیون خطی با توزیع خطاها می‌توانیم مدل را به صورت زیر بازنویسی کنیم:

رابطه ۹)

$$P(y|X.\theta) = N\left(y|\mu(X).\sigma^2(X)\right)$$

عبارت فوق نشان دهنده این موضوع است که مدل رگرسیون لجستیک از یک تابع چگالی شرطی پیروی می‌کند. در ساده‌ترین حالت $\mu(X)$ را یک تابع خطی از X در نظر می‌گیریم بنابراین $\mu = w^T X$ و واریانس خطاها نیز ثابت در نظر گرفته می‌شود $\sigma^2(X) = \sigma^2$ در این حالت فضای پارامتر برابر است با $\theta = (w.\sigma^2)$.
هدف یادگیری یا برآورد ضرایب $w.\sigma^2$ می باشد. برای مثال در نظر بگیرید تنها یک متغیّر ورودی در اختیار داریم. در این حالت:

رابطه۱۰)

$$\mu(X) = w_0 + w_1 x = w^T X$$

در یادگیری ماشین بر خلاف رویکرد آمار کلاسیک به دنبال استنباط بر روی ضرایب برآوردی نیستیم و به منظور برآورد پارامترها نیز از مکانیزمی تحت عنوان یادگیری استفاده می‌کنیم. مکانیزم یادگیری یک عملیات تکرار شونده است که طی آن با استفاده از یک الگوریتم بهینه ساز و تابع زیان، سعی در کمینه‌سازی تابع زیان داریم. ضرایب برآوردی حاصل از این مکانیزم اصطلاحاً اوزان

یا ضرایب یادگرفته شده نامیده می‌شود. این در حالیست که در آمار کلاسیک معمولاً این ضرایب توسط روش‌هایی نظیر حداقل مربعات یا حداکثر درست نمایی برآورد شده و استنباط بر روی آنان صورت می‌گیرد.
مکانیزم یادگیری بدین صورت است که ابتدا یک تابع زیان تعریف می‌شود و سپس توسط یک الگوریتم بهینه‌ساز اقدام به کمینه‌سازی این تابع می‌کنیم. برای مثال در مسئله رگرسیون لجستیک می‌توانیم تابع زیان منفی لگاریتم تابع درست‌نمایی توزیع برنولی را در نظر بگیریم که تابعی محدّب می‌باشد.

سپس از الگوریتم گرادیان کاهشی استفاده کنیم جهت کمینه‌سازی این تابع به صورت زیر:

رابطه ۱۱)

$$J(w) = -l(w) = -\left(\sum_{i=1}^{n} y_i \log\big(g_w(x)\big) + (1-y_i)\log\big(1-g_w(x)\big)\right)$$

شبکه‌های حافظه کوتاه مدت طولانی

شبکه‌های حافظه کوتاه‌مدت طولانی، نسخه‌ای جدیدتر از شبکه‌های عصبی برگشتی هستند که در زمینه یادگیری عمیق استفاده می‌شود. این رویکرد نه تنها مانند رویکردهای کلاسیک شبکه عصبی (بازخوردی) نقاط داده–واحد را پردازش کند بلکه می‌تواند توالی داده‌ها را نیز پردازش کند. این رویکرد پردازش داده‌های توالی با طول‌های دلخواه را از طریق یک بردار مخفی امکان‌پذیر می‌کند و همچنین یادگیری وابستگی بین داده‌های راه دور به وسیله معرّفی یک سلول حافظه، بهبود می‌بخشد.
این شبکه‌ها توسط مکانیزم‌های کنترلی تحت عنوان دروازه سبب حل مشکل محو گرادیان و بهبود کارایی شبکه می‌شوند. بنابراین این شبکه‌های علاوه بر درک روابط غیرخطی داده ها اطلاعات گذشته را نیز در حافظه خود دارد. عبارت حافظه کوتاه-مدت طولانی از این جهت است که در این شبکه‌ها، حافظه کوتاه‌مدت می‌باشد ولی بر روی دنباله یا سری‌های طولانی می‌تواند آموزش ببیند. این در حالی است که در شبکه‌های برگشتی ساده اگر دنباله طولانی باشد، مشکل محو گرادیان و فراموشی حافظه سیستم را خواهیم داشت. نخستین بار این ساختار جدید از شبکه‌های برگشتی را هوکرایتر و همکاران[1] ارائه کردند. اولین تفاوت در شبکه های LSTM نسبت به شبکه های RNN ساده اضافه شدن یک بردار حافظه دیگر است که با C_t آن را نشان می-دهند. یعنی علاوه بر h_t یک عامل حافظه دیگر مانند C_t نیز وجود دارد. همان‌طورکه در فوق ذکر شد تفاوت عمده شبکه‌های LSTM با شبکه های RNN ساده به کارگیری مکانیزمی تحت عنوان دروازه برای کنترل حافظه اطلاعات است. سه دروازه اصلی برای این‌کار وجود دارد: دروازه ورودی، دروازه فراموشی و دروازه خروجی. شکل ۲، یک سلول LSTM را بطور شماتیک نشان می‌دهد (لندی و همکاران[2]، ۲۰۲۱).

رابطه ۱۲)

$$f_t = \sigma\big(W_f.[h_{t-1}.x_t] + b_f\big)$$

$$i_t = \sigma(W_i.[h_{t-1}.x_t] + b_i)$$

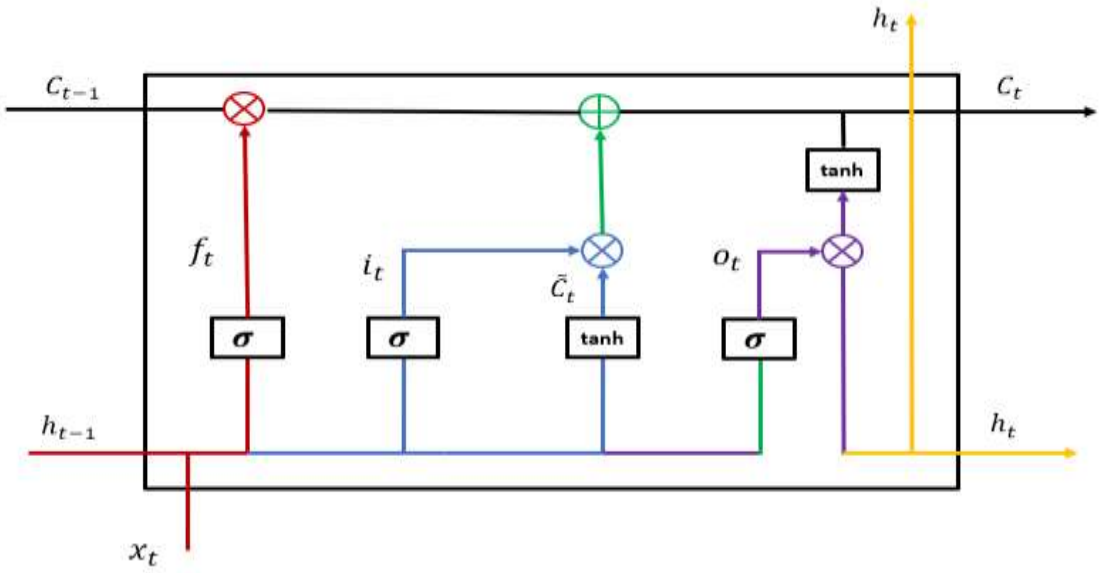
$$\tilde{C}_t = tanh(W_c.[h_{t-1}.x_t] + b_c)$$

$$C_t = f_t \odot C_{t-1} \oplus i_t \odot \tilde{C}_t$$

$$o_t = \sigma(W_o.[h_{t-1}.x_t] + b_o)$$

$$h_t = o_t \odot tanh(C_t)$$

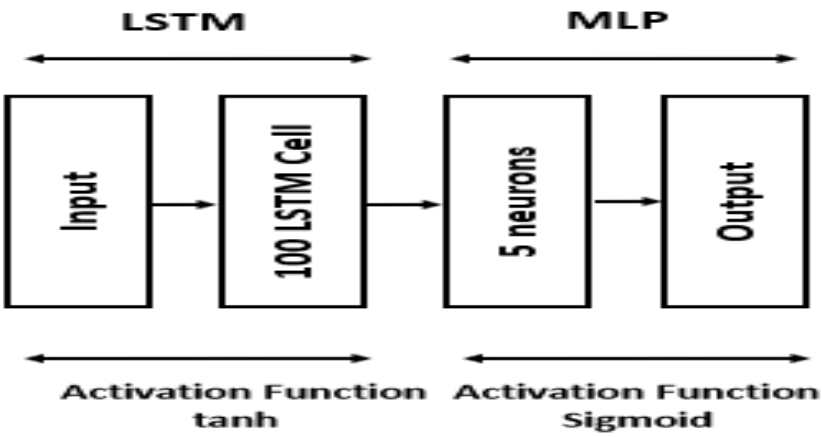
[1] Hochreiter et al.
[2] Landi et al.



شکل ۲. طرحی از ساختار یک سلول حافظه کوتاه‌مدت طولانی (LSTM)

منبع: ابوالمکارم و همکاران[1] (۲۰۲۴)

از آنجایی که مدل شبکه عصبی عمیق می‌تواند همزمان چند ورودی و چند خروجی را دریافت و پردازش کند معماری شبکه به صورت شکل ۳ می‌باشد:



شکل ۳. معماری شبکه عصبی عمیق ترکیبی متشکل از یک لایه LSTM و پرسپترون چندلایه

منبع: پوردرویش (۱۴۰۱)

[1] Abolmakarem et al.

یافته‌های پژوهش

بررسی آماره‌های توصیفی

همان‌طور که در جدول ۳ آمده است، آمار توصیفی مربوط به تغییرات قیمتی شاخص‌ها را در اختیار داریم. با بررسی معیارهای تمرکز (میانگین و میانه) درمی‌یابیم متوسّط بازدهی شاخص فلزات اساسی نسبت به بازدهی سایر شاخص‌ها اندکی بیشتر است. از سوی دیگر با نگاهی به مقادیر کمینه و بیشینه ملاحظه می‌گردد، بیشترین و کمترین بازدهی تغییرات قیمتی مشاهده شده نیز مربوط به شاخص فلزات اساسی است که به تبع آن بیشترین دامنه تغییرات و همچنین بیشترین مقدار انحراف معیار را نیز به خود اختصاص داده است. از این‌رو می‌توان نتیجه گرفت شاخص فلزات اساسی بیشترین ریسک را در بین سایر شاخص‌ها دارد. این درحالی است که شاخص کل بورس اوراق بهادار از وضعیت پایدارتری نسبت به سایرین برخوردار است. مقادیر بدست آمده چولگی برای تمامی بازدهی شاخص‌ها در بازه (۲- و۲) قرار دارد پس می‌توان توزیع آن‌ها را نسبتاً متقارن در نظر گرفت.

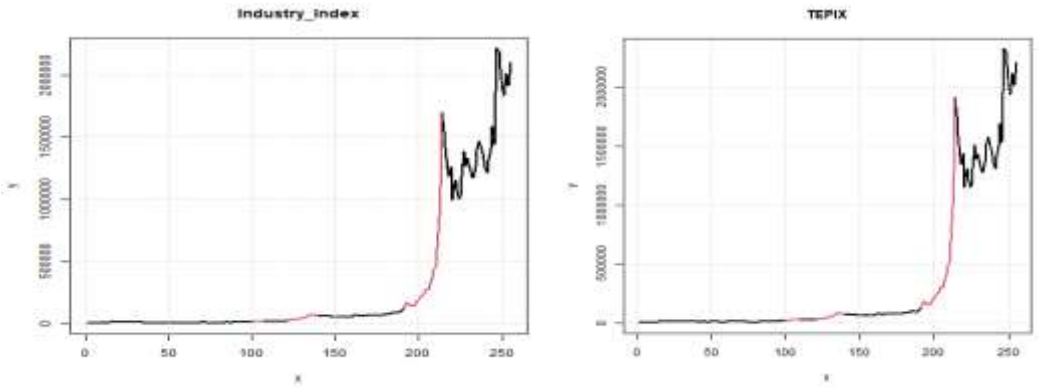
جدول ۳. آماره‌های توصیفی مربوط به بازدهی ماهانه متغیّرهای وابسته

شرح	شاخص کل	شاخص صنعت	شاخص مالی	شاخص ۵۰ شرکت فعال‌تر	شاخص فلزات اساسی
تعداد مشاهدات	۲۵۵	۲۵۵	۲۵۵	۲۵۵	۲۵۵
کمینه	-۰,۲۲۳۶	-۰,۲۴۱	-۰,۱۶۱	-۰,۲۹۱۹	-۰,۳۳۸۸
بیشینه	۰,۴۱۰۸	۰,۴۲۸۸	۰,۴۳۳۴	۰,۴۷۰۸	۰,۵۱۰۳
میانگین	۰,۰۲۴۲۶	۰,۰۲۴۴۹	۰,۰۲۱۱۲	۰,۰۲۲۵۵	۰,۰۲۸۶۹
میانه	۰,۰۱۰۶	۰,۰۰۹۷	۰,۰۰۴۹	۰,۰۰۴۷	۰,۰۲۱۳
انحراف معیار	۰,۰۷۷۵۷	۰,۰۷۹۸۹	۰,۰۸۲۱۸	۰,۰۸۸۳۹	۰,۱۰۵۱۱
چولگی	۱,۲۰۹۰۹	۱,۱۶۷۷۱	۱,۳۳۵۳۴	۱,۰۳۹۸۸	۰,۵۰۴۷۲
کشیدگی	۳,۷۱۵۴۲	۳,۵۷۶۱۳	۳,۵۸۳۳۳	۳,۷۳۱۲۶	۲,۵۱۷۹۳

منبع: یافته‌های پژوهش

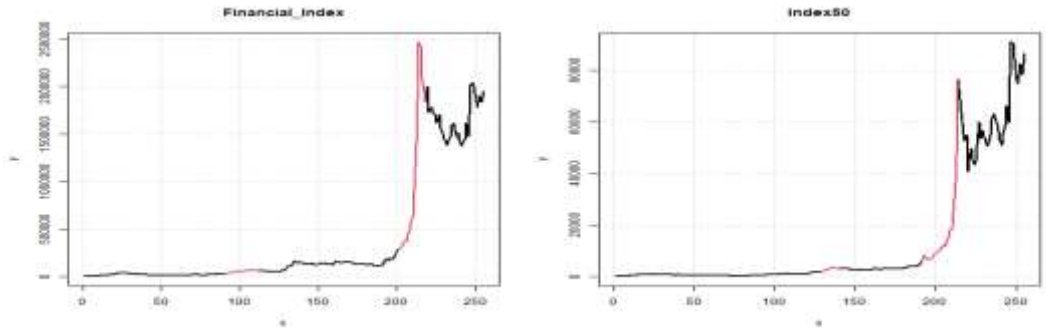
شناسایی دوره‌های حبابی و تشکیل متغیّر مجازی حباب

در این قسمت پس از شناسایی دوره‌های حبابی با استفاده از روش GSADF در شاخص‌های اصلی؛ متغیّر مجازی حباب با دو مقدار به ترتیب ۰ برای ماه‌های غیرحبابی و ۱ برای ماه‌های حبابی تعریف شده است. اشکال ۷ الی ۹، نمودار قیمت ماهانه شاخص‌ها را به همراه دوره‌های حبابی شناسایی شده نشان می‌دهند.



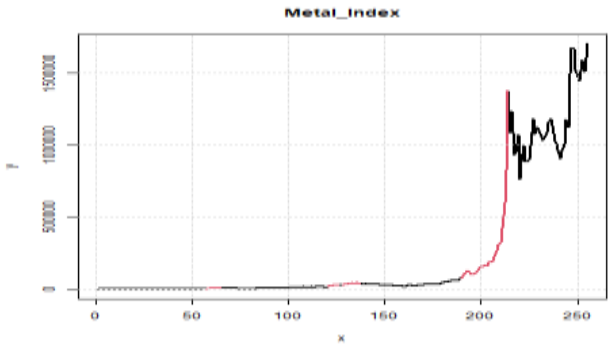
شکل ٤. نمودار قیمت ماهانه شاخص کل(چپ) و شاخص صنعت (راست) به همراه دوره‌های حبابی شناسایی شده

منبع: یافته‌های پژوهش



شکل ۵. نمودار قیمت ماهانه شاخص مالی(چپ) و ۵۰ شرکت بزرگ (راست) به همراه دوره‌های حبابی شناسایی شده

منبع: یافته‌های پژوهش



شکل ٦. نمودار قیمت ماهانه شاخص فلزات به همراه دوره‌های حبابی شناسایی شده

منبع: یافته‌های پژوهش

همان‌طورکه از نمودار فوق ملاحظه می‌گردد قسمت قرمز رنگ نمودار مربوط به دوره‌های حبابی است. از جداول ۴ الی ۸ و شکل ۹ جزئیات بیشتری را در اختیار داریم.

جدول ٤. جزئیات دوره حبابی برای شاخص کل

مدت (ماه)	تاریخ پایان	نقطه اوج (پیک)	تاریخ شروع
۹	۱۳۹۰/۰۷/۳۰	۱۳۹۰/۰۱/۳۱	۱۳۸۹/۱۰/۲۹
۱۸	۱۳۹۳/۰۱/۳۱	۱۳۹۲/۰۹/۳۰	۱۳۹۱/۰۷/۳۰
۶	۱۳۹۷/۱۱/۳۰	۱۳۹۷/۱۰/۳۰	۱۳۹۷/۰۵/۳۰
۱۶	۱۳۹۹/۰۴/۳۱	۱۳۹۸/۱۲/۲۸	۱۳۹۷/۱۲/۲۸

منبع: یافته‌های پژوهش

جدول ۵. جزئیات دوره حبابی برای شاخص صنعت

مدت (ماه)	تاریخ پایان	نقطه اوج (پیک)	تاریخ شروع
۶	۱۳۹۰/۰۴/۲۹	۱۳۹۰/۰۱/۳۱	۱۳۸۹/۱۰/۲۹
۱۸	۱۳۹۳/۰۱/۳۱	۱۳۹۲/۰۹/۳۰	۱۳۹۱/۰۷/۳۰
۲۳	۱۳۹۹/۰۴/۳۱	۱۳۹۸/۱۲/۲۸	۱۳۹۷/۰۵/۳۰

منبع: یافته‌های پژوهش

جدول ٦. جزئیات دوره حبابی برای شاخص مالی

مدت (ماه)	تاریخ پایان	نقطه اوج (پیک)	تاریخ شروع
۲۰	۱۳۹۰/۰۹/۳۰	۱۳۹۰/۰۱/۳۱	۱۳۸۹/۰۱/۳۱
۱۷	۱۳۹۹/۰۸/۲۸	۱۳۹۹/۰۷/۳۰	۱۳۹۸/۰۳/۲۹

منبع: یافته‌های پژوهش

جدول ۷. جزئیات دوره حبابی برای شاخص ۵۰ شرکت فعال‌تر

مدت (ماه)	تاریخ پایان	نقطه اوج (پیک)	تاریخ شروع
۱۰	۱۳۹۳/۰۱/۳۱	۱۳۹۲/۰۹/۳۰	۱۳۹۲/۰۳/۲۹
۲۲	۱۳۹۹/۰۴/۳۱	۱۳۹۸/۱۲/۲۸	۱۳۹۷/۰۵/۳۰

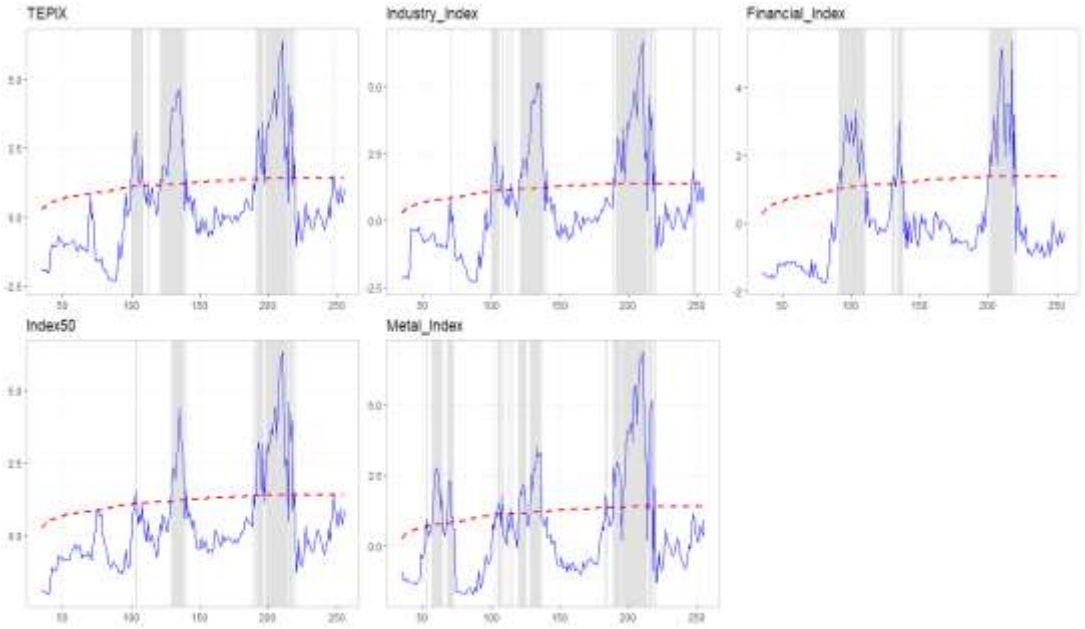
منبع: یافته‌های پژوهش

جدول ۸. جزئیات دوره حبابی برای شاخص فلزات

مدت (ماه)	تاریخ پایان	نقطه اوج (پیک)	تاریخ شروع
۸	۱۳۹۳/۰۱/۳۱	۱۳۹۲/۰۹/۳۰	۱۳۹۲/۰۳/۲۹
۱۵	۱۳۹۲/۱۱/۳۰	۱۳۹۲/۰۷/۳۰	۱۳۹۱/۰۶/۲۹
۲۴	۱۳۹۹/۰۴/۳۱	۱۳۹۸/۱۲/۲۸	۱۳۹۷/۰۳/۳۰

منبع: یافته‌های پژوهش

همانطورکه از نتایج جداول فوق ملاحظه می‌گردد تمامی شاخص‌ها یک دوره مشخص حبابی تقریباً دو ساله را از مرداد ماه سال ۱۳۹۷ الی مرداد ماه سال ۱۳۹۹ تجربه کرده‌اند. نکته حائز اهمیّت دیگر این است که در شاخص مالی، سیگنال خروج از حباب قدری دیرتر نسبت به سایر شاخص‌ها بوده است ولی شاخص‌های صنعت و شاخص کل تقریباً دوره‌های مشابهی داشته‌اند. از شکل ۹، نحوه تشخیص این دوره‌ها توسط روش GSADF قابل مشاهده است.



شکل ۷. نمودار نتایج روش GSADF به جهت تشخیص دوره‌های حبابی

منبع: یافته‌های پژوهش

مدل‌سازی پیش‌بینی حباب

پس از شناسایی دوره‌های حبابی و همچنین تشکیل متغیّر مجازی حباب، با در نظر گرفتن این متغیّر مجازی به عنوان متغیّر هدف، مدل‌سازی به منظور پیش‌بینی آن انجام شده است. برای این منظور از دو مدل رگرسیون لجستیک و شبکه‌های عصبی برگشتی رهیافت حافظه کوتاه مدت طولانی استفاده شده است. ۷۰ درصد مشاهدات از تاریخ ۲۸-۱۲-۱۳۸۱ الی ۲۹-۰۶-۱۳۹۶ به عنوان مجموعه آموزشی (درون نمونه ای) و ۳۰ درصد باقی مانده از تاریخ ۳۰-۰۷-۱۳۹۶ الی ۲۹-۰۹-۱۴۰۲ به عنوان مجموعه آزمایشی (برون نمونه‌ای) در نظر گرفته شده است. از جدول ۹ میزان توزیع دوره‌های حبابی و غیرحبابی شاخص‌های پژوهش را در دو مجموعه آموزشی و آزمایشی به تفکیک مشاهده می‌کنیم.

همانطورکه از جدول ۹ ملاحظه می‌گردد نحوه توزیع فراوانی دوره‌های حبابی در سه شاخص کل، صنعت و فلزات اساسی تقریباً مشابه می‌باشند. از سوی دیگر کمترین تعداد مشاهدات مربوط به شاخص ۵۰ شرکت فعال‌تر با تعداد ۳۵ ماه است. پس از معین نمودن مجموعه داده‌های آموزشی و آزمایشی به مدل‌سازی و آموزش مدل‌ها پرداخته شده است. تنظیمات ابر پارامترها نیز از جدول ۱۰ قابل مشاهده است:

جدول ۹. توزیع دوره‌های حبابی در داده‌های آموزشی و آزمایشی

شاخص‌ها	ماه‌های غیرحبابی مجموعه آموزشی	تعداد حباب مجموعه آموزشی	ماه‌های غیرحبابی مجموعه آزمایشی	تعداد حباب مجموعه آزمایشی	جمع تعداد حباب‌ها
شاخص کل	۱۴۶	۲۹	۵۱	۲۴	۵۳
شاخص صنعت	۱۴۹	۲۶	۵۱	۲۴	۵۰
شاخص مالی	۱۵۴	۲۱	۵۷	۱۸	۳۹
شاخص ۵۰ شرکت فعال‌تر	۱۶۴	۱۱	۵۱	۲۴	۳۵
شاخص فلزات اساسی	۱۴۹	۲۶	۴۹	۲۶	۵۲

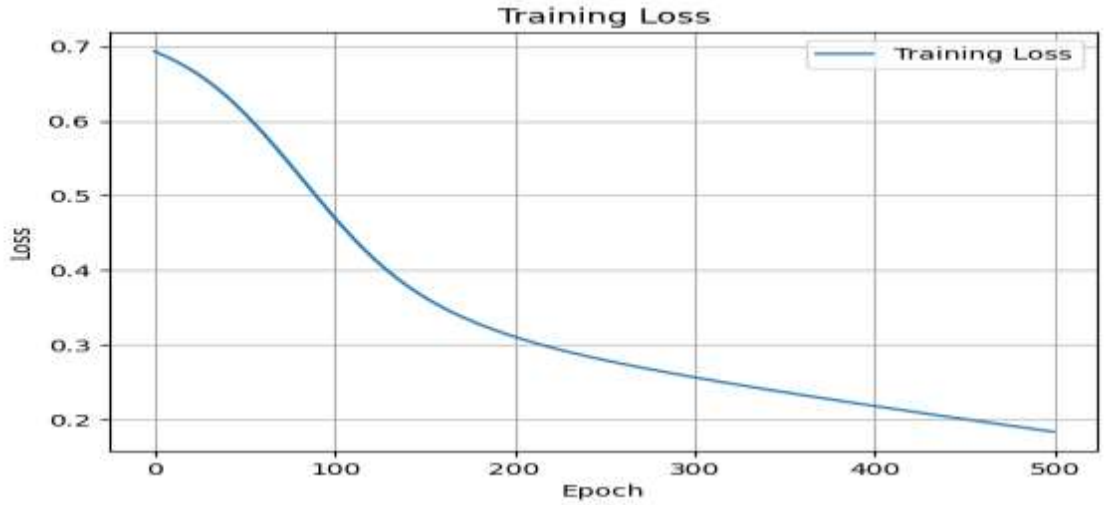
منبع: یافته‌های پژوهش

جدول ۱۰. تنظیمات ابر پارامترها

ابر پارامترها	مقدار تنظیم شده
نرخ یادگیری	۰,۰۰۱
نرخ منظم‌ساز	۰,۰۰۰۱
الگوریتم بهینه‌ساز	Adam
β_1	۰,۹
β_2	۰,۹۹۹
تعداد دسته آموزشی	۵۱۲
تعداد تکرار	۵۰۰

منبع: یافته‌های پژوهش

نتیجه آموزش شبکه برای داده‌های مجموعه آموزشی (درون نمونه ای) را نیز از شکل ۱۰ در اختیار داریم:



شکل ۸. نتیجه حاصل از فرآیند آموزش شبکه

منبع: یافته‌های پژوهش

با توجه به شکل ۱۰ مشاهده می‌شود مقدار تابع هزینه با افزایش تکرار عملیات آموزش کم و کمتر شده تا به همگرایی می‌رسد. این مهم بیانگر آن است که شبکه عصبی عمیق به طور قابل قبول و خوبی آموزش دیده است.

ارزیابی دقّت و عملکرد مدل‌های تبیین شده

در این قسمت نتایج ارزیابی دقت پیش‌بینی مدل‌های رگرسیون لجستیک و حافظه کوتاه مدت طولانی برای شاخص‌های مورد پژوهش گزارش شده است. از جدول ۱۱، درصد صحّت پیش‌بینی مدل رگرسیون لجستیک به تفکیک مجموعه آموزشی و آزمایشی آورده شده است. از سوی دیگر ملاحظه می‌گردد بالاترین دقت پیش‌بینی مربوط به شاخص مالی به میزان ۸۵ درصد است و همچنین کمترین دقت پیش‌بینی مربوط به شاخص صنعت به میزان ۶۱ درصد می باشد که به نوعی بیانگر وقوع بیش-برازشی نیز می‌تواند باشد. در ادامه از جداول ۱۲ الی ۱۶ ماتریس درهم‌ریختگی هر یک از شاخص‌ها را برای داده‌های مجموعه آزمایشی در اختیار داریم.

جدول ۱۱. ارزیابی دقت مدل LR برای مجموعه داده‌های آموزشی و آزمایشی به تفکیک شاخص

شاخص ها	مجموعه آموزشی	مجموعه آزمایشی
شاخص کل	۰,۹۴	۰,۶۷
شاخص صنعت	۱	۰,۶۱
شاخص مالی	۰,۹۱	۰,۸۵
شاخص ۵۰ شرکت بزرگ	۱	۰,۷۵
شاخص فلزات	۰,۹۹	۰,۷۲

منبع: یافته‌های پژوهش

جدول ۱۲. ماتریس درهم ریختگی مدل LR داده‌های آزمایشی شاخص کل

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۱۶	۳۵	غیر حباب
٪۶۲,۵	۱۵	۹	حباب

منبع: یافته های پژوهش

جدول ۱۳. ماتریس درهم ریختگی مدل LR داده‌های آزمایشی شاخص صنعت

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۱۷	۳۴	غیر حباب
٪۵۰	۱۲	۱۲	حباب

منبع: یافته‌های پژوهش

جدول ۱٤. ماتریس درهم ریختگی مدل LR داده‌های آزمایشی شاخص مالی

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۵	۵۲	غیر حباب
٪۶۶	۱۲	۶	حباب

منبع: یافته‌های پژوهش

جدول ۱۵. ماتریس درهم ریختگی مدل LR داده‌های آزمایشی شاخص ۵۰ شرکت فعال‌تر

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۳	۴۸	غیر حباب
٪۳۳	۸	۱۶	حباب

منبع: یافته‌های پژوهش

جدول ۱٦. ماتریس درهم ریختگی مدل LR داده های آزمایشی شاخص فلزات

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۸	۴۱	غیر حباب
٪۵۰	۱۳	۱۳	حباب

منبع: یافته‌های پژوهش

ماتریس درهم ریختگی نحوه توزیع فراوانی مشاهدات واقعی در مجموعه داده‌های آزمایشی را در مقابل مشاهدات پیش‌بینی‌شده توسط مدل نشان می‌دهد. برای مثال اگر به جدول ۱۲ توجه داشته باشیم که ماتریس درهم ریختگی برای شاخص کل است درمی‌یابیم از ۷۵ مشاهده موجود در مجموعه آزمایشی مجموعا ۵۱ مشاهده غیرحبابی و ۲۴ مشاهده حباب بوده است که از ۵۱ مشاهده غیر حبابی ۳۵ مورد به درستی توسط مدل غیر حبابی شناسایی شده و ۱۶ مورد خطا وجود داشته که در واقعیت غیر-حبابی بوده اما مدل به اشتباه حباب تشخیص داده است. از سوی دیگر از بین ۲۴ مشاهده حبابی مدل آموزش دیده شده ۱۵ مورد را به درستی حباب تشخیص داده و ۹ مورد خطا داشته که در واقعیت حباب بوده‌اند ولی مدل غیرحباب پیش‌بینی کرده است. اگر میزان درستی پیش‌بینی در خصوص تشخیص حباب (۱۵ مورد) را تقسیم بر مجموع کل مشاهدات حبابی (۲۴ مورد) کنیم به نرخ تبدیل ٪۶۲٫۵ می‌رسیم که اصطلاحاً به آن نرخ صحیح مثبت[1] می‌گویند.

تفسیر ماتریس‌های درهم ریختگی مابقی شاخص‌ها نیز به همین منوال می‌باشد. با نگاهی اجمالی در می‌یابیم مدل رگرسیون لجستیک در پیش‌بینی حباب شاخص مالی و پس از آن شاخص کل؛ نسبت به سایر شاخص‌ها عملکرد بهتری داشته است.

از جدول ۱۷ نیز نتایج دقّت پیش‌بینی برای مدل حافظه کوتاه‌مدت طولانی را در اختیار داریم؛ همچنین از جداول ۱۸ الی ۲۲ نیز ماتریس‌های درهم ریختگی مربوط به مجموعه آزمایشی را مشاهده می‌کنیم. با مقایسه نتایج دقّت پیش بینی در مدل LSTM درمی‌یابیم دقّت پیش‌بینی در تمامی شاخص‌ها به جز شاخص مالی بهبود نسبی داشته است. برای مثال دقّت پیش‌بینی مدل رگرسیون لجستیک برای شاخص کل ٪۶۷ بوده درحالی‌که در مدل LSTM به ٪۷۷ رسیده که نشان‌دهنده افزایش بهبود ۱۰ درصدی در دقّت پیش‌بینی مدل می‌باشد. اما در خصوص شاخص مالی این نتیجه کاملاً معکوس بوده است.

[1]. True Positive Rate

جدول ۱۷. ارزیابی دقت مدل LSTM برای مجموعه داده‌های آموزشی و آزمایشی به تفکیک شاخص

شاخص ها	مجموعه آموزشی	مجموعه آزمایشی
شاخص کل	۰,۹۳	۰,۷۷
شاخص صنعت	۰,۹۵	۰,۷۷
شاخص مالی	۰,۸۹	۰,۷۵
شاخص ۵۰ شرکت بزرگ	۰,۹۹	۰,۷۹
شاخص فلزات	۰,۹۳	۰,۷۷

منبع: یافته های پژوهش

جدول ۱۸. ماتریس درهم ریختگی مدل LSTM برای داده های آزمایشی شاخص کل

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۹	۴۲	غیر حباب
٪۶۶	۱۶	۸	حباب

منبع: یافته‌های پژوهش

جدول ۱۹. ماتریس درهم ریختگی مدل LSTM برای داده های آزمایشی شاخص صنعت

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۹	۴۲	غیر حباب
٪۶۶	۱۶	۸	حباب

منبع: یافته‌های پژوهش

جدول ۲۰. ماتریس درهم ریختگی مدل LSTM برای داده های آزمایشی شاخص مالی

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۴	۵۳	غیر حباب
٪۱۷	۳	۱۵	حباب

منبع: یافته های پژوهش

جدول ۲۱. ماتریس درهم ریختگی مدل LSTM برای داده های آزمایشی شاخص ۵۰ شرکت فعال‌تر

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۳	۴۸	غیر حباب
٪۴۶	۱۱	۱۳	حباب

منبع: یافته های پژوهش

جدول ۲۲. ماتریس درهم ریختگی مدل LSTM برای داده های آزمایشی شاخص فلزات

نرخ تشخیص حباب	حباب	غیر حباب	پیش بینی/ واقعی
	۲	۴۷	غیر حباب
٪۴۲	۱۱	۱۵	حباب

منبع: یافته های پژوهش

همانطورکه از جداول ماتریس های درهم ریختگی فوق ملاحظه می گردد مدل LSTM در بهبود پیش بینی های حباب شاخص کل، صنعت و ۵۰ شرکت عملکرد بهتری نسبت به مدل رگرسیون لجستیک داشته است ولی در شاخص فلزّات اندکی ضعیف‌تر و در شاخص مالی عملکرد بدتری داشته است.

نتیجه‌گیری و پیشنهادها

هدف اصلی پژوهش حاضر، طرّاحی یک سیستم هشدار سریع جهت پیش‌بینی حباب شاخص‌های منتخب بورس تهران (کل، صنعت، ۵۰ شرکت فعّال‌تر، فلزات اساسی، مالی) با لحاظ تغییرات قیمتی (بازدهی لگاریتمی) مجموعه‌ای از متغیّرهای مستقل به عنوان شاخص‌های هشداردهنده و با رویکرد یادگیری عمیق بوده است. این سیستم، با دقّت حدود ۷۷ تا ۷۹ درصد در شاخص-های کل، ۵۰ شرکت فعّال‌تر و صنعت و با کیفیت پیش‌بینی بهتری نسبت به سایر شاخص‌ها، طرّاحی و محقّق شده است.

از جمله اهداف جزئی این پژوهش، شناسایی دوره‌های حبابی در شاخص‌های منتخب بورس تهران بوده است که این امر نیز توسط آزمون GSADF تحقّق پذیرفته و نتایج آن از جداول ۴ الی ۸ قابل مشاهده است. نکته حائز اهمیّت این است که در شاخص مالی، سیگنال خروج از حباب قدری دیرتر نسبت به سایر شاخص ها بوده است ولی شاخص‌های صنعت و شاخص کل تقریباً دوره‌های مشابهی داشته‌اند. هدف دیگر این پژوهش، مقایسه‌ی دقّت مدل‌های به کار گرفته شده در سیستم هشدار سریع طرّاحی شده، می‌باشد؛ نتایج به دست آمده حاکی از آن بود که در شاخص مالی، مدل رگرسیون لجستیک عملکرد بهتری داشته است در حالی‌که برای شاخص‌های کل، ۵۰ شرکت فعّال‌تر، صنعت و فلزّات، مدل حافظه کوتاه‌مدت طولانی عملکرد بهتری ارائه کرده است و البته برای شاخص‌های کل و صنعت بهبود قابل ملاحظه‌ای را به همراه داشته است.

در رابطه با مقایسه‌ی کیفیّت پیش‌بینی حباب شاخص‌های منتخب بورس تهران از طریق ماتریس‌های درهم‌ریختگی این نتیجه حاصل شده است که کیفیّت پیش‌بینی مدل رگرسیون لجستیک برای شاخص مالی و فلزّات نسبت به سایر شاخص‌ها به مراتب بهتر بوده در حالی‌که کیفیّت پیش‌بینی مدل حافظه کوتاه‌مدت طولانی برای شاخص‌های کل، صنعت و ۵۰ شرکت فعّال‌تر نسبت به سایر شاخص‌ها بهتر بوده است. بنابراین از آن‌چه که از طریق ماتریس‌های درهم‌ریختگی حاصل شده است، می‌توان نتیجه گرفت که لزوماً استفاده از مدل یادگیری عمیق برای تمامی شاخص‌ها بهتر نبوده و باید نگاهی ترکیبی نسبت به انتخاب مدل‌ها برای شاخص‌های مورد نظر داشته باشیم. البته این نکته نیز قابل توجّه است که با گذشت زمان و افزایش تعداد مشاهدات، عملکرد مدل‌های مبتنی بر یادگیری عمیق بهتر خواهند شد، از این‌رو باید سیستم‌های هشداردهنده و پیش‌بینی‌کننده به طور مداوم به روز شوند.

پیشنهادهای پژوهش به شرح زیر است:

- سیستم‌های هشدار سریع پیش‌بینی حباب برای سایر بازار دارایی‌ها همچون مسکن، طلا، ارز، رمزارز در تواترهای روزانه و هفتگی مورد بررسی قرار گیرند.
- سایر شاخص‌های هشداردهنده همچون تولید ناخالص داخلی، پایه پولی، نقدینگی، کسری بودجه، صادرات نفتی و غیرنفتی، شاخص‌های مالی رفتاری، شاخص احساسات و ... جهت بهبود دقّت سیستم هشدار سریع پیش‌بینی حباب به کار روند.
- روش‌ها و مدل‌های ترکیبی اقتصادسنجی، هوش مصنوعی و ابتکاری به منظور طرّاحی سیستم‌های هشدار سریع به کار گرفته شوند.
- نتایج به دست آمده در این پژوهش را می‌توان در جهت بهبود مدیریت سرمایه و پرتفوی، طرّاحی استراتژی‌های معاملاتی پویا، استراتژی‌های پوشش ریسک و ... به کار برد.

منابع

آسیم، محمد (۱۳۹۹). الگویی برای تبیین رفتار سرمایه‌گذاران قبل و بعد از حباب قیمت سهام. رساله دکتری، دانشگاه علّامه طباطبائی.

احمدپور، بهادر؛ پوردرویش، احمد (۱۴۰۱). رویکرد شبکه‌های عصبی عمیق با اثر القایی نوسانات خطا روی برخی رمزارزها. پایان نامه ارشد، دانشگاه مازندران.

بیابانی خامنه، کاظم؛ خزایی، سعید؛ افشاریان، امیرحسین (۱۳۹۵). آزمون وجود حباب و رفتار انفجاری در بازار سهام ایران. دانش مالی تحلیل اوراق بهادار، ۹ (۲۹)، ۱۱۱-۱۲۵

ترابی، تقی؛ انواری رستمی، علی‌اصغر؛ غفاری، فرهاد؛ داستانی هریس، سارا (۱۳۹۹). ارائه مدلی جهت برآورد احتمال ایجاد حباب قیمتی در بازار سرمایه: شواهد تجربی و تئوریک از بورس اوراق بهادار تهران. فصلنامه علمی پژوهشی دانش سرمایه‌گذاری، ۹ (۳۴)

خلیلی عراقی، مریم؛ فلاح شمس، میرفیض؛ رئیسی وانانی، ایمان؛ شریف‌فر، امیر (۱۴۰۱). کاربرد معماری‌های یادگیری عمیق در پیش‌بینی قیمت سهام؛ رویکرد شبکه عصبی پیچشی. مدیریت دارایی و تأمین مالی، ۱۰ (۳)، ۱-۲۰

رهنمای رودپشتی، فریدون؛ فلاح شمس، میرفیض؛ چیرانی، ابراهیم؛ زمردیان، غلامرضا؛ کاشانی تبار، شهرزاد (۱۳۹۹). بررسی تأثیر سرریز نوسانات در بازارهای مالی و ویژگی‌های بازاری در پیش‌بینی ترکیدن حباب قیمت در بورس با رویکرد تلاطم-های شرطی. فصلنامه مهندسی مالی و مدیریت اوراق بهادار، ۴۴

سلمانی، بهزاد؛ حقیقت، جعفر؛ اصغرپور، حسین؛ اکبرموسوی، سیدصالح (۱۴۰۱). پیش‌بینی بحران‌های بانکی: سیستم هشدار زودهنگام پویا. فصلنامه مدل‌سازی اقتصادسنجی، ۷ (۱)

صیادنیا طیبی، عزّت‌اله؛ ارشدی، علی؛ صمدی، سعید؛ شجری، هوشنگ (۱۳۸۹). تبیین یک سیستم هشداردهنده جهت شناسایی بحران‌های مالی در ایران. فصلنامه پول و اقتصاد، (۶) ، ۱۶۹-۲۱۱

عبّاسیان، عزّت‌الله؛ محمودی، وحید؛ فرزانگان، الهام (۱۳۸۹)؛ شناسایی حباب قیمتی سهام عادی بورس اوراق بهادار تهران با استفاده از مدل ارزش حال. بررسی‌های حسابداری و حسابرسی، ۱۷ (۶۰)، ۷۵-۹۲

عبّاسیان، عزّت‌الله؛ نصیرالاسلامی، ابراهیم؛ فرزانگان، الهام (۱۳۹۴)؛ بی‌قاعدگی حباب قیمتی در بورس اوراق بهادار تهران:رویکرد محدودیت در آربیتراژ. فصلنامه پژوهش‌ها و سیاست‌های اقتصادی، ۲۳ (۷۶)، ۷۵-۹۲

فلاح شمس، میرفیض؛ چیرانی، ابراهیم؛ زمردیان، غلامرضا (۱۳۹۹). پیش‌بینی ترکیدن حباب قیمتی سهام در بورس اوراق بهادار تهران (رویکرد تلاطم‌های شرطی). فصلنامه علمی پژوهشی دانش سرمایه‌گذاری، ۹ (۳۶)

مهرآرا، محسن؛ هاتفی مجومرد، مجید (۱۳۹۸). سرایت حباب: بررسی موردی بازارهای ارز و بورس اوراق بهادار. نشریه علمی سیاست‌گذاری اقتصادی، ۱۱ (۲۱)

نبوی چاشمی، سیدعلی؛ محجوب، محمدرضا (۱۴۰۰). آزمون وجود حباب سهام با استفاده از تکنیک‌های سوپریمم راست‌دنباله و توابع عکس‌العمی و تجزیه واریانس. فصلنامه علمی پژوهشی دانش سرمایه‌گذاری، ۱۰ (۳۸)

یاوری، کاظم؛ نجارزاده، رضا؛ مهرگان، نادر؛ نصراللهی، محمد (۱۳۹۶). طرّاحی یک سیستم هشدار زودهنگام بحران‌های ارزی در ایران: رویکرد رگرسیون لجستیک. تحقیقات اقتصادی، ۵۲ (۱)، ۱۸۷-۲۱۴.

Abdelsalam, M. A. M., Abdel-Latif, H. (2020). An optimal early warning system for currency crises under model uncertainty. Central Bank Review, 20(3), 99-107.

Abolmakarem, S., Abdi, F., Damghani, K. K. and Didehkhani, H. (2024). A Multi-Stage Machine Learning Approach for Stock Price Prediction: Engineered and Derivative Indices. Intelligent Systems with Applications, 24, 200449.

Brunnermeier, M. K. (2008). Bubbles, the New Palgrave Dictionary of Economics.

Barberis, N., Greenwood, R., Jin, L., & Shleifer, A. (2018). Extrapolation and Bubbles. Journal of Financial Economics 129(2), 203-227.

Bohl, M. T., Kaufmann, P. & Stephan, P. M. (2013). From Hero to Zero: Evidence of Performance Reversal and Speculative Bubbles in German Renewable Energy Stocks. Energy Economics, 37 (C), 40-51.

Claessens, S., and Kose, M. A. (2013). Financial Crises: Explanations, Types, and Implications. IMF Working Paper, No WP/13/28.

Fullbrunn, S. and Peters, J. (2019). Constructing an Early Warning System to Predict the Speculative House Price Bubble in the Current Western- European Housing Market. Radboud University.

Frommel, M. and Kruse, R. (2012). Testing for a Rational Bubble under Long Memory. Quantitative Finance, Taylor & Francis Journals, 12(11), 1723-1732.

Gomez-Gonzalez, J. E., Gamboa-Arbelaez, J., Hirs-Garzon, J., and Pinchao-Rosero, A. (2016). When Bubble Meets Bubble: Contagion in OECD Countries. The Journal of Real Estate Finance and Economics, 1-21.

Homm, U. and Breitung, J. (2012). Testing for Speculative Bubbles in Stock Markets: A Comparison of Alternative Methods. Journal of Financial Econometrics 10(1), 198-231.

Hennig, T., Lossifov, P. and Varghese, R. (2023). Predicting Financial Crises: The Role of Asset Prices. IMF Working Paper, No WP/23/157.

Hochreiter, S., and Schmidhuber, J. (1997). Long short-term Memory. Neural Computation, 9, 1735-1780.

Kaliva, K., Koskinen, L. (2007). Stock Market Bubbles, Inflation and Investment Risk. International Review of Financial Analysis, 17 (3), 592-603.

Klopotan, I., Zoroja, J. and Mesko, M. (2018). Early Warning System in Business, Finance, and Economic: Bibliometric and Topic Analysis. International Journal of Engineering Business Management, 10, 1-12.

Landi, F., Baraldi, L., Cornia, M. and Cucchiara, R. (2021). Working Memory Connections for LSTM. Neural Networks, 144, 334-341.

Maghyereh, A. and Abdoh, H. (2022). Can News-Based Economic Sentiment Predict Bubbles in Precious Metal Markets? Financial Innovation, 8, 35.

- McQueen, G., and Thorley, S. (1994). Bubbles, Stock Returns, and Duration Dependence. Journal of Financial and Quantitative Analysis, 29(3), 379-401

- Namaki, A., Eivazlu, R. and Ramtinnia, S. (2023). A systematic Review of Early Warning Systems in Finance.

Phillips, P. C. B., Shi, S., and Yu, J. (2015). Testing for Multiple Bubbles: Historical Episodes of Exuberance and Collapse in the S&P 500. International Economic Review, 56(4), 1043- 1078.

Phillips, P. C. B., Wu, Y., and Yu, J. (2011). Explosive Behavior in the 1990s NASDAQ: When Did Exuberance Escalate Asset Values? International Economic Review, 52(1), 201-226.

Phillips, P. C. B. and Yu, J. (2011). Dating the Timeline of Financial Bubbles during the Subprime Crisis. Quantitative Economics, 2(3), 455-491.

Park, D. and Ryu, D. (2021). A Machine Learning-Based Early Warning System for the Housing and Stock Markets. National Research Foundation of Korea (NRF).

Scherbina, A. and Schlusche, B. (2014). Asset Price Bubbles: A Survey. Quantitative Finance 14(4), 589-604.

Tran, K. L., Le, H. A., Lieu, C. P. and Nguyen, D. T. (2023). Machine Learning to Forecast Financial Bubbles in Stock Markets: Evidence from Vietnam. International Journal of Financial Studies, 11(133)

Virtanen, T., Tolo, E., Viren, M. & Taipalus, K. (2017). Use of Unit Root Methods in Early Warning of Financial Crises. Working Paper. European Systemic Risk Board.

Wever, M. Shah, M. and O'Leary N. (2022). Designing Early Warning Systems for Detecting Systemic Risk: A case Study and Discussion. Futures, 136.

Wockl, I. (2019). Bubble Detection in Financial Markets: A Survey of Theoretical Bubble Models and Empirical Bubble Detection Tests. Working Paper, In Institute of Finance, University of Graz, Austria.