https://amf.ui.ac.ir

Journal of Asset Management and Financing
E-ISSN: 2383-1189
Vol. 14, Issue 3, No. 54, 2026, p 31-58
Received: 28/12/2024 Accepted: 09/09/2025

Research Paper

Designing an Early Warning System to Predict Price Bubbles in the Tehran Stock Exchange Using Deep Learning

Morteza Mazarei
Ph.D. Candidate, Department of Financial Management, Kish International Campus, Tehran University, Kish, Iran
morteza.mazarei@ut.ac.ir

Ezatollah Abbasian*
Professor, Department of Financial Engineering, Faculty of Management, University of Tehran, Tehran, Iran
e.abbasian@ut.ac.ir

Ebrahim Nasiroleslami
Assistant Professor, Department of Statistics, Faculty of Basic Sciences, Bu-Ali Sina University, Hamadan, Iran
e.nasiroleslami@basu.ac.ir

Abstract
The primary objective of this study is to design an Early Warning System (EWS) based on a Long Short-Term Memory (LSTM) architecture for the timely forecasting of price bubbles in the Tehran Stock Exchange (TSE). A secondary objective is to compare the predictive performance of this model against a Logistic Regression (LR) benchmark, using evaluation metrics such as the AUC-ROC and confusion matrix. The system's performance was evaluated on five selected TSE indices. Utilizing monthly data from 2002 to 2023, bubble periods were identified via the Generalized Supremum Augmented Dickey-Fuller (GSADF) test and represented as a binary variable. This bubble variable was then modeled using price changes of key warning indicators. The proposed deep learning-based system achieved predictive accuracy ranging from 73% to 81%, with the highest performance on the Total Index (81%) and the lowest on the Basic Metals Index (73%). A comparative analysis demonstrates that the LSTM model outperformed the LR model across all selected indices. The evaluation metrics confirm the superior performance of the LSTM model. To the best of our knowledge, this study presents the first reported EWS designed for predicting price bubbles in this context using a deep learning approach.
Keywords: Generalized Supremum Augmented Dickey-Fuller Test (GSADF), Early Warning System (EWS), Logistic Regression (LR), Long Short-Term Memory (LSTM)
JEL Classification: G01, G32, C45, C53

Introduction

The bursting of price bubbles can precipitate financial crises, rendering the study of bubbles and market collapses highly consequential for investment portfolio risk management (Kaliva & Koskinen, 2008). The early identification of such bubbles and the forecasting of their trajectories are therefore crucial for policymakers and market participants, as it enables preventive measures to mitigate or avert financial turmoil. Consequently, the development and deployment of financial EWS are essential to actively reduce economic vulnerabilities and counteract price bubbles (Claessens & Kose, 2013). As Phillips et al. (2015) note, an effective EWS must achieve a high degree of accurate detection to facilitate swift and effective policy implementation, while simultaneously maintaining a low false-positive rate to avoid unnecessary policy actions. Analyzing historical bubble episodes and the factors influencing their emergence is thus fundamental to informed decision-making and the control of market irregularities (Sadeghisharif et al., 2017). In this context, deep learning algorithms have significantly advanced machine-learning models by offering greater computational speed and predictive precision. The rapid evolution of this field has attracted considerable attention from economists addressing a range of problems, particularly in the domain of asset price forecasting (Khaliliaraghi et al., 2022). The primary objective of this study is to evaluate bubble periods in selected Tehran Stock Exchange (TSE) indices and, by incorporating price changes from a set of early warning indicators,

*Corresponding author
Mazarei, M., Abbasian, E. and Nasiroleslami, E. (2026). Designing of an Early Warning System for the Prediction of Price Bubbles in the Tehran Stock Exchange Using a Deep Learning Approach. *Journal of Asset Management and Financing*, *14*(3), 31-58.

2383-1189 © University of Isfahan
This is an open access article under the CC BY-NC-ND/4.0/ License (https://creativecommons.org/licenses/by-nc-nd/4.0/).

10.22108/amf.2025.143670.1943

to design a bubble prediction system using an LSTM model. This research further aims to compare the predictive accuracy and quality of the LSTM model against an LR benchmark. Accordingly, this research seeks to answer the following question: Does the employment of a deep learning approach improve the accuracy and quality of bubble forecasts across all selected indices in this study?

Materials and Methods

The target variables in this study were identified through a comparative analysis. Five TSE indices were selected: the Total Index, the 50 Most Active Companies Index, the Industry Index, the Financial Index, and the Basic Metals Index. Monthly data for these indices were collected for the period from 2002 to 2023. Bubble episodes were identified using the GSADF test, and the resulting bubble signals were used to construct a dummy bubble variable, which served as the dependent variable in the subsequent modeling. Based on a literature review, eighteen influential variables were drawn from macroeconomic indicators, market information, valuation multiples, and commodity prices to serve as independent warning indicators. The returns for these variables were calculated as logarithmic changes. Given the time-series nature of the data, these indicators were structured with a 5-period lag and normalized to serve as input features for the models. The contribution of these variables to predictive power, while indirect, is evidenced through the final model performance. Subsequently, bubble-forecasting models were developed and an EWS was designed using a Recurrent Neural Network with an LSTM architecture as the deep learning approach, alongside an LR model as a classical machine-learning benchmark. Finally, model performance was evaluated based on the model type and stock index, using forecasting accuracy, the Area Under the Receiver Operating Characteristic Curve (AUC-ROC), and the confusion matrix. This evaluation framework allowed for a comprehensive assessment and comparison of the models' predictive capabilities.

Findings

As illustrated in Table 1, the highest forecasting accuracy for the LR model was achieved by the Financial Index at 79%, while the lowest was observed for the Basic Metals Index at 65%. The AUC evaluation for the LR model indicates its strongest performance on the Financial Index (92%) and its weakest on the Basic Metals Index (79%). Furthermore, the confusion matrix assessment for the LR model reveals notably low true positive rates for the test data, ranging from 0% to 17%. According to the results in Table 2, the LSTM model attained its highest forecasting accuracy on the Total Index (81%) and its lowest on the Basic Metals Index (73%). A comparative analysis of predictive accuracy demonstrates that the LSTM model outperformed the LR benchmark across all indices. The AUC evaluation for the LSTM model also shows its best performance on the Financial Index (92%) and its lowest on the Basic Metals Index (81%). The confusion matrix for the LSTM model indicates substantially higher true positive rates, ranging from 38% to 71%, with the highest rate for the Total Index (71%) and the lowest for the 50 Most Active Companies Index (38%).

Table (1) Evaluation of the accuracy of the LR model for training and testing datasets by index

Indices	Training	Testing
Total	0.83	0.69
Industry	0.85	0.69
Financial	0.88	0.79
50 Most Active Companies	0.94	0.67
Basic Metals	0.85	0.65

Table (2) Evaluation of the accuracy of the LSTM model for training and testing datasets by Index

Indices	Training	Testing
Total	0.85	0.81
Industry	0.88	0.77
Financial	0.84	0.80
50 Most Active Companies	0.94	0.75
Basic Metals	0.87	0.73

Discussion and conclusion

The results demonstrate that the proposed EWS achieves predictive accuracy ranging from 73% to 81% across all selected indices, with the highest performance on the Total Index (81%) and the lowest on the Basic Metals Index (73%). A comparative analysis of model performance confirms that the LSTM model consistently outperforms the LR benchmark across all indices. This superiority is particularly evident in the case of the Total Index, where the LSTM model's accuracy of 81% represents a 12-percentage-point improvement over the LR model's 69%. Similarly, the accuracy improved by 8 percentage points for the Industrial, 50 Most Active Companies, and Basic Metals indices, while a marginal improvement of 1 percentage point was observed for the Financial Index. In terms of predictive quality, as evaluated by the AUC-ROC and confusion matrices, the findings present a nuanced picture. The AUC-ROC metrics indicate that the performance of the LSTM and LR models is somewhat comparable. In contrast, the evaluation based on confusion matrices reveals a substantially superior performance for the LSTM model, particularly in its ability to correctly identify true positives.

مدیریت دارایی و تأمین مالی
سال چهاردهم، شماره سوم، شماره پیاپی (۵۴)، ۱۴۰۵، ص ۳۱-۵۸
تاریخ دریافت: ۱۴۰۳/۱۰/۸ تاریخ پذیرش: ۱۴۰۴/۶/۱۸

مقاله پژوهشی

طراحی سیستم هشدار سریع جهت پیش‌بینی حباب‌های بورس اوراق بهادار تهران با رویکرد یادگیری عمیق

مرتضی مزارعی
دانشجوی دکتری گروه مدیریت مالی، پردیس بین‌المللی کیش، دانشگاه تهران، کیش، ایران
morteza.mazarei@ut.ac.ir

عزت‌اله عباسیان *
استاد، گروه مهندسی مالی، دانشکدگان مدیریت، دانشگاه تهران، تهران، ایران
e.abbasian@ut.ac.ir
ابراهیم نصیرالاسلامی
استادیار، گروه آمار، دانشکده علوم، دانشگاه بوعلی‌سینا، همدان، ایران
e.nasiroleslami@basu.ac.ir

چکیده
هدف اصلی این پژوهش، طراحی سیستم هشدار سریع با مدل شبکه‌های عصبی برگشتی رهیافت LSTM (یادگیری عمیق) است که قادر به پیش‌بینی به‌هنگامِ حباب‌های قیمتی در بورس تهران باشد. هدف دیگر، مقایسهٔ دقت و کیفیت نتایج با مدل LR (یادگیری ماشین) با استفاده از شاخص‌های ارزیابی مساحت زیر منحنی و ماتریس درهم‌ریختگی است. عملکرد این سیستم بر روی پنج شاخص منتخب بورس تهران آزمایش شد. ابتدا داده‌های ماهانهٔ شاخص‌های منتخب طی سال‌های ۱۳۸۱ تا ۱۴۰۲ استخراج و سپس دوره‌های حبابی توسط آزمون GSADF شناسایی و متغیر مجازی حباب ایجاد شد. سپس با لحاظ تغییرات قیمتی (بازده لگاریتمی) مجموعه‌ای از شاخص‌های هشداردهنده، مدل‌سازی پیش‌بینی متغیر حباب انجام شد. سیستم مدنظر با رویکرد یادگیری عمیق و با دقت حدود ۷۳٪ تا ۸۱٪ طراحی شد که بیشترین دقت پیش‌بینی مربوط به شاخص کل با ۸۱٪ و کمترین مربوط به شاخص فلزات اساسی با ۷۳٪ بود. با مقایسهٔ نتایج مدل LSTM با مدل LR ملاحظه شد که دقت پیش‌بینی در تمامی شاخص‌های منتخب بهبود داشته است. مقایسهٔ نتایج شاخص‌های ارزیابی نشان از عملکرد مطلوب مدل LSTM در مقایسه با مدل LR می‌دهد. براساس بررسی‌ها، سیستم هشدار سریعی با هدف پیش‌بینی حباب‌های قیمتی و با استفاده از یادگیری عمیق طراحی نشده است.

کلیدواژه‌ها: آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته، سیستم هشدار سریع، رگرسیون لجستیک، حافظهٔ کوتاه‌مدت طولانی
طبقه‌بندی JEL: G01, G32, C45, C53

---

* نویسندهٔ مسئول

مزارعی، مرتضی، عباسیان، عزت‌اله و نصیرالاسلامی، ابراهیم. (۱۴۰۵). طراحی سیستم هشدار سریع جهت پیش‌بینی حباب‌های بورس اوراق بهادار تهران با رویکرد یادگیری عمیق، *مدیریت دارایی و تأمین مالی*، ۱۴ (۳)، ۳۱-۵۸.

2383-1189 © University of Isfahan
This is an open access article under the CC BY-NC-ND/4.0/ License (https://creativecommons.org/licenses/by-nc-nd/4.0/).

10.22108/amf.2025.143670.1943

مقدمه

حباب‌های قیمتی یکی از پیچیده‌ترین پدیده‌های اقتصادی است که می‌تواند تبعات گسترده‌ای برای اقتصاد و جامعه داشته باشد. حباب‌های قیمتی وقتی رخ می‌دهد که قیمت معاملات جاری سهام از ارزش واقعی خود جدا می‌شود؛ این وضعیت یا ازطریق واکنش بازار از بین می‌رود یا تشدید می‌شود که حباب واقعی از حالت تشدیدشوندهٔ 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 می‌شود و در عمل گفته می‌شود که حباب قیمتی درحال ترکیدن است (Abbasian et al., 2010).

حباب‌های قیمت دارایی می‌تواند به سرمایه‌گذاری نامناسبی منجر شود که کارایی هر اقتصادی را کاهش می‌دهد. ترکیدن حباب‌ها می‌تواند به بحران‌های مالی گسترده منجر شود؛ زیرا بسیاری از مؤسسات مالی ممکن است در معرض ریسک ورشکستگی قرار گیرند؛ ازاین‌رو، فروپاشی‌ها و حباب‌ها برای مدیریت ریسک سبدهای سرمایه‌گذاری از اهمیت زیادی برخوردار است (Kaliva & Koskinen, 2008). بحران‌های مالی و حباب‌های قیمت دارایی ارتباط بسیار نزدیکی با یکدیگر دارند. عموماً بازارهای مالی، بحران‌های مالی را تجربه کرده‌اند که منشأ آن رشد و انفجار یک حباب قیمت دارایی بوده است. در زمانی که تعداد زیادی از معامله‌گران تصمیم به فروش دارایی بگیرند، قیمت‌ها به‌سرعت کاهش خواهد یافت. پس وجود حباب به معنای خطر سقوط قیمت است (Gomez-Gonzalez et al., 2017).

حباب‌های قیمتی در بازارهای مالی همواره تهدیدی جدی برای ثبات اقتصادی و سلامت سیستم‌های مالی محسوب می‌شود. شناسایی سریع این حباب‌ها و پیش‌بینی روند توسعه یا انفجار آن‌ها برای سیاست‌گذاران و فعالان بازار اهمیت حیاتی دارد تا بتوانند اقدامات پیشگیرانه انجام دهند و از بروز بحران‌های مالی جلوگیری کنند؛ در این راستا، سیستم‌های هشدار سریع مالی به‌عنوان ابزارهای کلیدی در شناسایی نشانه‌های اولیهٔ خطر و تحلیل رفتارهای بازار طراحی شده‌اند؛ زیرا امکان تشخیص علائم هشداردهنده قبل از وقوع بحران را فراهم می‌آورند و نقش حیاتی در مدیریت ریسک‌های مالی دارند؛ بنابراین، توسعه و بهره‌برداری از این سیستم‌ها ضروری است تا به‌صورت فعال، در مسیر کاهش آسیب‌پذیری‌های اقتصادی و مقابله با حباب‌های قیمتی گام برداشته شود (Claessens & Kose, 2013).

سیستم‌های هشدار سریع[1] در ابتدا از مسیر موضوع بحران‌های مالی به ادبیات مالی ورود کرده‌اند؛ بنابراین، یک تنیدگی اولیه‌ای بین موضوع بحران‌های مالی و سیستم‌های هشدار سریع وجود دارد؛ بااین‌وجود، این سیستم‌ها می‌توانند در هر منطقه‌ای که رویدادهای معمول، نشانه‌های منفی دارند به کار برده شوند و به سیستم‌های فناوری، سیاست‌ها و رویه‌هایی اشاره دارد که با هدف اصلی پیش‌بینی رویداد منفی در محیط‌های مختلف استفاده می‌شود (Klopotan et al., 2018). 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 (Abdelsalam & Abdel-Latif, 2020).

بعضی از پژوهش‌های اخیر درزمینهٔ شناسایی حباب‌های مالی، شامل روش‌هایی هستند که می‌توانند به‌عنوان سیستم‌های هشداردهندهٔ حباب‌های آتی به کار روند. این روش‌ها به دنبال کمک به فعالان بازار برای جلوگیری از ریسک‌های فروپاشی حباب‌ها هستند. بدیهی است که طراحی سیستم‌های هشدار سریع به اندازهٔ توسعهٔ سازوکارهای اتکاپذیر شناسایی حباب چالش‌برانگیز است (Wockl, 2019). همان‌طور که فیلیپس و همکاران (Phillips et al., 2015) اشاره می‌کنند، سیستم‌های هشدار باید درجه و میزان زیادی از شناسایی صحیح داشته باشند که از اجرای سیاست‌گذاری سریع و مؤثر آن اطمینان حاصل شود. درعین‌حال، برای جلوگیری از اقدامات غیرضروری سیاست‌گذاری باید درجه و میزان کمی از شناسایی نادرست داشته باشند.

1. Early Warning Systems (EWS)

تحلیل دوره‌های حبابی و بررسی عوامل مؤثر در پدیدآمدن این پدیده، کلید اتخاذ تصمیم‌های مؤثر و کنترل ناهنجاری‌های بازار است (Sadeghisharif et al., 2017). براساس پژوهش‌های انجام‌شده، متغیرهایی مانند نرخ‌های تورم و ارز، تأثیر معنی‌داری بر احتمال رخداد حباب‌های قیمتی در بازارهای مالی دارد و به دنبال واردکردن یک شوک به آن‌ها، شاخص سهام دارای حباب می‌شود (Nabavichashmi & Mahjoub, 2021; Mohammadporzarandi et al., 2022). با بررسی عوامل مؤثر بر رفتار سرمایه‌گذاران قبل و بعد از حباب قیمت سهام در بورس تهران، یافته‌ها نشان می‌دهد که در زمان تشکیل حباب، تعداد معاملات و ارزش معاملات افزایش می‌یابد و از طرف دیگر در زمان ریزش حباب قیمت رابطهٔ معکوسی وجود دارد (Asim, 2020). مدل برآورد احتمال ایجاد حباب قیمتی و بررسی عوامل مؤثر نشان می‌دهد که متغیرهایی مانند ترکیب سهام‌داران، نسبت قیمت به سود و سرعت نقدشوندگی دارای اثری معنی‌دار بر حباب قیمتی است (Torabi et al., 2020). نسبت قیمت به سود هر سهم به‌طور مثبت با تغییرات قیمت سهام در دورهٔ گذشته تغییر می‌کند که تأکیدی است بر اینکه افزایش سریع و حباب‌های قیمتی سهام با فروپاشی‌های بازار مرتبط است (Abbasian et al., 2016). بررسی تأثیر ویژگی‌های بازاری در پیش‌بینی 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 حباب‌های قیمتی و ایجاد نوسان در بورس نقش مهم‌تری بازی می‌کند (Rahnamaroodposhti et al., 2020). بازار سهام ایران در برخی از دوره‌ها درگیر حباب قیمتی بوده است و شوک نرخ بهره و نقدینگی بر تقویت آن مؤثر بوده‌اند (Hadizadeh et al., 2023). نسبت قیمت طلا به پلاتین در تشخیص شکل‌گیری حباب‌ها در بازارهای سهام در مقیاس‌های زمانی مختلف کمک کرده است (Demirer et al., 2024). قیمت کالاهای پایه می‌تواند به‌عنوان شاخص پیشرو برای تورم (متغیر مؤثر بر حباب) استفاده شود (Boughton & Branson, 1988; Moosa, 1998). شاخص خشک بالتیک[1] نیز به‌عنوان شاخص پیشرو به‌طور چشمگیری بر شاخص‌های کلان اقتصادی و تورم در سال‌های اخیر به دلیل افزایش عدم قطعیت‌های اقتصادی به‌ویژه در دوره‌های شوک‌های اقتصادی تأثیرگذار بوده است (Tarkun, 2025). این شاخص به‌عنوان شاخص کوتاه‌مدت بر بازارهای کالا، ارز و سهام به‌ویژه در دوران بحران‌های مالی اثرگذار بوده است (Lin et al., 2019).

پژوهشگران مالی از روش‌های متعددی در حوزهٔ یادگیری ماشینی نظیر محاسبات تکاملی[2] و شبکهٔ عصبی مصنوعی برای بررسی داده‌های سری زمانی استفاده کرده‌اند. در یادگیری ماشینی ازطریق به‌کارگیری یک سری از الگوریتم‌های خاص سعی می‌شود تا الگوهای پنهان بین داده‌ها کشف شود. درصورتی‌که تعداد متغیرهای مستقل و وابسته زیاد باشد و بین آن‌ها ارتباط خطی برقرار نباشد، این روش در زمرهٔ بهترین گزینه‌ها برای پیش‌بینی است. الگوریتم‌های یادگیری عمیق توانسته‌اند در مدل‌های یادگیری ماشین با توانمندسازی الگوریتم‌ها سرعت و دقت بیشتری ایجاد کنند. توسعهٔ سریع آن، مطالعات زیادی را در حل مسائل اقتصادی به‌ویژه برای پیش‌بینی بازار دارایی‌ها به سمت خود جلب کرده است (Khaliliaraghi et al., 2022).

روش‌های یادگیری ماشین به‌طور فزاینده‌ای به‌عنوان راه‌حلی امیدوارکننده، توجه پژوهشگران را برای مطالعه و پژوهش طیف گسترده‌ای از مسائل مربوط به پیش‌بینی همچون بحران‌های مالی، عدم پرداخت بدهی و پیش‌بینی قیمت‌های سهام جلب کرده است. براساس این مطالعات، الگوریتم‌های یادگیری ماشین نتایج بهتری در مقایسه با مدل‌های آماری کلاسیک در مسائل طبقه‌بندی و رگرسیون سری زمانی از خود نشان داده‌اند؛ بااین‌حال، توجه به این نکته مهم است که نتایج پیش‌بینی می‌تواند به‌طور چشمگیری در بین مدل‌ها باتوجه‌به مجموعه داده‌های استفاده‌شده متفاوت باشد و هیچ رویکرد یکسانی وجود ندارد که بتواند عملکرد برتر را تضمین کند (Tran et al., 2023). نمکی و همکاران (Namaki et al., 2023) در بررسی جامع پایگاه‌های

1. Baltic Dry Index (BDI)
2. Evolutionary Computations (ECs)

اطلاعاتی دانشگاهی ضمن بیان اهمیت فزایندهٔ سیستم‌های هشدار سریع در ادبیات و پژوهش‌های مالی نشان داده‌اند که پژوهش‌های اخیر به سمت روش‌ها و الگوریتم‌های یادگیری ماشین تغییر کرده است و این سیستم‌ها دائماً درحال تکامل است. بیشترین زمینهٔ پژوهشی این سیستم‌ها در این بررسی عبارت‌اند از: بحران‌های بانکی، ارزی، پیش‌بینی ورشکستگی و پیش‌بینی با روش‌های یادگیری ماشین.

با بررسی پژوهش‌ها مشاهده شده است که در موضوع حباب، بیشتر پژوهش‌ها متمرکز بر آزمون‌های شناسایی حباب، بررسی وجود و عوامل مؤثر بر شکل‌گیری آن‌ها بوده و پژوهش‌های اندکی در رابطه با پیش‌بینی حباب‌های قیمتی صورت گرفته است. در موضوع سیستم هشدار سریع نیز پژوهش‌ها درزمینهٔ بحران‌های مالی یا بررسی شاخص‌های هشداردهنده بوده و در سایر زمینه‌ها همچون پیش‌بینی حباب‌های قیمتی سهام مطالعاتی صورت نگرفته است. همچنین، استفاده از یادگیری عمیق نیز یک رویکرد نوآورانه در این دو زمینه است؛ بنابراین، ضرورت وجود یک مدل، سیستم یا برنامه‌ای اهمیت می‌یابد که با شناسایی سریع نشانه‌های شکل‌گیری حباب‌ها و پیش‌بینی به‌هنگامِ حباب‌های قیمتی به‌عنوان یک ریسک بالقوه بتواند هشدار مناسبی دراین‌خصوص به سرمایه‌گذاران، سیاست‌گذاران، نهادهای نظارتی و اجرایی بدهد؛ ازاین‌رو پژوهش حاضر بر آن است تا دوره‌های حبابی شاخص‌های منتخب بورس تهران را شناسایی و ارزیابی کند و با لحاظ تغییرات قیمتی (بازدهٔ لگاریتمی) مجموعه‌ای از متغیرهای مستقل به‌عنوان شاخص‌های هشداردهنده به طراحی سیستمی برای پیش‌بینی حباب با مدل شبکه‌های عصبی برگشتی رهیافت حافظهٔ کوتاه‌مدت طولانی (یادگیری عمیق) بپردازد و سپس نتایج آن را ازنظر دقت و کیفیت با مدل رگرسیون لجستیک (به‌عنوان مدل کلاسیک یادگیری ماشین) مقایسه کند؛ علاوه‌براین، اهداف این پژوهش به دنبال پاسخی به این سؤال است که آیا استفاده از رویکرد یادگیری عمیق باعث بهبود دقت و کیفیت پیش‌بینی حباب‌ها در همهٔ شاخص‌های منتخب این پژوهش خواهد شد.

در ادامه به‌منظور تحقق اهداف پژوهش، ساختار مقاله به‌گونه‌ای ساماندهی شده است که در ابتدا مبانی نظری و تجربی در راستای موضوع پژوهش بررسی شده است. در بخش بعد، روش‌شناسی پژوهش و مدل‌های استفاده‌شده معرفی می‌شود؛ درنهایت یافته‌ها و نتایج به‌دست‌آمده به تفصیل بیان و پیشنهادات سیاستی، محدودیت‌ها و منابع مقاله ذکر شده است.

مبانی نظری

مک‌کوین و ثورلی (McQueen & Thorley, 1994) بیان داشتند که در بازار دارایی مالی، چهار نوع حباب قیمتی شامل حباب‌های عقلایی[1]، ذاتی[2]، رفتاری[3] و اطّلاعاتی می‌تواند به وجود آید. همچنین، بسیاری از محققان ازجمله شربینا و شلوشه (Scherbina & Schlusche, 2013) با بررسی ادبیات گذشته تلاش کردند با هدف ارائهٔ رویکرد استاندارد و ساختاریافته، مدل‌های نظری حباب را به دو گروه کلی حباب‌های عقلایی و حباب‌های رفتاری دسته‌بندی کنند. از این منظر، حباب‌های عقلایی را می‌توان به انواع تقارن اطلاعاتی، عدم تقارن اطلاعاتی، حباب ذاتی و عامل بنیان[4] دسته‌بندی کرد. حباب‌های عقلایی به دنبال توضیح و بیان رفتار انفجاری قیمت دارایی‌های مالی با فرض رفتار عقلایی تمام سرمایه‌گذاران و براساس انتظارات آن‌ها از درآمدهای آتی و کارابودن بازارها است. همچنین، حباب‌های رفتاری با انواع مدل‌های مبتنی‌بر اختلاف‌نظر[5]، معاملات

1. Rational Bubbles
2. Intrinsic Bubbles
3. Fads Bubbles
4. Agency-Based Models
5. Disagreement-Based Bubble Models

بازخوردی[۱]، سوگیری خوداسنادی[۲] و سوگیری نمایندگی و محافظه‌کاری[۳] بر سوگیری‌های روان‌شناسانه برای توضیح حباب‌ها تکیه دارد.

هدف ادبیات تجربی حباب، توسعهٔ سازوکارهایی برای شناسایی منشأ، پایان و میزان رفتار انفجاری در قیمت دارایی‌ها براساس معیارهای کمّی واضح و روشن است. آزمون‌های شناسایی تجربی حباب‌ها به دو گروه کلّی روش‌های اقتصادسنجی اولیه و روش‌های اقتصادسنجی پیشرفته تقسیم می‌شود. پژوهش‌های اولیه دربارهٔ شناسایی تجربی حباب‌ها به دههٔ ۱۹۸۰ و اوایل دههٔ ۱۹۹۰ برمی‌گردد. فرومل و کروس (Frommel & Kruse, 2012) سه نوع مدل را در گروه روش‌های اقتصادسنجی اولیه قرار می‌دهند که شامل آزمون‌های کران واریانس شیلر[۴]، آزمون‌های دومرحله‌ای وست[۵] و آزمون‌های مانایی استاندارد و هم‌انباشتگی[۶] است. مروری بر آزمون‌های اقتصادسنجی اولیه نشان می‌دهد که این روش‌های شناسایی کشف حباب، نتایج نامطلوبی ارائه می‌دهد. رویکردهای مختلف هنگامی که برای مجموعهٔ داده‌های مشابه اعمال می‌شود، نه‌تنها به نتیجه‌گیری‌های متفاوتی منجر می‌شود، بلکه بسیاری از آن‌ها دارای ضعف‌هایی همچون توان کم و اعوجاجِ اندازه است (Wockl, 2019).

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؛ بااین‌حال، بحران مالی جهانی ۲۰۰۷–۲۰۰۸، علاقهٔ اقتصاددلنان تجربی را به حباب قیمت دارایی‌ها و پیامدهای بالقوهٔ جهانی آن دوباره احیا و درعین‌حال فضایی غنی برای پژوهش‌های تجربی بیشتر فراهم کرد (Phillips et al., 2011). پژوهش‌های اخیر عمدتاً بر روی روش‌های مانایی پیشرفته و مبتنی‌بر هم‌انباشتگی برای تشخیص مراحل رونق و سرخوشی در بازارهای مالی متمرکز شده است. این آزمون‌ها مبتنی‌بر متغیرهای بنیادی نیست و بر سری زمانی قیمت دارایی‌ها تمرکز دارد. یکی از روش‌های مانایی پیشرفته و مبتنی‌بر هم‌انباشتگی که کاربرد روش‌های شناسایی حباب در سری‌های زمانی با حباب‌های درحال فروپاشی دوره‌ای را تا حد زیادی ارتقا داده است، آزمون‌های ریشهٔ واحد بازگشتی است که برای اولین بار توسط فیلیپس و همکاران (Phillips et al., 2011) ایجاد و سپس اصلاح شد و بهبود پیدا کرد. در این آزمون‌ها، حباب‌ها با یافتن زیرنمونه‌هایی شناسایی می‌شود که رفتار انفجاری مشخصی دارد. باتوجه‌به ماهیت بازگشتی آن‌ها، این آزمون‌ها قادرند حباب‌های درحال فروپاشی دوره‌ای را از فرایندهای ریشهٔ واحد کامل تشخیص دهند و به آن‌ها مزیت مشخصی در مقایسه با آزمون‌های مانایی استاندارد و مبتنی‌بر هم‌انباشتگی می‌دهد. هنگامی که یک حباب در سری زمانی وجود دارد، داده‌ها ممکن است با رفتار انفجاری خفیف[۷] مشخص شود. این رفتار انفجاری خفیف را می‌توان با فرایند خودهمبسته[۸] با ریشه‌ای فراتر، اما همچنان نزدیک به ریشهٔ واحد مدل‌سازی کرد (Bohl et al., 2013). این آزمون‌ها به دو گروه تقسیم می‌شود:

گروه اول، آزمون سوپریمم دیکی‌فولر تعمیم‌یافته[۹] است که به‌عنوان روش فیلیپس، وو و یو[۱۰] (Phillips et al., 2011) نیز شناخته شده و مبتنی‌بر آزمون‌های دیکی‌فولر بازگشتی راست‌دم[۱۱] است. این آزمون را فیلیپس و همکاران (Phillips et al., 2011) به‌منظور

1. Feedback Trading
2. Biased Self-Attribution
3. Representative Heuristic and Conservatism Bias
4. Variance Bounds Tests
5. West (1987) Two-Step Tests
6. Standard Stationary and Cointegration-Based Tests
7. Mildly Explosive Behavior
8. Autoregressive Process
9. Sup Augmented Dickey-Fuller (SADF)
10. PWY Method
11. Recursive right-tailed ADF Tests

برطرف‌کردن انتقاد اوانس[1] و سایر ایرادهای وارد به روش‌های پیشینِ کشف و ارزیابیِ وجود حباب‌های قیمتی در بازارهای مالی به‌خصوص آزمون‌های متعارف ریشهٔ واحد دیکی‌فولر و هم‌انباشتگی پیشنهاد دادند. آن‌ها سرخوشی مالی[2] را برحسب رفتارِ خودهمبستهٔ انفجاری تعریف و شواهد تجربی سرخوشی قیمت را با کمک آزمون‌های رگرسیون بازگشتی پیشرو[3] ارزیابی کردند. هوم و بریتلنگ (Homm & Breitung, 2012) دریافتند که این آزمون‌ها بهینه‌ترین روش در بین روش‌های به‌کاررفته است. آن‌ها نشان دادند که این روش به‌عنوان سازوکار شناسایی شکست‌های ساختاری[4] عملکرد رضایت‌بخشی دارد.

این روش دارای این مزیت است که ضمن آزمون فرضیهٔ رفتار انفجاری در قیمت، به‌طور 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 افزایش در قیمت دارایی‌ها را در دوره‌های تورمی دارد؛ بااین‌حال، همان‌طور که فیلیپس و همکاران (Phillips et al., 2015) نشان دادند، این آزمون دارای یک محدودیت مهم است و آن اینکه برای تجزیه‌وتحلیل یک دورهٔ حبابیِ منفرد مناسب و مؤثر است؛ درحالی‌که در کاربردهای عملی و بسیاری از سری‌های زمانی ممکن است حباب‌های متعددی در نمونه‌های به اندازهٔ کافی بزرگ ظاهر شود. این روش، حباب‌های تاریخی معروف را با موفقیت شناسایی کرد؛ درحالی‌که نتوانست حباب بحران بدهی ۲۰۰۷–۲۰۰۸ را شناسایی کند.

گروه دوم، آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته[5] است که به‌عنوان روش فیلیپس، شی و یو[6] (Phillips et al., 2015) نیز شناخته شده است. فیلیپس و همکاران (Phillips et al., 2015) این آزمون را برای داده‌های ماهانهٔ سهام S&P 500 از سال ۱۸۷۱ تا ۲۰۱۰ به کار بردند و با تعمیم روش‌شناسی به‌منظور غلبه بر محدودیت‌های آزمون قبل، برای شناسایی حباب‌های چندگانه پیشنهاد دادند. آن‌ها توانستند با موفقیت، دوره‌های حبابی تاریخیِ بنام و شناخته‌شده را شناسایی کنند. در فرایند جدید از عرضِ پنجره‌های انعطاف‌پذیر در رگرسیون‌های بازگشتی[7] استفاده می‌شود. این تغییر به‌طور چشمگیری قدرت تمایز و تشخیص را در زمانی بهبود می‌بخشد که حباب‌های چندگانه در داده‌ها رخ می‌دهد؛ بنابراین، بر ضعف روش فیلیپس، وو و یو (Phillips et al., 2011) غلبه می‌کند و برای دوره‌های حباب‌های چندگانه، سرخوشی و فروپاشی بسیار مناسب‌تر است و باعث می‌شود در بررسی سری‌های زمانی طولانی تاریخی کاربرد بیشتری داشته باشد. 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 و بر ضعف‌های کاربردهای قبلی آزمون ریشهٔ واحد برای حباب‌های اقتصادی غلبه می‌کند.

بعد از بحران مالی کشورهای شرق آسیا در سال ۱۹۹۷–۱۹۹۸، نیاز به مدلی که بتواند بحران را قبل از وقوع آن تشخیص دهد و بتواند سیاست‌گذاران را از وقوع آن آگاه سازد، بیش‌ازپیش ضروری به نظر می‌رسید؛ ازاین‌رو، موضوعی به نام سیستم‌های هشدار سریع، وارد ادبیات بحران‌های مالی شد. این سیستم‌ها می‌توانند بحران را قبل از وقوع شناسایی و سیگنال مناسب را برای جلوگیری از وقوع یا کاستن اثرات آن صادر کنند (Sayadniatayebi et al., 2011). هدف از این سیستم‌ها آن است که علائم هشداردهندهٔ اولیه، مشکلات مالی را ارائه دهند تا سیاست‌گذاران و بازیگران بازار قبل از گسترش بحران، اقدامات لازم را انجام دهند (Claessens & Kose, 2013).

پژوهش‌های اولیه درزمینهٔ سیستم‌های هشدار سریع در حوزهٔ مالی عمدتاً به ایجاد مدل‌های اقتصادسنجی برای پیش‌بینی بحران‌های مالی مربوط می‌شد. این سیستم‌ها باتوجه‌به توان و ظرفیت خود در ارائهٔ هشدارهای اولیهٔ مرتبط با تهدیدات بالقوه

1. Evans' Critique
2. Financial Exuberance
3. Forward Recursive Regression Tests
4. Structural Break
5. The Generalized Sup Augmented Dickey-Fuller (GSADF)
6. PSY Method
7. Recursive Regressions

در صنایع مختلف، اخیراً توجه زیادی را به خود جلب کرده است. مدیریت ریسک اعتباری، تجزیه‌وتحلیل بازار سهام و سقوط‌های قریب‌الوقوع بازار، انتقال ریسک مالی، نظارت بانکی، مدیریت ریسک بازار، بیمه، نظارت و کشف تقلب و کلاهبرداری‌ها، نظارت بر رفتار بیمه‌گذاران، ارزیابی ریسک سبد وام، شناسایی نکول‌های احتمالی و ریسک‌های بالقوه تعدادی از حوزه‌های صنعت مالی هستند که سیستم هشدار سریع در آن‌ها به کار رفته است. پژوهشگران اخیراً به دلیل پیشرفت در روش‌های جمع‌آوری و تجزیه‌وتحلیل داده‌ها توانسته‌اند مدل‌های پیچیده‌تری از سیستم‌های هشدار سریع ایجاد کنند که تجزیه‌وتحلیل مبتنی‌بر شبکه، الگوریتم‌های یادگیری ماشین و تجزیه‌وتحلیل داده‌های بزرگ را ترکیب می‌کنند (Wever et al., 2022).

سیستم هشدار سریع، تابعی را تعریف می‌کند که شاخص‌های مختلفی را به وقوع اهداف مدنظر پیوند می‌دهد؛ درحالی‌که ارزیابی سیستم‌های هشدار سریع شامل روش‌هایی است که به ارزیابی اعتبار مدل‌های هشدار سریع منتهی می‌شود. با این شرایط، تصریح تکنیکی مدل سیستم هشدار سریع نیازمند سه عنصر است: الف) شناسایی و تعیین هدف و سپس بررسی دلایل آن، ب) انتخاب مجموعه‌ای از شاخص‌های هشداردهندهٔ سیستم هشدار سریع[1] با مراجعه به علائم پررنگ در گام اول به‌عنوان متغیرهای توضیحی مدل است که در ادبیات مربوط، راه‌هایی ازقبیل استفاده از نظریهٔ اقتصادی، مالی یا رویکرد داده‌کاوی دراین‌خصوص مطرح است. ج) یک تابعی بین این شاخص‌های هشداردهنده و احتمالات وقوع هدف، اینکه چگونه می‌توان از روی حرکت شاخص‌های هشداردهنده، وقوع هدف را پیش‌بینی کرد. شاخص‌های هشداردهندهٔ سیستم متغیرهایی هستند که تغییرات در آن‌ها می‌تواند هشداری بر وقوع هدف در آینده باشد. این شاخص‌ها شامل طیف وسیعی از متغیرها و شاخص‌های کلان اقتصادی و مالی است که در مطالعات مختلف در سال‌های اخیر بررسی و برای پیش‌بینی و درک روندها در بخش‌های حقیقی، پولی و خارجی اقتصاد به کار گرفته شده است. شاخص‌های کلان اقتصادی به سه گروه تقسیم می‌شود: ۱) شاخص‌های پیشرو[2] اولین شاخص‌هایی است که نشان‌دهندهٔ بروز تغییرات اقتصادی است؛ به‌عبارت‌دیگر، با مشاهدهٔ تغییرات در شاخص‌های پیشرو انتظار می‌رود تغییراتی در مجموعهٔ فعالیت‌های اقتصادی بروز یابد؛ مانند عرضهٔ کل پول[3]، شاخص قیمت مواد خام[4]، منحنی بازدهی[5]، شاخص مدیران خرید[6]؛ ۲) شاخص‌های هم‌زمان[7] شامل شاخص‌هایی است که پس از بروز تغییرات در شاخص‌های پیشرو شروع به تغییر می‌کند. درآمد شخصی[8]، تولیدات بخش‌ها، آمار خرده‌فروشی[9]، شاخص قیمت تولیدکننده[10] و تولید ناخالص ملی[11] از این دسته‌اند؛ ۳) شاخص‌های پسرو[12](تأخیری) شامل شاخص‌هایی است که بروز تغییرات در آن‌ها پس از بروز تغییر در سایر بخش‌های اقتصادی به وقوع می‌پیوندد؛ مانند نرخ بیکاری[13]، شاخص قیمت مصرف‌کننده[14]، سرمایه‌گذاری در ماشین‌آلات و تجهیزات و نرخ‌های بهرهٔ بانکی (Sayadniatayebi et al., 2011). روش‌های معمول پیش‌بینی در سیستم هشدار سریع در ادبیات مربوط، شامل روش سیگنالی یا استخراج علائم، رویکرد لاجیت و پروبیت، روش مارکوف سوئیچینگ و شبکه‌های عصبی مصنوعی است (Nasrollahi et al., 2017).

1. Early Warning System Indicators
2. Leading Indicators
3. The Overall Money Supply
4. The Raw Materials Price Index (RMPI)
5. Yield Curve
6. Purchasing Managers' Index (PMI)
7. Coincident Indicators
8. Personal Income
9. Retail Sales
10. Producer Price Index (PPI)
11. Gross National Product (GNP)
12. Lagging Indicators
13. Unemployment Rate
14. Consumer Price Index (CPI)

مروری بر مبانی نظری و پیشینهٔ پژوهش‌ها در حوزهٔ حباب‌های قیمتی نشان می‌دهد که آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته، بسیار قوی‌تر از سایر روش‌های پژوهش می‌تواند دوره‌های حبابی را مشخص کند. درواقع، این آزمون علاوه‌بر شناسایی حباب در بازهٔ طولانی‌مدت، رفتارهای انفجاری را در بین این بازه‌ها می‌تواند شناسایی کند (Sadeghisharif et al., 2017). همچنین، بررسی‌ها نشان می‌دهد که بیشتر پژوهش‌ها در این حوزه بر شناسایی و آزمون وجود حباب در دوره‌های مختلف و بازارهای متنوع و عوامل مؤثر بر شکل‌گیری آن‌ها تمرکز داشته است و پژوهش‌های محدودی درزمینهٔ پیش‌بینی حباب انجام شده است. مروری بر پیشینهٔ پژوهش‌ها در سیستم‌های هشدار سریع نیز نشان می‌دهد که پژوهش‌های بسیار محدودی درزمینهٔ سیستم‌های هشدار سریع برای پیش‌بینی حباب‌های مالی انجام شده است و این در حالی است که بیشترین زمینهٔ پژوهشی این سیستم‌ها عبارت‌اند از: بحران‌های بانکی، ارزی، پیش‌بینی ورشکستگی و سایر پیش‌بینی‌ها با روش‌های یادگیری ماشین. هرکدام از این زمینه‌های پژوهشی، دیدگاه‌های متمایزی را دربارهٔ رویکردها و روش‌های استفاده‌شده برای سیستم‌های هشدار سریع ارائه می‌دهد. این پژوهش‌ها بر اهمیت ترکیب متغیرهای استفاده‌شده در مدل‌های سیستم‌های هشدار سریع و سایر داده‌های دیگر به منظور بهبود دقت پیش‌بینی‌ها تأکید می‌کند (Namaki et al., 2023). در این پژوهش با بهره‌بردن از نتایج آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته و داده‌های اقتصادی و مالی به‌عنوان شاخص‌های هشداردهنده، یک سیستم هشدار سریع برای پیش‌بینی حباب‌های شاخص‌های منتخب بورس تهران با رویکرد یادگیری عمیق طراحی و ارزیابی شد.

روش پژوهش

متغیرهای هدف با بررسی‌های تطبیقی انجام‌شده در این پژوهش، ۵ شاخص منتخب بورس تهران (شاخص کل، شاخص ۵۰ شرکت فعال‌تر، شاخص صنعت، شاخص مالی و شاخص فلزات اساسی) انتخاب شدند. در ادامه، داده‌های ماهانهٔ این شاخص‌های منتخب طی سال‌های ۱۳۸۱ تا ۱۴۰۲ استخراج و سپس به شناسایی دوره‌های حبابی توسط آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته (GSADF) و استخراج سیگنال حباب و ایجاد متغیر مجازی حباب پرداخته شد و آن‌ها به‌عنوان متغیرهای هدف «وابسته» در نظر گرفته شدند. سپس براساس پژوهش‌های گذشته، از داده‌های ۱۸ متغیر مهم و اثرگذار بر بازار سهام و حباب‌های قیمتی با لحاظ تغییرات قیمتی (بازدهٔ لگاریتمی) مطابق جدول (۱) که از میان اطلاعات متغیرهای کلان اقتصادی، اطلاعات بازار، ضریب‌های ارزش‌گذاری و قیمت کالاها استخراج شدند، به‌عنوان متغیرهای مستقل «شاخص‌های هشداردهنده» استفاده شد. این متغیرها به دلیل ماهیت سری زمانی پس از اعمال وقفهٔ ۵ دوره‌ای و نرمال‌سازی به‌عنوان ویژگی‌های ورودی در مدل‌ها استفاده شدند. نقش این متغیرها در تقویت قدرت پیش‌بینی مدل‌ها به‌صورت غیرمستقیم و ازطریق نتایج عملکرد ارزیابی می‌شود. در گام بعد، به مدل‌سازی پیش‌بینی متغیر حباب به‌منظور طراحی سیستم هشدار سریع پرداخته شد. این هدف با به‌کارگیری شبکه‌های عصبی برگشتی رهیافت حافظهٔ کوتاه‌مدت طولانی (LSTM)، به‌عنوان یک مدل یادگیری عمیق و رگرسیون لجستیک (LR) به‌عنوان یک مدل کلاسیک یادگیری ماشین انجام شد؛ درنهایت، ارزیابی عملکرد نتایج حاصل‌شده براساس مدل‌های به‌کاررفته و نوع شاخص منتخب بورسی براساس شاخص‌هایی چون دقت پیش‌بینی[1]، مساحت زیر منحنی مشخصهٔ عملکرد گیرنده[2] و ماتریس درهم‌ریختگی[3] انجام شد تا عملکرد مدل‌ها از منظر پیش‌بینی‌پذیری قابل‌ارزیابی و مقایسه باشد. این رویکرد مطابق با استانداردهای رایج در تحلیل‌های مبتنی‌بر یادگیری ماشین

1. Accuracy
2. Area Under the Receiver Operating Characteristic Curve (AUC-ROC)
3. Confusion Matrix

است.کلیهٔ متغیرهای استفاده‌شده در این پژوهش در مقیاس کمی و مشاهدات به‌صورت سری زمانی ماهانه از تاریخ ۱۳۸۱/۰۷/۲۹ الی ۱۴۰۲/۰۹/۲۹ به تعداد ۲۵۵ ماه است که ۷۰٪ مشاهدات از تاریخ ۱۳۸۱/۱۲/۲۸ الی ۱۳۹۶/۰۶/۲۹ به‌عنوان مجموعهٔ داده‌های آموزشی (درون‌نمونه‌ای) برای مدل‌سازی حباب قیمتی و ۳۰٪ باقی‌مانده از تاریخ ۱۳۹۶/۰۷/۳۰ الی ۱۴۰۲/۰۹/۲۹ به‌عنوان مجموعهٔ داده‌های آزمایشی (برون‌نمونه‌ای) برای آزمون و ارزیابی مدل در نظر گرفته شده است. کلیهٔ محاسبات لازم در این پژوهش با استفاده از نرم‌افزارهای متن باز R 4.2.1 و پایتون انجام شده است.

جدول (۱): شاخص‌های هشداردهنده «متغیرهای مستقل»

Table (1) Warning indicators "independant variables"

طبقه‌بندی	متغیرهای مستقل	منبع داده‌ها
اقتصاد کلان	شاخص قیمت مصرف‌کننده، شاخص قیمت تولیدکننده، میانگین نرخ بهرهٔ بدون ریسک، نرخ ارز دلار، شاخص بالتیک	بانک مرکزی ایران، Bourseview.com، رهاورد۳۶۵
اطلاعات بازار	ارزش معاملات، حجم معاملات، تعداد معاملات	Bourseview.com
ضریب‌های ارزش‌گذاری[1]	نسبت قیمت به سود هر سهم[2]، نسبت قیمت به فروش هر سهم[3]	Bourseview.com
قیمت کالاها	نفت خام وست تگزاس، سنگ آهن عیار ۶۲٪ چین، شمش آلومینیوم، مس، روی، انس طلا، سکهٔ طلا قدیم، شاخص جهانی کامودیتی	رهاورد۳۶۵، بانک جهانی

در ادبیات اقتصادسنجی شناسایی دوره‌های حبابی در داده‌های سری زمانی چالش بزرگی است. تکنیک‌های اقتصادسنجی بیشتر دچار تورش ناشی از نمونه‌های محدود[4] هستند؛ برای مثال آزمون‌های هم‌انباشتگی و ریشهٔ واحد سنتی توانایی شناسایی تنها یک حباب انفجاری را می‌توانند داشته باشند، اما توانایی شناسایی چندین دورهٔ حبابی را نخواهند داشت؛ زیرا آزمون‌های ریشهٔ واحد سنتی نمی‌توانند تغییرات داده‌ها را از فرایند I(0) به I(1) و دوباره بازگشت به فرایند I(0) را تشخیص دهند و پیگیری کنند. پدیده‌ای که در سری‌های زمانی قیمت به‌ویژه در بازارهای مالی ممکن است (Biabanykhameneh et al., 2016).

در مسیر توسعهٔ روش‌های اقتصادسنجی برای تشخیص بهینهٔ رفتار داده‌ها و آزمون وجود حباب قیمتی، مطالعات بسیاری صورت گرفته است. یکی از نوآوری‌های اخیر در آزمون‌های ریشهٔ واحد توسط فیلیپس و همکاران (Phillips et al., 2015) ازطریق بسط آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته راست‌دنباله ارائه شد. در این روش فرض صفر آزمون این است که سری زمانی قیمت P_t از یک فرایند گام تصادفی به‌صورت رابطهٔ (۱) پیروی می‌کند:

$$P_t = dT^{-\eta} + \theta P_{t-1} + \varepsilon_t \qquad \text{رابطهٔ (۱)}$$

که در آن $\theta = 1$، d جملهٔ ثابت، T اندازهٔ 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 می‌دهد و مدل رگرسیون بازگشتی به‌صورت رابطهٔ (۲) در نظر گرفته می‌شود:

$$\Delta P_t = \alpha_{r_1.r_2} + \beta_{r_1.r_2} P_{t-1} + \sum_{i=1}^{k} \gamma_{r_1.r_2} \Delta P_{t-i} + \varepsilon_t \qquad \text{رابطهٔ (۲)}$$

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

1. Valuation Multiples
2. P/E Ratio
3. P/S Ratio
4. Finite samples

که در آن Δ عملگر تفاضل مرتبهٔ اول و k طول وقفه است. آنگاه آمارهٔ دیکی‌فولر استاندارد به‌صورت رابطهٔ (۳) محاسبه می‌شود:

$$ADF_{r_1.r_2} = \beta_{r_1.r_2}/se(\beta_{r_1.r_2}) \qquad \text{رابطه (۳)}$$

براساس این رویکرد، فرایند شناسایی حباب‌ها به دو گام تقسیم می‌شود: در گام اول با محاسبهٔ آمارهٔ آزمون GSADF حباب‌های قیمتی شناسایی می‌شوند؛ در گام دوم سپس با استفاده از آمارهٔ BSADF[1] دوره‌های شروع و پایان حباب‌های قیمتی شناسایی‌شده تاریخ‌گذاری می‌شوند.

ابتدا آمارهٔ GSADF پس از تغییر نقاط آغازین رگرسیون یعنی r_1 از صفر تا r_2-r_0 و تغییر نقطهٔ پایانی یعنی r_2 از r_0 تا ۱ و تخمین رگرسیون برای تمام حالت‌های ممکن انجام می‌گیرد؛ به‌عبارت‌دیگر آمارهٔ GSADF به‌صورت رابطهٔ (۴) می‌شود:

$$GSADF(r_0) = sup^{r_2\in[r_0,1]}_{r_1\in[0,\ r_2-r_0]}\{ADF_{r_1.r_2}\} \qquad \text{رابطهٔ (۴)}$$

وجود حباب در دنبالهٔ نمونه به‌وسیلهٔ مقایسهٔ آمارهٔ GSADF و مقادیر بحرانی که از یک شبیه‌سازی مونت کارلو محاسبه می‌شود، استنباط‌پذیر است. گام دوم نیز، یعنی محاسبهٔ دنبالهٔ آمارهٔ BSADF با به‌کارگیری آزمون ADF راست‌دنباله بر دنبالهٔ بسط‌یابندهٔ بازگشتی نمونه و مقایسهٔ دنبالهٔ آمارهٔ BSADF با مقادیر بحرانی محاسبه‌شده به روش مونت کارلو انجام می‌شود. در آمارهٔ BSADF، نقطهٔ پایانی نمونه یعنی r_2 ثابت و r_1 از بازهٔ r_2-r_0 تا صفر تغییر می‌کند. این آماره به‌صورت رابطهٔ (۵) آمده است:

$$BSADF_{r_2}(r_0) = sup_{r_1\in[0,r_2-r_0]}\{ADF_{r_1.r_2}\} \qquad \text{رابطهٔ (۵)}$$

با اجازه‌دادن اینکه نقطهٔ پایانی از r_0 تا آخرین مشاهدهٔ نمونه تغییر کند، دنباله‌ای از آماره‌های BSADF به دست آمده است. در این چارچوب، تاریخ‌های شروع و پایان حباب به‌صورت رابطه‌های (۶) و (۷) می‌شود:

$$\widetilde{r_e} = inf_{r_2\in[r_0,1]}\left\{r_2 : BSADF_{r_2}(r_0) > cv^{\beta}_{r_2}\right\} \qquad \text{رابطهٔ (۶)}$$

$$\widetilde{r_f} = inf_{r_2\in[\widetilde{r_e},1]}\left\{r_2 : BSADF_{r_2}(r_0) < cv^{\beta}_{r_2}\right\} \qquad \text{رابطهٔ (۷)}$$

که در آن $cv^{\beta}_{r_2}$ مقدار بحرانی در سطح اطمینان β درصد آماره BSADF است. سپس براساس آزمون BSADF، یک متغیر y_t به‌صورت رابطهٔ (۸) تعریف می‌شود:

$$y_t = \begin{cases} 0. & BSADF_{r_2.t} < cv^{\beta}_{r_2.t} \\ 1. & BSADF_{r_2.t} > cv^{\beta}_{r_2.t} \end{cases} \qquad \text{رابطهٔ (۸)}$$

براین‌اساس اگر در زمان t حباب شناسایی شود، متغیر y در دورهٔ t مقدار ۱ می‌گیرد و درغیراین‌صورت y برابر صفر است؛ بنابراین، متغیر y نشان‌دهندهٔ دوره‌هایی خواهد بود که در شاخص‌های منتخب بورس تهران حباب قیمتی وجود داشته است (Tran et al., 2023).

در ادامهٔ مدل‌های استفاده‌شده در این پژوهش، مدل رگرسیون لجستیک یکی از پرکاربردترین مدل‌ها در حل مسائل یادگیری ماشین از نوع طبقه‌بندی دوکلاسه است که در آن متغیر هدف تابعی خطی از ورودی‌ها به‌صورت رابطهٔ (۹) در نظر گرفته می‌شود.

1. Backward sup ADF

$$y(X) = w^T X + \varepsilon = \sum_{j=1}^{D} w_j x_j + \varepsilon$$ رابطهٔ (۹)

که در آن $\mathrm{w^T X}$ ضرب ماتریسی بین بردار وزن‌ها و ماتریس طرح X است و ε نیز خطای باقی‌مانده میان پیش‌بینی‌کنندهٔ خطی و مقادیر پاسخ صحیح است که y دو مقدار ۰ یا ۱ می‌تواند اختیار کند. برای تشریح ارتباط مدل رگرسیون خطی با توزیع خطاها می‌توان مدل را به‌صورت رابطهٔ (۱۰) بازنویسی کرد:

$$P(y|X.\theta) = N\big(y|\mu(X).\sigma^2(X)\big)$$ رابطهٔ (۱۰)

رابطهٔ (۱۰) نشان‌دهندهٔ این موضوع است که مدل رگرسیون لجستیک از یک تابع چگالی شرطی پیروی می‌کند. در ساده‌ترین حالت $\mu(X)$ یک تابع خطی از X در نظر گرفته می‌شود؛ 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 $w.\sigma^2$ است؛ برای مثال در نظر گرفته شود تنها یک متغیر ورودی در اختیار است که در این حالت:

$$\mu(X) = w_0 + w_1 x = w^T X$$ رابطهٔ (۱۱)

که w_0 معمولاً عرض از مبدأ یا bias و w_1 نیز شیب خط نامیده می‌شود؛ بنابراین، ماتریس طرح به‌صورت $X = \begin{bmatrix} 1 & x_{11} \\ \vdots & \vdots \\ 1 & x_{N1} \end{bmatrix}$ در می‌آید. اگر مقدار w_1 مثبت باشد، انتظار است تا تغییرات متغیر ورودی یا مستقل بر روی متغیر پاسخ یا هدف از نوع مستقیم و مثبت باشد.

در یادگیری ماشین برخلاف رویکرد آمار کلاسیک از استنباط بر روی ضرایب برآوردی پرهیز می‌شود و به‌منظور برآورد پارامترها از سازوکاری با نام یادگیری استفاده می‌شود. سازوکار یادگیری عملیاتی تکرارشونده است که با به‌کارگیری الگوریتم بهینه‌ساز و تابع زیان، تلاش در کمینه‌سازی تابع زیان می‌شود. ضرایب برآوردی حاصل از این سازوکار اصطلاحاً اوزان یا ضرایب یادگرفته‌شده نامیده می‌شود. این در حالی است که در آمار کلاسیک معمولاً این ضرایب توسط روش‌هایی نظیر حداقل مربعات یا حداکثر درست‌نمایی برآورد می‌شود و استنباط روی آنان صورت می‌گیرد. سازوکار یادگیری به این صورت است که ابتدا تابع زیان تعریف می‌شود و سپس با به‌کارگیری الگوریتم بهینه‌ساز اقدام به کمینه‌سازی این تابع می‌شود؛ برای مثال در مسئلهٔ رگرسیون لجستیک، تابع زیان منفی لگاریتم تابع درست‌نمایی توزیع برنولی در نظر گرفته می‌شود که تابعی محدّب است. سپس از الگوریتم گرادیان کاهشی برای کمینه‌سازی این تابع به‌صورت رابطهٔ (۱۲) استفاده می‌شود:

$$J(w) = -l(w) = -\left(\sum_{i=1}^{n} y_i \log\big(g_w(x)\big) + (1-y_i)\log\left(1 - g_w(x)\right)\right)$$ رابطهٔ (۱۲)

هدف به دست آوردن مقادیر w به‌گونه‌ای است که تابع زیان درجهٔ دوم کمینه شود؛ بدین منظور مطابق الگوریتم گرادیان کاهشی، ابتدا مقادیری تصادفی اولیه برای w در نظر گرفته می‌شود وگرادیان‌های تابع زیان رابطهٔ (۱۲) به دست می‌آید. سپس در خلاف جهت گرادیان به اندازهٔ نرخ یادگیری به‌صورت رابطهٔ (۱۳) پیش می‌رود:

رابطهٔ (۱۳)

Initial values randomly for w
Repeat until coverage:

$$w_j = w_j - \alpha \frac{\partial}{\partial w_j} J(w)$$

در رابطهٔ (۱۳)، α نرخ یادگیری و $\frac{\partial}{\partial w_j}J(w)$ مقدار گرادیان یا همان مشتق برداری است.

همان‌طورکه گفته شد، رویکرد اصلی در یادگیری ماشین پیش‌بینی متغیر هدف براساس متغیرهای ورودی یا ویژگی‌ها است و ضرایب براساس سازوکار یادگیری و خطا به‌گونه‌ای برآورد می‌شود که بیشترین دقت را در جهت پیش‌بینی متغیر هدف داشته باشد (Fallah et al., 2024).

در ادامهٔ بررسی مدل‌های استفاده‌شده در این پژوهش، شبکه‌های حافظهٔ کوتاه‌مدت طولانی نسخه‌ای جدیدتر از شبکه‌های عصبی برگشتی هستند که درزمینهٔ یادگیری عمیق استفاده می‌شود. این رویکرد نه‌تنها مانند رویکردهای کلاسیک شبکهٔ عصبی (بازخوردی) نقاط داده–واحد را پردازش می‌کند، بلکه می‌تواند توالی داده‌ها را نیز پردازش کند. این رویکرد پردازش داده‌های توالی با طول‌های دلخواه را ازطریق یک بردار مخفی امکان‌پذیر می‌کند و یادگیری وابستگی بین داده‌های راه دور را به‌وسیلهٔ معرفی یک سلول حافظه بهبود می‌بخشد.

این شبکه‌ها توسط سازوکارهای کنترلی با عنوان دروازه سبب حل مشکل محو گرادیان و بهبود کارایی شبکه می‌شوند؛ بنابراین، این شبکه‌ها علاوه‌بر درک روابط غیرخطی داده‌ها، اطلاعات گذشته را نیز در حافظهٔ خود دارند. عبارت حافظهٔ کوتاه‌مدت طولانی از این جهت است که در این شبکه‌ها، حافظه کوتاه‌مدت است، ولی 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 حافظهٔ سیستم وجود دارد. نخستین بار این ساختار جدید از شبکه‌های برگشتی را هوکرایتر و اشمیدوبر (Hochreiter & Schmidhuber, 1997) ارائه کردند. اولین تفاوت در شبکه‌های LSTM در مقایسه با شبکه‌های RNN ساده اضافه‌شدن یک بردار حافظهٔ دیگر است که با C_t آن را نشان می‌دهند؛ یعنی علاوه‌بر h_t یک عامل حافظهٔ دیگر مانند C_t نیز وجود دارد. همان‌طورکه ذکر شد، تفاوت عمدهٔ شبکه‌های LSTM با شبکه‌های RNN ساده، استفاده از سازوکاری با عنوان دروازه برای کنترل حافظهٔ اطلاعات است. سه دروازهٔ اصلی برای این‌کار وجود دارد: دروازهٔ ورودی، دروازهٔ فراموشی و دروازهٔ خروجی. شکل (۱) یک سلول LSTM را به‌طور شماتیک و رابطه‌های (۱۴) تا (۱۹)، معادلات مربوط را نشان می‌دهد (Landi et al., 2021).

$$f_t = \sigma\left(W_f . [h_{t-1}, x_t] + b_f\right) \quad \text{رابطهٔ (۱۴)}$$

$$i_t = \sigma(W_i\ [h_{t-1},\ x_t] + b_i) \quad \text{رابطهٔ (۱۵)}$$

$$\tilde{C}_t = tanh(W_c . [h_{t-1}, x_t] + b_c) \quad \text{رابطهٔ (۱۶)}$$

$$C_t = f_t \odot C_{t-1} \ \oplus\ i_t \odot \tilde{C}_t \quad \text{رابطهٔ (۱۷)}$$

$$o_t = \sigma\left(W_o . [h_{t-1}, x_t] + b_o\right) \quad \text{رابطهٔ (۱۸)}$$

$$h_t = o_t \odot tanh\left(C_t\right) \quad \text{رابطهٔ (۱۹)}$$

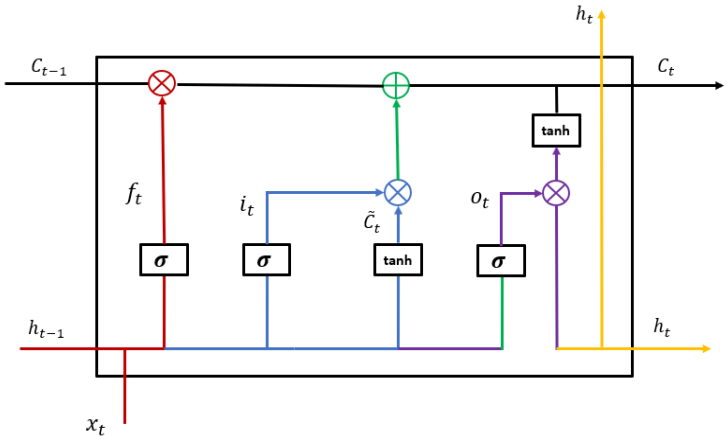

شکل (۱): طرحی از ساختار یک سلول حافظهٔ کوتاه‌مدت طولانی (Abolmakarem et al., 2024)

Figure (1) A diagram of the structure of Long Short-term Memory (Abolmakarem et al., 2024)

ازآنجایی‌که مدل شـــبکهٔ عصـــبی عمیق می‌تواند هم‌زمان چند ورودی و چند خروجی را دریافت و پردازش کند، معماری شبکه در این پژوهش به‌صورت شکل (۲) است. در ادامه، تنظیمات ابر پارامترهای استفاده‌شده در این پژوهش از جدول (۲) مشاهده می‌شود:

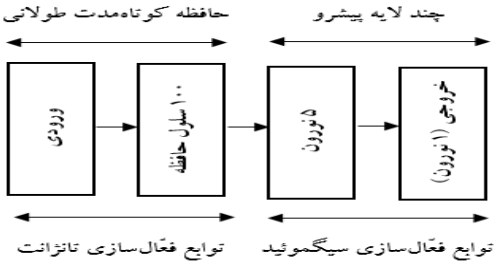

شکل (۲): معماری شبکهٔ عصبی عمیق ترکیبی متشکل از یک لایه LSTM و پرسپترون چندلایه

Figure (2) Hybrid deep neural network architecture consisting of LSTM and MLP

جدول (۲): تنظیمات ابر پارامترها

Table (2) Hyperparameter settings

ابر پارامترها	مقدار تنظیم‌شده
نرخ یادگیری	۰/۰۰۱
نرخ منظم‌ساز L2[1]	۰/۰۰۰۱
درصد حذف تصادفی[2]	۱۰٪
الگوریتم بهینه‌ساز	Adam
β_1	۰/۹
β_2	۰/۹۹۹
تعداد دسته آموزشی	۵۱۲
تعداد تکرار	۵۰۰

1. Regularization
2. Dropout

به‌منظور اطمینان از جلوگیری از بیش‌برازش[1]، از تکنیک‌های منظم‌سازی مانند حذف تصادفی و نرخ منظم‌ساز L2 بهره گرفته شده است. استفاده از این تکنیک‌ها تعمیم‌پذیری مدل را افزایش و به استحکام روش‌شناسی کمک می‌کند. در ادامه، برای ارزیابی تعمیم‌پذیری مدل، عملکرد آن روی مجموعهٔ تست متوالی (ناشی از تقسیم زمانی) بررسی شده و از شاخص‌های ارزیابی دقیق‌تری همچون مساحت زیر منحنی و ماتریس‌های درهم‌ریختگی در کنار دقت کلی استفاده شده است، تا تحلیل پایداری مدل برای داده‌های دیده‌نشده دقیق‌تر باشد؛ درنهایت، باتوجه‌به ماهیت سری زمانی و حجم محدود داده، سعی شده است تا بین ملاحظات روش‌شناسی و واقعیت‌های داده‌ای تعادل برقرار تا باعث تقویت تعمیم‌پذیری مدل شود.

یافته‌ها

همان‌طور که در جدول (۳) آمده است، آمار توصیفی مربوط به تغییرات قیمتی شاخص‌ها در اختیار است. با بررسی معیارهای تمرکز (میانگین و میانه) ملاحظه می‌شود که متوسط بازدهٔ شاخص فلزات اساسی در مقایسه با بازدهٔ سایر شاخص‌ها اندکی بیشتر است؛ علاوه‌براین، با نگاهی به مقادیر کمینه و بیشینه ملاحظه می‌شود که بیشترین و کمترین بازدهٔ تغییرات قیمتی مشاهده‌شده نیز مربوط به شاخص فلزات اساسی است که به‌تبع آن بیشترین دامنهٔ تغییرات و مقدار انحراف معیار را نیز به خود اختصاص داده است؛ از این‌رو می‌توان نتیجه گرفت که شاخص فلزات اساسی بیشترین ریسک را در بین سایر شاخص‌ها دارد. این درحالی است که شاخص کل بورس اوراق بهادار از وضعیت پایدارتری در مقایسه با سایرین برخوردار است. مقادیر به‌دست‌آمده چولگی برای تمامی بازدهٔ شاخص‌ها در بازهٔ (۲- و۲) قرار دارد؛ پس می‌توان توزیع آن‌ها را نسبتاً متقارن در نظر گرفت.

جدول (۳): آماره‌های توصیفی مربوط به بازدهٔ ماهانهٔ متغیرهای وابسته

Table (3) Descriptive statistics related to monthly returns of dependant variables

شرح/شاخص	کل	صنعت	مالی	۵۰ شرکت فعال‌تر	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

در این قسمت پس از شناسایی دوره‌های حبابی با استفاده از روش GSADF در شاخص‌های اصلی، متغیر مجازی حباب با دو مقدار به ترتیب ۰ برای ماه‌های غیرحبابی و ۱ برای ماه‌های حبابی تعریف شده است. اشکال (۳) الی (۵)، نمودار قیمت ماهانهٔ شاخص‌ها را به همراه دوره‌های حبابی شناسایی‌شده نشان می‌دهند. قسمت قرمزرنگ نمودار مربوط به دوره‌های حبابی است.

1. Overfitting

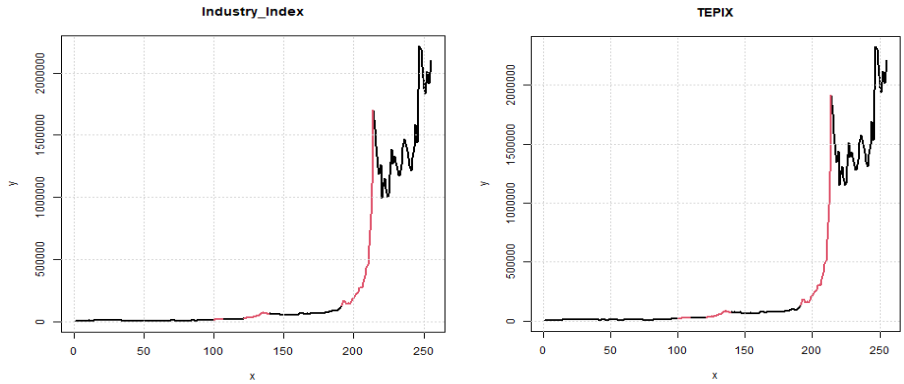

شکل (۳): نمودار قیمت ماهانهٔ شاخص کل (راست) و شاخص صنعت (چپ) به همراه دوره‌های حبابی شناسایی‌شده

Figure (3) Monthly price chart of the Total Index (right) and the Industry Index (left) with identified bubble periods

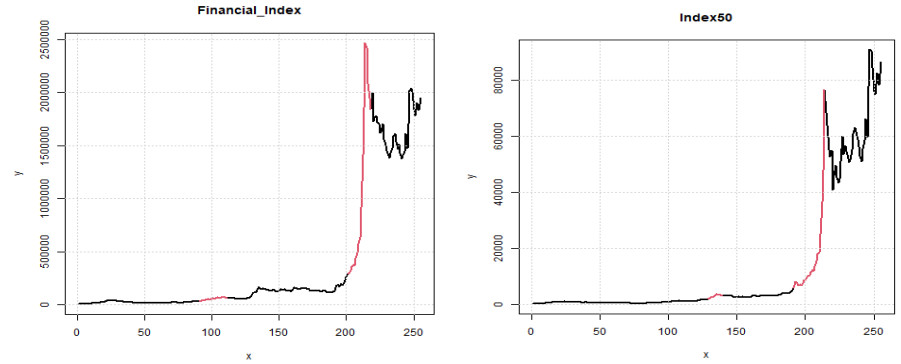

شکل (۴): نمودار قیمت ماهانهٔ شاخص ۵۰ شرکت فعال‌تر (راست) و شاخص مالی(راست) به همراه دوره‌های حبابی شناسایی‌شده

Figure (4) Monthly price chart of the the Most 50 Active Companies Index (right) and the Financial Index (left) with identified bubble periods

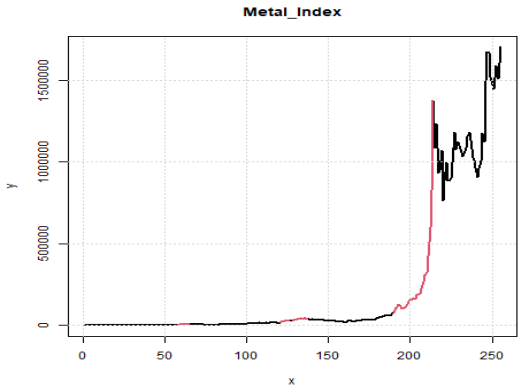

شکل (۵): نمودار قیمت ماهانهٔ شاخص فلزات اساسی به همراه دوره‌های حبابی شناسایی‌شده

Figure (5) Monthly price chart of the Metal Index with identified bubble periods

در ادامه، دوره‌های حبابی شناسایی شده از جدول (۴) و شکل (۶) با جزئیات بیشتری مشاهده می‌شود.

جدول (۴): جزئیات دوره‌های حبابی به تفکیک شاخص

Table (4) Bubble periods details by index

شاخص‌ها	تاریخ شروع	نقطهٔ اوج (پیک)	تاریخ پایان	مدت (ماه)
کل	۱۳۸۹/۱۰/۲۹	۱۳۹۰/۰۱/۳۱	۱۳۹۰/۰۷/۳۰	۹
	۱۳۹۱/۰۷/۳۰	۱۳۹۲/۰۹/۳۰	۱۳۹۳/۰۱/۳۱	۱۸
	۱۳۹۷/۰۵/۳۰	۱۳۹۷/۱۰/۳۰	۱۳۹۷/۱۱/۳۰	۶
	۱۳۹۷/۱۲/۲۸	۱۳۹۸/۱۲/۲۸	۱۳۹۹/۰۴/۳۱	۱۶
صنعت	۱۳۸۹/۱۰/۲۹	۱۳۹۰/۰۱/۳۱	۱۳۹۰/۰۴/۲۹	۶
	۱۳۹۱/۰۷/۳۰	۱۳۹۲/۰۹/۳۰	۱۳۹۳/۰۱/۳۱	۱۸
	۱۳۹۷/۰۵/۳۰	۱۳۹۸/۱۲/۲۸	۱۳۹۹/۰۴/۳۱	۲۳
مالی	۱۳۸۹/۰۱/۳۱	۱۳۹۰/۰۱/۳۱	۱۳۹۰/۰۹/۳۰	۲۰
	۱۳۹۸/۰۳/۲۹	۱۳۹۹/۰۷/۳۰	۱۳۹۹/۰۸/۲۸	۱۷
۵۰ شرکت فعال‌تر	۱۳۹۲/۰۳/۲۹	۱۳۹۲/۰۹/۳۰	۱۳۹۳/۰۱/۳۱	۱۰
	۱۳۹۷/۰۵/۳۰	۱۳۹۸/۱۲/۲۸	۱۳۹۹/۰۴/۳۱	۲۲
فلزات اساسی	۱۳۹۲/۰۳/۲۹	۱۳۹۲/۰۹/۳۰	۱۳۹۳/۰۱/۳۱	۸
	۱۳۹۱/۰۶/۲۹	۱۳۹۲/۰۷/۳۰	۱۳۹۲/۱۱/۳۰	۱۵
	۱۳۹۷/۰۳/۳۰	۱۳۹۸/۱۲/۲۸	۱۳۹۹/۰۴/۳۱	۲۴

همان‌طورکه از نتایج جدول (۴) ملاحظه می‌شود، تمامی شاخص‌ها یک دورهٔ مشخص حبابی تقریباً دوساله را از مردادماه سال ۱۳۹۷ الی مردادماه سال ۱۳۹۹ تجربه کرده‌اند. نکتهٔ حائز اهمیت دیگر این است که در شاخص مالی، سیگنال خروج از حباب قدری دیرتر در مقایسه با سایر شاخص‌ها بوده است؛ ولی شاخص‌های صنعت و کل تقریباً دوره‌های مشابهی داشته‌اند. از شکل (۶)، نحوهٔ تشخیص این دوره‌ها توسط روش GSADF مشاهده می‌شود.

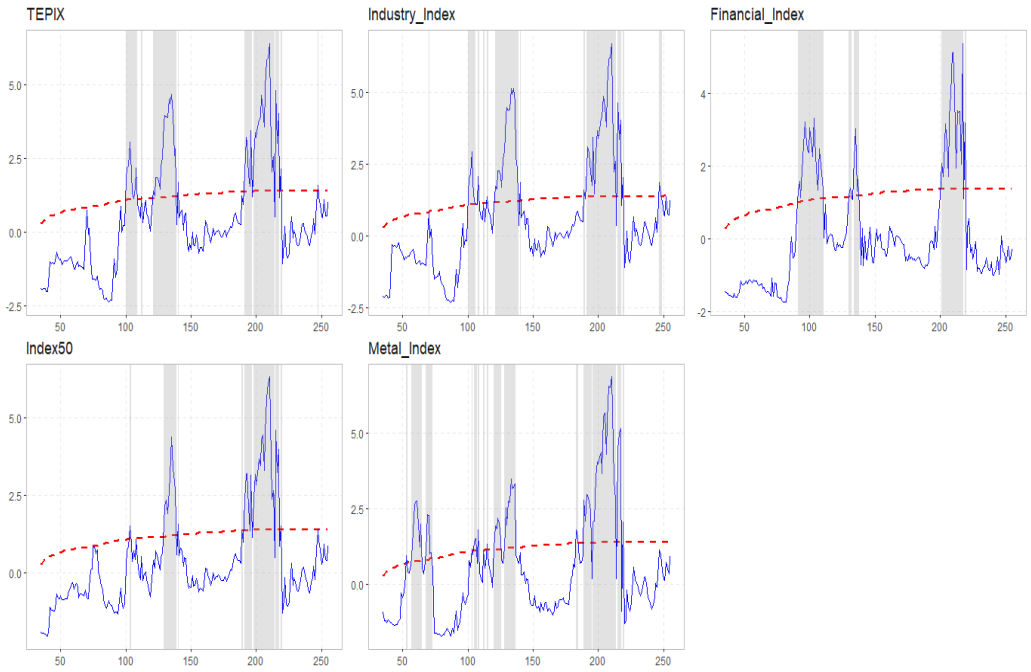

شکل (۶): نمودار نتایج روش GSADF به جهت تشخیص دوره‌های حبابی

Figure (6) Graph of the method 'GSADF' results for detecting bubble periods

از جدول (۵) میزان توزیع دوره‌های حبابی و غیرحبابی شاخص‌های پژوهش در دو مجموعهٔ آموزشی و آزمایشی به تفکیک مشاهده می‌شود. همان‌طورکه ملاحظه می‌شود، نحوهٔ توزیع فراوانی دوره‌های حبابی در سه شاخص کل، صنعت و فلزات اساسی تقریباً مشابه هستند. همچنین کمترین تعداد مشاهدات مربوط به شاخص ۵۰ شرکت فعال‌تر با تعداد ۳۵ ماه است. پس از تعیین مجموعهٔ داده‌های آموزشی و آزمایشی به مدل‌سازی و آموزش مدل‌ها پرداخته شده است.

جدول (۵): توزیع دوره‌های حبابی در داده‌های آموزشی و آزمایشی

Table (5) Distribution of bubble periods in training and test data

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

پس از شناسایی دوره‌های حبابی و تشکیل متغیر مجازی حباب، با در نظر گرفتن این متغیر مجازی به‌عنوان متغیر هدف (وابسته) و لحاظ شاخص‌های هشداردهنده (متغیرهای مستقل) مطابق جدول (۱) پس از اعمال وقفهٔ ۵ دوره‌ای و نرمال‌سازی به‌عنوان ویژگی‌های ورودی در مدل‌ها، مدل‌سازی به‌منظور پیش‌بینی حباب انجام شده است؛ برای این منظور از دو مدل رگرسیون لجستیک و شبکه‌های عصبی برگشتی رهیافت حافظهٔ کوتاه‌مدت طولانی براساس تنظیمات ابرپارامترها مطابق جدول (۲) استفاده شده است.

نتیجهٔ آموزش شبکه برای داده‌های مجموعهٔ آموزشی (درون‌نمونه ای) نیز از شکل (۷) در اختیار است؛ مشاهده می‌شود که مقدار تابع هزینه با افزایش تکرار عملیات آموزش کم و کمتر شده تا به همگرایی می‌رسد. این مهم بیانگر آن است که شبکهٔ عصبی عمیق به‌طور قابل‌قبول و خوبی آموزش دیده است.

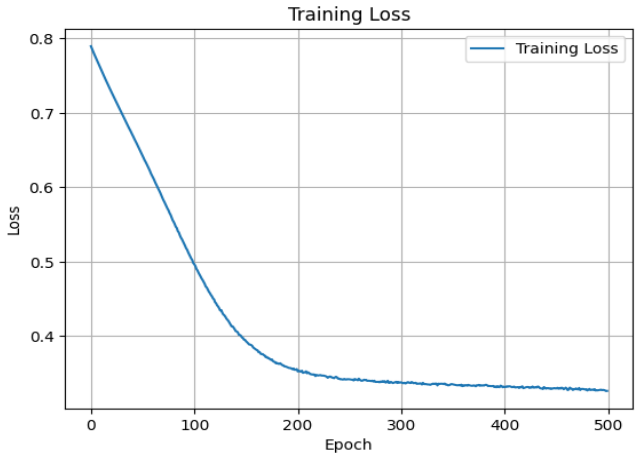

شکل (۷): نتیجهٔ حاصل از فرایند آموزش شبکه

Figure (7) Result of the network training process

در ادامه، نتایج ارزیابی دقت پیش‌بینی مدل‌های رگرسیون لجستیک و حافظهٔ کوتاه‌مدت طولانی برای شاخص‌های پژوهش‌شده گزارش شده است. عملکرد نتایج حاصل‌شده براساس سایر شاخص‌های ارزیابی عملکرد AUC-ROC و ماتریس درهم‌ریختگی نیز بررسی و مقایسه شد.

در جدول (۶) نتایج درصد دقت پیش‌بینی مدل رگرسیون لجستیک به تفکیک مجموعهٔ آموزشی و آزمایشی آورده شده است. همان‌طور که ملاحظه می‌شود، بیشترین دقت پیش‌بینی مربوط به شاخص مالی به میزان ۷۹٪ و کمترین دقت پیش‌بینی مربوط به شاخص فلزات اساسی به میزان ۶۵٪ است. دقت این مدل در پیش‌بینی‌های حباب شاخص‌های مالی، کل و صنعت بیشتر بوده است.

جدول (۶): ارزیابی دقت مدل LR برای مجموعهٔ داده‌های آموزشی و آزمایشی به تفکیک شاخص

Table (6) Evaluation of the accuracy of the LR model for training and testing datasets by index

شاخص‌ها	آموزشی	آزمایشی
کل	۰/۸۳	۰/۶۹
صنعت	۰/۸۵	۰/۶۹
مالی	۰/۸۸	۰/۷۹
۵۰ شرکت فعال‌تر	۰/۹۴	۰/۶۷
فلزات	۰/۸۵	۰/۶۵

در جدول (۷)، ارزیابی AUC-ROC مدل رگرسیون لجستیک به تفکیک مجموعهٔ آموزشی و آزمایشی آورده شده است. در این ارزیابی، همان‌طور که ملاحظه می‌شود، بهترین عملکرد مربوط به شاخص مالی به میزان ۹۲٪ و کمترین مربوط به شاخص فلزات اساسی به میزان ۷۹٪ است. این مدل در پیش‌بینی‌های حباب شاخص‌های مالی و ۵۰ شرکت فعال‌تر عملکرد بهتری داشته است. در ادامه در شکل (۸) تصاویر مساحت زیر منحنی آورده شده است.

جدول (۷): ارزیابی AUC-ROC مدل LR برای مجموعهٔ داده‌های آموزشی و آزمایشی به تفکیک شاخص

Table (7) Evaluation of the AUC-ROC of the LR model for training and testing datasets by index

شاخص‌ها	آموزشی	آزمایشی
کل	۰/۸۷	۰/۸۲
صنعت	۰/۸۸	۰/۸۲
مالی	۰/۸۰	۰/۹۲
۵۰ شرکت فعال‌تر	۰/۹۴	۰/۸۴
فلزات اساسی	۰/۷۹	۰/۷۹

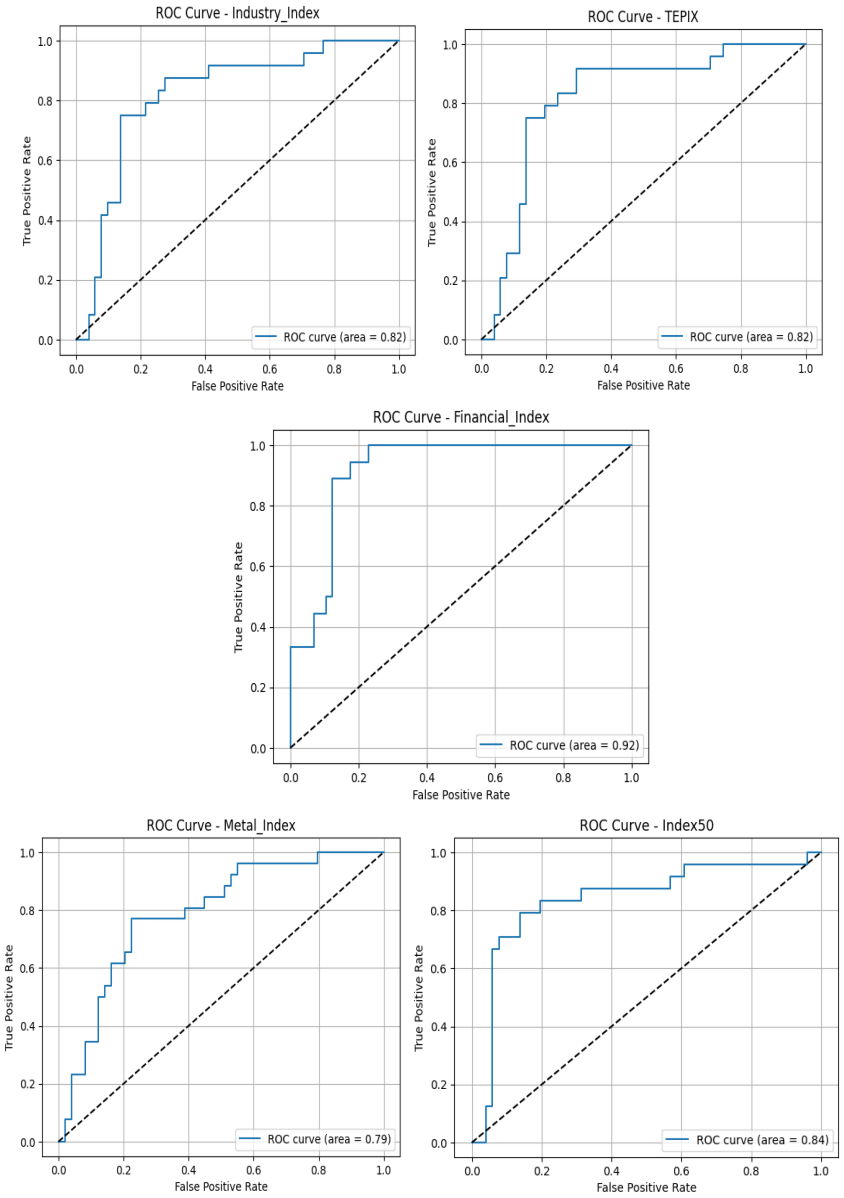

شکل (۸): نمودارهای مساحت زیر منحنی AUC-ROC مدل LR به تفکیک شاخص

Figure (8) Graph of AUC-ROC of the LR model by index

در ادامه، جدول (۸) ماتریس‌های درهم‌ریختگی مدل LR به تفکیک شاخص‌ها برای داده‌های مجموعهٔ آزمایشی مشاهده می‌شود. ماتریس درهم‌ریختگی نحوهٔ توزیع فراوانی مشاهدات واقعی در مجموعهٔ داده‌های آزمایشی را درمقابل مشاهدات پیش‌بینی‌شده توسط مدل نشان می‌دهد؛ برای مثال در ماتریس درهم‌ریختگی برای شاخص کل ملاحظه می‌شود که از ۷۵ مشاهدهٔ موجود در مجموعهٔ آزمایشی درمجموع ۵۱ مشاهدهٔ غیرحبابی و ۲۴ مشاهدهٔ حباب بوده است که از ۵۱ مشاهدهٔ غیرحبابی ۴۸ مورد به‌درستی توسط مدل غیرحبابی شناسایی شده و ۳ مورد خطا وجود داشته که در واقعیت غیرحبابی بوده است؛ اما مدل به اشتباه حباب تشخیص داده است. همچنین از بین ۲۴ مشاهدهٔ حبابی مدل آموزش دیده‌شده، ۴ مورد را به‌درستی حباب تشخیص داده و ۲۰ مورد خطا داشته است که در واقعیت حباب بوده‌اند؛ ولی مدل غیرحباب پیش‌بینی کرده است. اگر میزان درستی پیش‌بینی درخصوص تشخیص حباب (۴ مورد)، تقسیم بر مجموع کل مشاهدات حبابی (۲۴ مورد)

شود، نرخ تشخیص حباب ۱۷٪ می‌شود که اصطلاحاً به آن نرخ صحیح مثبت[1] می‌گویند. تفسیر ماتریس‌های درهم‌ریختگی مابقی شاخص‌ها نیز به همین منوال است. با نگاهی اجمالی به نتایج ماتریس درهم‌ریختگی ملاحظه می‌شود که نرخ‌های صحیح مثبت توسط مدل رگرسیون لجستیک از ۰٪ تا ۱۷٪ بسیار پایین هستند.

جدول (۸): ماتریس درهم‌ریختگی مدل LR داده‌های آزمایشی به تفکیک شاخص

Table (8) Confusion matrix of the LR model for the testing data by index

شاخص	واقعی/ پیش‌بینی	غیر حباب	حباب	نرخ تشخیص حباب
کل	غیرحباب	۴۸	۳	٪۱۷
	حباب	۲۰	۴	
صنعت	غیرحباب	۴۸	۳	٪۱۷
	حباب	۲۰	۴	
مالی	غیرحباب	۵۷	۰	٪۱۱
	حباب	۱۶	۲	
۵۰ شرکت فعال‌تر	غیرحباب	۵۰	۱	٪۰
	حباب	۲۴	۰	
فلزات اساسی	غیرحباب	۴۸	۱	٪۴
	حباب	۲۵	۱	

از جدول (۹) نیز نتایج درصد دقت پیش‌بینی برای مدل LSTM به تفکیک مجموعهٔ آموزشی و آزمایشی در اختیار است. ملاحظه می‌شود که بیشترین درصد دقت پیش‌بینی مربوط به شاخص کل با ۸۱٪ و کمترین مربوط به فلزات اساسی با ۷۳٪ است. با مقایسهٔ نتایج دقت پیش‌بینی در مدل LSTM با مدل LR ملاحظه می‌شود که دقت پیش‌بینی در تمامی شاخص‌ها بهبود داشته است؛ برای مثال دقت پیش‌بینی مدل رگرسیون لجستیک برای شاخص کل ۶۹٪ بوده است؛ درحالی‌که در مدل LSTM به ۸۱٪ رسیده که نشان‌دهندهٔ افزایش بهبود ۱۲٪ در دقت پیش‌بینی مدل است. این افزایش بهبود دقت در شاخص‌های صنعت، ۵۰ شرکت فعال‌تر و فلزات اساسی ۸٪ و در شاخص مالی ۱٪ بوده است.

جدول (۹): ارزیابی دقت مدل LSTM برای مجموعهٔ داده‌های آموزشی و آزمایشی به تفکیک شاخص

Table (9) Evaluation of the accuracy of the LSTM model for training and testing datasets by Index

شاخص‌ها	آموزشی	آزمایشی
کل	۰/۸۵	۰/۸۱
صنعت	۰/۸۸	۰/۷۷
مالی	۰/۸۴	۰/۸۰
۵۰ شرکت فعال‌تر	۰/۹۴	۰/۷۵
فلزات	۰/۸۷	۰/۷۳

در جدول (۱۰)، ارزیابی AUC-ROC مدل LSTM به تفکیک مجموعهٔ آموزشی و آزمایشی آورده شده است. در این ارزیابی همان‌طور که ملاحظه می‌شود، بهترین عملکرد مربوط به شاخص مالی به میزان ۹۲٪ و کمترین مربوط به شاخص

1. True Positive Rate (TPR)

فلزات به میزان ۸۱٪ است. این مدل در پیش‌بینی‌های حباب شاخص مالی عملکرد بهتری داشته است. در ادامه در شکل (۹) تصاویر مساحت زیر منحنی آورده شده است.

جدول (۱۰): ارزیابی AUC-ROC مدل LSTM برای مجموعهٔ داده‌های آموزشی و آزمایشی به تفکیک شاخص

Table (10) Evaluation of the AUC-ROC of the LSTM model for training and testing datasets by Index

شاخص‌ها	آموزشی	آزمایشی
کل	۰/۸۷	۰/۸۲
صنعت	۰/۹۰	۰/۸۲
مالی	۰/۷۵	۰/۹۲
۵۰ شرکت فعال‌تر	۰/۹۰	۰/۸۳
فلزات	۰/۷۳	۰/۸۱

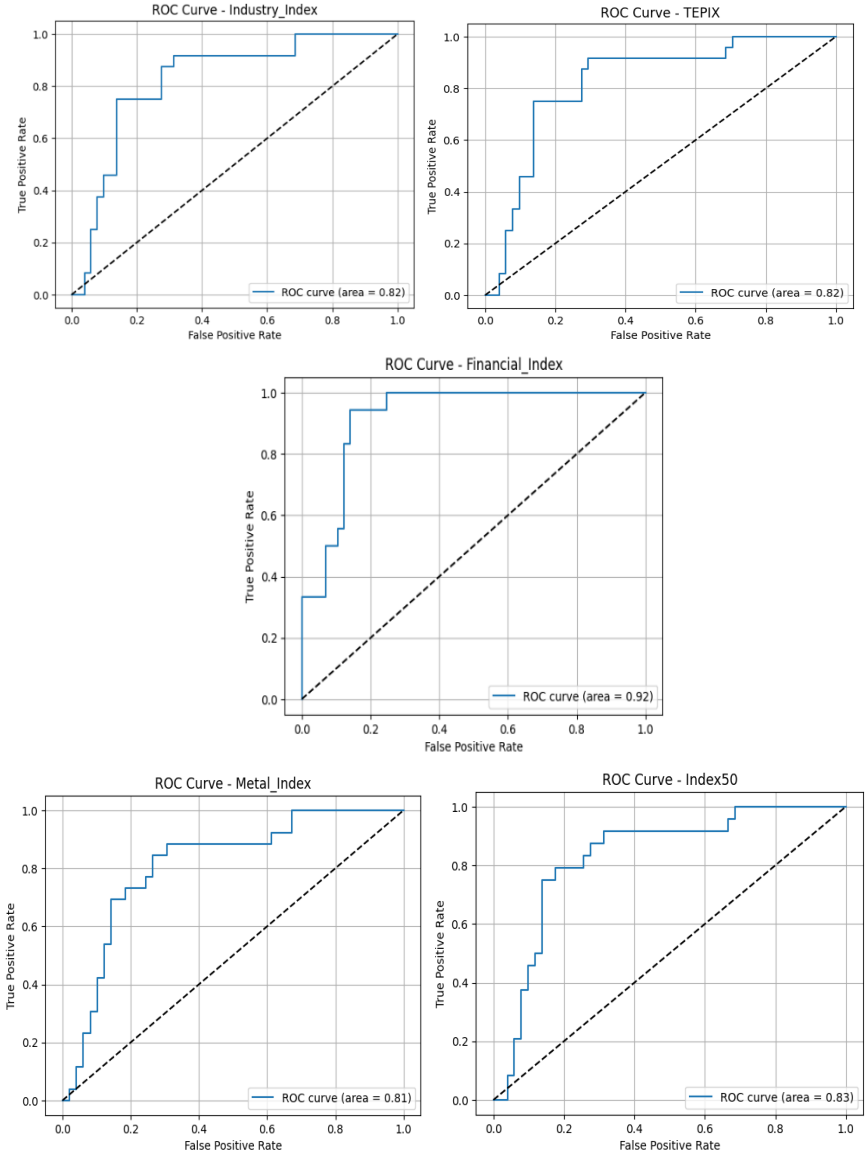

شکل (۹): نمودارهای مساحت زیر منحنی AUC-ROC مدل LSTM به تفکیک شاخص

Figure (9) Graph of AUC-ROC of the LSTM model by index

در ادامه، در جدول (۱۱) ماتریس‌های درهم‌ریختگی مدل LSTM به تفکیک شـــاخص برای داده‌های مجموعهٔ آزمایشـــی مشاهده می‌شود. با نگاهی اجمالی به نتایج ملاحظه می‌شود که نرخ‌های صحیح مثبت در این مدل از ۳۸٪ تا ۷۱٪ بوده است و شـاخص کل با ۷۱٪ بیشـترین و شـاخص ۵۰ شـرکت فعال‌تر با ۳۸٪ کمترین میزان را داشـته‌اند؛ بنابراین، با ارزیابی و مقایسـهٔ ماتریس‌های درهم‌ریختگی دو مدل می‌توان دریافت که مدل LSTM در تمام شـــاخص‌های منتخب عملکرد بســـیار بهتری در مقایسه با مدل رگرسیون لجستیک داشته است.

جدول (۱۱): ماتریس درهم‌ریختگی مدل LSTM برای داده های آزمایشی به تفکیک شاخص

Table (11) Confusion matrix of the LSTM model for the testing data by index

شاخص	واقعی/ پیش‌بینی	غیر حباب	حباب	نرخ تشخیص حباب
کل	غیر حباب	۴۴	۷	
	حباب	۷	۱۷	٪۷۱
صنعت	غیر حباب	۴۴	۷	
	حباب	۱۰	۱۴	٪۵۸
مالی	غیر حباب	۵۰	۷	
	حباب	۸	۱۰	٪۵۶
۵۰ شرکت فعال‌تر	غیر حباب	۴۷	۴	
	حباب	۱۵	۹	٪۳۸
فلزات اساسی	غیر حباب	۴۳	۶	
	حباب	۱۴	۱۲	٪۴۶

نتایج و پیشنهادها

در این پژوهش با هدف کاهش شـــکاف در حوزهٔ پژوهش‌های مالی و ایجاد و ارتقای نوآوری، با تمرکز بر تحلیل داده‌های اقتصادی و مالی و با بهره‌گیری فناوری‌های پیشرفته و انتخاب متغیرهای هشداردهنده مبتنی‌بر پیشینهٔ پژوهش‌ها که نقش مهمی در تشکیل حباب‌های قیمتی دارند، یک سیستم هشدار سریع برای پیش‌بینی حباب‌های قیمتی بازار سهام طراحی شده است. در مروری بر پیشینهٔ پژوهش مشخص شده است که بیشتر مطالعات داخلی و خارجی در حوزهٔ حباب‌های مالی، بر آزمون و شـــناســـایی حباب در بازه‌های زمانی مختلف، بازار دارایی‌های مختلف و با روش‌های پژوهش متنوع متمرکز بوده‌اند. تعداد محدودی از پژوهش‌ها نیز به توسـعه و ارائهٔ مدل‌هایی برای پیش‌بینی حباب اختصـاص یافته اسـت. پژوهش حاضـر با هدف پاسـخ به این شـکاف، راهکار نوینی درزمینهٔ توسـعهٔ مدل‌های پیش‌بینی حباب در بازار سـهام ارائه می‌دهد که می‌تواند نقش مؤثری در مدیریت ریسـک و تصـمیم‌گیری‌های سـریع و آگاهانه در بازار سـرمایه ایفا کند و ریسـک‌های مرتبط با حباب‌های قیمتی را کاهش دهد.

درزمینهٔ سیستم هشدار سریع، پژوهش‌های داخلی محدود به بررسی بحران‌های مالی، پولی، ارزی، نوسانات بازار سهام و شـاخص‌های هشـداردهندهٔ این بحران‌ها بوده اسـت؛ اما تاکنون پژوهشـی مسـتقل در حوزهٔ حباب‌های مالی و پیش‌بینی آن‌ها انجام نشـده اسـت؛ بنابراین، یافته‌ها و مدل‌های این مطالعه می‌تواند نقطهٔ شـروعی مهم برای پژوهش‌های داخلی در این حوزه باشـد. در پژوهش‌های خارجی نیز، مطالعات مرتبط عمدتاً بر مســـکن، بحران‌های مالی، تلاطم‌ها، نوســـانات بازار ســـهام و شـاخص‌های هشـداردهنده متمرکز بوده اسـت. این نوآوری می‌تواند راهگشـای توسـعه و بهبود سـامانه‌های هشـدار سـریع در بازارهای مالی باشد.

در این پژوهش مدل شبکه‌های عصبی برگشتی رهیافت حافظهٔ کوتاه‌مدت طولانی LSTM (یادگیری عمیق) و مدل رگرسیون لجستیک LR (به‌عنوان یک مدل کلاسیک یادگیری ماشین)، به‌عنوان رویکردهای متفاوت و مقایسه‌پذیر برای طراحی مدل‌های پیش‌بینی حباب و ارزیابی عملکرد آن‌ها استفاده شده است. استفاده از شاخص‌های منتخب بورس اوراق بهادار تهران نیز موجب افزایش جامعیت پژوهش و امکان تفسیر و مقایسهٔ دقیق‌تر نتایج براساس ویژگی‌های فنی هر شاخص و تأثیر آن‌ها بر پیش‌بینی حباب شده است. این نوآوری‌ها می‌توانند نقش مؤثری در توسعهٔ روش‌های پیش‌بینی و هشدار حباب‌های مالی ایفا کنند.

هدف اصلی پژوهش حاضر، طراحی یک سیستم هشدار سریع به‌منظور پیش‌بینی حباب شاخص‌های منتخب بورس تهران (کل، صنعت، ۵۰ شرکت فعال‌تر، فلزات اساسی و مالی) است. این هدف ازطریق شناسایی دوره‌های حبابی با استفاده از آزمون سوپریمم عمومی دیکی‌فولر تعمیم‌یافته، ایجاد متغیر مجازی حباب و مدل‌سازی پیش‌بینی با لحاظ تغییرات قیمتیِ (بازدهٔ لگاریتمی) مجموعه‌ای از متغیرهای مستقل «شاخص‌های هشداردهنده» با مدل شبکه‌های عصبی برگشتی رهیافت حافظهٔ کوتاه‌مدت طولانی LSTM (یادگیری عمیق) بوده است. نتایج نشان می‌دهد که این سیستم، با دقت حدود ۷۳٪ تا ۸۱٪ در تمام شاخص‌های منتخب (شاخص کل با دقت ۸۱٪، شاخص مالی با دقت ۸۰٪، شاخص صنعت با دقت ۷۷٪، شاخص ۵۰ شرکت فعال‌تر با دقت ۷۵٪ و شاخص فلزات اساسی با دقت ۷۳٪) طراحی شده است. هدف دیگر این پژوهش، مقایسهٔ دقت مدل‌های به‌کارگرفته‌شده در سیستم هشدار سریع طراحی‌شده است؛ نتایج به‌دست‌آمده حاکی‌ازآن است که دقت پیش‌بینی مدل LSTM در تمام شاخص‌های منتخب در مقایسه با مدل LR بهبود داشته است. به عبارتی، دقت پیش‌بینی حباب در مدل LR برای شاخص کل ۶۹٪ بوده است؛ درحالی‌که در مدل LSTM به ۸۱٪ رسیده که نشان‌دهندهٔ افزایش بهبود ۱۲٪ است. این بهبود دقت در شاخص‌های صنعت، ۵۰ شرکت فعال‌تر و فلزات اساسی ۸٪ و در شاخص مالی ۱٪ بوده است. در رابطه با مقایسهٔ کیفیت پیش‌بینی حباب شاخص‌های منتخب ازطریق شاخص‌های ارزیابی مساحت زیرمنحنی AUC-ROC و ماتریس‌های درهم‌ریختگی این نتیجه حاصل شده است که کیفّت پیش‌بینی مدل LSTM در مقایسه با مدل LR ازطریق مساحت زیرمنحنی تا حدودی به هم نزدیک بوده‌اند؛ ولی ازطریق ماتریس‌های درهم‌ریختگی، به‌مراتب بهتر بوده است. البته این نکته نیز درخور توجه است که با گذشت زمان و افزایش تعداد مشاهدات، عملکرد مدل‌های مبتنی‌بر یادگیری عمیق بهتر خواهد شد؛ از این‌رو باید سیستم‌های هشداردهنده و پیش‌بینی‌کننده به‌طور مداوم به‌روز شوند. از جمله اهداف جزئی این پژوهش، شناسایی دوره‌های حبابی در شاخص‌های منتخب بررسی‌شده بوده است که این امر نیز توسط آزمون GSADF تحقق پذیرفته است و نتایج آن در جدول (۴) مشاهده می‌شود. نکتهٔ حائز اهمیت این است که در شاخص مالی، سیگنال خروج از حباب قدری دیرتر در مقایسه با سایر شاخص‌ها بوده است؛ ولی شاخص‌های صنعت و شاخص کل تقریباً دوره‌های مشابهی داشته‌اند.

به‌منظور توصیه‌های سیاستی این پژوهش، تأکید می‌شود که نهادهای سیاست‌گذار و نظارتی با بهره‌گیری از مدل‌های پیش‌بینی به‌روز و پیشرفته و پایش شاخص‌های هشداردهنده، به طراحی و توسعهٔ سیستم‌های هشدار سریع بپردازند و به‌صورت مستمر، وضعیت حباب‌های قیمتی را در شاخص‌های اصلی و صنایع مختلف بورس اوراق بهادار رصد کنند و با شناسایی نشانه‌های شکل‌گیری حباب‌ها و هشدار سریع در رابطه با آن‌ها، با تدابیر مناسب و اتخاذ اقدامات پیشگیرانهٔ مؤثر، از بروز بحران و آسیب‌های اقتصادی بیشتر جلوگیری کنند. راهکارهای جلوگیری از توسعهٔ پدیدهٔ حباب از منظر نظریه‌پردازان، اجرای سیاست‌های پولی و مالی مناسب، وجود ابزارهای متنوع سرمایه‌گذاری، تقویت نظارت و کنترل بیشتر سازمان بورس اوراق بهادار بر شفاف‌سازی اطّلاعات شرکت‌ها، افزایش سهام شناور، تقویت عوامل نظارتی بر تزریق نقدینگی در بخش‌های مختلف اقتصادی، تخلف‌های معاملاتی و رانت‌های داخلی شرکت‌ها و... است. همچنین شرکت‌های سرمایه‌گذاری،

سبدگردان‌ها و سرمایه‌گذاران با شناسایی و پیش‌بینی حباب‌های قیمتی و امکان دریافت هشدار سریع، قادر خواهند بود با اتخاذ راهبردهای معاملاتی مناسب و مؤثر در مدیریت ریسک، اصلاح سبد سرمایه‌گذاری و تخصیص مجدد سرمایه، ریسک‌های کمتری را تجربه و تهدیدات بازار را به فرصت تبدیل کنند.

در پژوهش‌های آتی پیشنهاد می‌شود سیستم‌های هشدار سریع برای پیش‌بینی حباب برای سایر بازار دارایی‌ها همچون مسکن، طلا، ارز، رمزارز در افق‌های زمانی مختلف و با مدل‌های ترکیبی اقتصادسنجی، هوش مصنوعی و ابتکاری با دقت پیش‌بینی بیشتر و عملکرد بهتر بررسی شود. شاخص‌های هشداردهنده‌ای همچون تولید ناخالص داخلی، پایهٔ پولی، نقدینگی،کسری بودجه، صادرات نفتی و غیرنفتی، شاخص‌های مالی رفتاری، شاخص احساسات و... نیز برای توسعه و بهبود عملکرد این سیستم‌ها به کار روند. نتایج به‌دست‌آمده در این پژوهش را می‌توان در پژوهش‌های مرتبط با بهینه‌سازی سبد سرمایه‌گذاری‌ها، طراحی راهبردهای معاملاتی پویا، راهبردهای پوشش ریسک و... به کار برد. ازجمله محدودیت‌های این پژوهش می‌توان به تعداد محدود داده‌های سری زمانی برای استفادهٔ بهینه در یادگیری عمیق اشاره کرد. به‌منظور انتخاب متغیرهای هشداردهنده به‌عنوان عوامل مؤثر بر حباب‌ها از به‌کارگیری بعضی متغیرها به دلیل کافی‌نبودن داده یا تواترهای غیرمتناسب با تواتر استفاده‌شده در این پژوهش صرف نظر شد.

منابع

آسیم، محمد (۱۳۹۹). *الگویی برای تبیین رفتار سرمایه‌گذاران قبل و بعد از حباب قیمت سهام* [پایان‌نامه دکترا، دانشگاه علامه طباطبائی]. گنج.

بیابانی خامنه، کاظم، خزایی، سعید، و 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، و داستانی هریس، سارا (۱۳۹۹). ارائه مدلی جهت برآورد احتمال ایجاد حباب قیمتی در بازار سرمایه: شواهد تجربی و تئوریک از بورس اوراق بهادار تهران. *دانش سرمایه‌گذاری*، ۹(۳۴)، ۳۷۱–۳۸۷.

خلیلی عراقی، مریم، فلاح شمس، میرفیض، رئیسی وانانی، ایمان، و شریف‌فر، امیر (۱۴۰۱). کاربرد معماری‌های یادگیری عمیق در پیش‌بینی قیمت سهام؛ رویکرد شبکه عصبی پیچشی. *مدیریت دارایی و تأمین مالی*، ۱۰(۳)، ۱–۲۰.
https://doi.org/10.22108/amf.2022.129205.1673

رهنمای رودپشتی، فریدون، فلاح شمس، میرفیض، چیرانی، ابراهیم، زمردیان، غلامرضا، و کاشانی تبار، شهرزاد (۱۳۹۹). بررسی تأثیر سرریز نوسانات در بازارهای مالی و ویژگی‌های بازاری در پیش‌بینی ترکیدن حباب قیمت در بورس با رویکرد تلاطم‌های شرطی. *مهندسی مالی و مدیریت اوراق بهادار*، ۱۱(۴۴)، ۳۲۸–۳۴۹.

صادقی شریف، جلال، اصولیان، محمد، و افشاریان، امیرحسین (۱۳۹۶). آزمون‌های رفتار حباب انفجاری چندگانه در بورس اوراق بهادار و مسکن ایران. *مدیریت دارایی و تأمین مالی*، ۵(۴)، ۱۲۹–۱۴۲.
https://doi.org/10.22108/amf.2017.21169

صیادنیا طیبی، عزّت‌اله، شجری، هوشنگ، صمدی، سعید، و ارشدی، علی (۱۳۹۰). تبیین یک سیستم هشداردهنده جهت شناسایی بحران‌های مالی در ایران. *پژوهش‌های پولی و بانکی*، ۲(۶)، ۱۶۹–۲۱۲.

عبّاسیان، عزّت‌اله، محمودی، وحید، و فرزانگان، الهام (۱۳۸۹). شناسایی حباب قیمتی سهام عادی بورس اوراق بهادار تهران با استفاده از مدل ارزش حال. *بررسی‌های حسابداری و حسابرسی*، ۱۷(۲)، ۷۵–۹۲.

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

محمدپوررزندی، محمدابراهیم، مینویی، مهرزاد، و نوروزی، مهدیه (۱۴۰۱). طراحی سیستم هشداردهنده حباب قیمتی و بحران مالی در بازار سهام ایران. *دانش مالی و تحلیل اوراق بهادار*، ۱۵(۵۴)، ۳۷-۴۹.

https://doi.org/10.30495/jfksa.2022.20588

نبوی چاشمی، علی و محجوب، محمدرضا (۱۴۰۰). آزمون وجود حباب سهام با استفاده از تکنیک‌های سوپریمم راست‌دنباله و توابع عکس‌العملی و تجزیه واریانس. *دانش سرمایه‌گذاری*، ۱۰(۳۸)، ۲۴۳-۲۶۴.

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

https://doi.org/10.22059/jte.2017.59617

هادی‌زاده، آرش، میرزاپور باباجان، اکبر، و نادری، مینا (۱۴۰۲). بررسی اثرات شوک‌های سیاست پولی بر حباب قیمت سهام: کاربرد روش خودرگرسیون برداری ساختاری با پارامتر متغیر در زمان (TVP-SVAR). *پژوهش‌های اقتصادی (رشد و توسعه پایدار)*، ۲۳(۲)، ۱۹۳-۲۱۸.

References

Abbasian, E., Mahmoudi, V., & Farzanegan, E. (2010). The influences survey of the intellectual capital elements efficiency on the firms' financial performance in Tehran Stock Exchange. *Accounting and Auditing Review*, 17(2), 75-92. [In Persian]

Abbasian, E., Farzanegan, E., & Nasiroleslami, E. (2016). Price bubble anomalies in Tehran Stock Exchange: Limits to arbitrage approach. *Quarterly Journal of Economic Research and Policies*, 23(76), 75-92. [In Persian]

Abdelsalam, M. A., & Abdel-Latif, H. (2020). An optimal early warning system for currency crises under model uncertainty. *Central Bank Review*, 20(3), 99-107. https://doi.org/10.1016/j.cbrev.2020.03.002

Abolmakarem, S., Abdi, F., Damghani, K. K., & Didehkhani, H. (2024). A multi-stage machine learning approach for stock price prediction: Engineered and derivative indices. *Intelligent Systems with Applications*, 24, 200449. https://doi.org/10.1016/j.iswa.2024.200449

Asim, M. (2020). *A model for explaining investor behaviour before and after the stock price bubble* [Doctoral dissertation, Allameh Tabataba'I University]. Ganj. [In Persian].

Biabanykhameneh, K., Khazaei, S., & Afsharian, A. (2016). Testing for explosive behavior and bubbles in Iran's stock market. *Financial Knowledge of Securities Analysis*, 9(29), 111-125. [In Persian]

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, 40-51. https://doi.org/10.1016/j.eneco.2013.01.006

Boughton, J. M., & Branson, W. H. (1988). *Commodity Prices as a Leading Indicator of Inflation*, 88/87. IMF Working Paper.

Claessens, S., & Kose, M. A. (2013). *Financial Crises: Explanations, Types, and Implications*, 06. CAMA Working Paper.

Demirer, R., Gabauer, D., Gupta, R., & Nielsen, J. (2024). Gold, platinum and the predictability of bubbles in global stock markets. *Resources Policy*, 90, 1-16. https://doi.org/10.1016/j.resourpol.2024.104808

Fallah, M., Pourmansouri, R., & Ahmadpour, B. (2024). Presenting a new deep learning-based method with the incorporation of error effects to predict certain cryptocurrencies. *International Review of Financial Analysis*, 95, 103466. https://doi.org/10.1016/j.irfa.2024.103466

Frommel, M. & Kruse, R. (2012). Testing for a rational bubble under long memory. *Quantitative Finance*, 12(11), 1723-1732. https://doi.org/10.1080/14697688.2011.578151

Gomez-Gonzalez, J. E., Gamboa-Arbelaez, J., Hirs-Garzon, J., & Pinchao-Rosero, A. (2017). When bubble meets bubble: contagion in OECD countries. *The Journal of Real Estate Finance and Economics*, 56, 546-566. https://doi.org/10.1007/s11146-017-9605-4

Hadizadeh, A., Mirzapour-Babajan, A., & Naderi, M. (2023). Investigating the effects of monetary policy shocks on stock price bubbles: The application of structural vector autoregression with time-varying parameters (SVAR-TVP). *Quarterly Journal of the Economic Research*, 23(2), 193-218. [In Persian]

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. https://doi.org/10.1162/neco.1997.9.8.1735

Homm, U., & Breitung, J. (2012). Testing for speculative bubbles in stock markets: a comparison of alternative methods. *Journal of Financial Econometrics*, 10(1), 198-231. https://doi.org/10.1093/jjfinec/nbr009

Kaliva, K., & Koskinen, L. (2008). Stock market bubbles, inflation and investment risk. *International Review of Financial Analysis*, 17(3), 592-603. https://doi.org/10.1016/j.irfa.2007.03.004

Khaliliaraghi, M., Fallahshams, M., Vanani, I. R., & Sharif far, A. (2022). Application of deep learning architectures in stock price forecasting: A convolutional neural network approach. *Journal of Asset Management and Financing*, 10(3), 1-20. https://doi.org/10.22108/amf.2022.129205.1673 [In Persian]

Klopotan, I., Zoroja, J., & Mesko, M. (2018). Early warning system in business, finance, and economics: Bibliometric and topic analysis. *International Journal of Engineering Business Management*, 10, 1847979018797013. https://doi.org/10.1177/1847979018797013

Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks*, 144, 334-341. https://doi.org/10.1016/j.neunet.2021.08.030

Lin, A. J., Chang, H. Y., & Hsiao, J. L. (2019). Does the Baltic Dry Index drive volatility spillovers in the commodities, currency, or stock markets?. *Transportation Research Part E: Logistics and Transportation Review*, 127, 265-283. https://doi.org/10.1016/j.tre.2019.05.013

McQueen, G., & Thorley, S. (1994). Bubbles, stock returns, and duration dependence. *The Journal of Financial and Quantitative Analysis*, 29(3), 379-401. https://doi.org/10.2307/2331336

Mohammadporzarandi, M., Minouei, M., & Norozi, M. (2022). Modelling the price bubble warning system and financial crisis in the stock market. *Financial Knowledge of Securities Analysis*, 15(54), 37-49. https://doi.org/10.30495/jfksa.2022.20588 [In Persian]

Moosa, I. A. (1998). Are commodity prices a leading indicator of inflation?. *Jornal of Policy Modeling*, 20(2), 201-212. https://doi.org/10.1016/S0161-8938(97)00004-5

Nabavichashmi, A., & Mahjoub, M. (2021). Existing bubble stock test with Generalized Supremum Augmented Dickey-Fuller techniques and Impulse Response Function and analysis of Variance Decomposition. *Journal of Investment Knowledge*, 10(38), 243-264. [In Persian]

Namaki, A., Eyvazloo, R., & Ramtinnia, S. (2023). A Systematic Review of Early Warning Systems in Finance. *arXiv preprint arXiv:2310.00490*. https://doi.org/10.48550/arXiv.2310.00490

Nasrollahi, M., Yavari, K., Najarzadeh, R., & Mehregan, N. (2017). The design of an early warning system of currency crisis in Iran: A logistic regression approach. *Economic Research*, 52(1), 187-214. https://doi.org/10.22059/jte.2017.59617 [In Persian]

Phillips, P. C. B., Shi, S., & 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. https://doi.org/10.1111/iere.12132

Phillips, P. C. B., Wu, Y., & Yu, J. (2011). Explosive behavior in the 1990s NASDAQ: When did exuberance escalate asset values? *International Economic Review*, 52(1), 201-226. https://doi.org/10.1111/j.1468-2354.2010.00625.x

Rahnamaroodposhti, F., Kashanitabar, S., Fallah, M., Chirani, E., & Zomorodian, G. (2020). Prediction of stock price bubble drop in Tehran Stock Exchange (Conditional Volatility Approach). *Financial Engineering and Securities Management*, 11(44), 328-349. [In Persian]

Sadeghisharif, J., Osoolian, M., & Afsharian, A. (2017). Tests of multiple explosive bubbles behavior in Tehran Stock Exchange and real esate market in Iran. *Journal of Asset Management and Financing*, 5(4), 129-142. https://doi.org/10.22108/amf.2017.21169 [In Persian]

Sayadniatayebi, E., Shajari, H., Samadi, S., & Arshadi, A. (2011). Explanation an early warning system for identification of the financial crisis in Iran. *Journal of Monetary and Banking Research*, 2(6), 169-212. [In Persian]

Scherbina, A., & Schlusche, B. (2013). Asset price bubbles: A survey. *Quantitative Finance*, 14(4), 589-604. https://doi.org/10.1080/14697688.2012.755266

Tarkun, S. (2025). Dynamic relationships between inflation, industrial production, and freight rates in the EU: A wavelet coherence and casuality analysis. *Marine Policy*, 172, 106534. https://doi.org/10.1016/j.marpol.2024.106534

Torabi, T., Rostami, A., Ghaffari, F., & Heris, S. D. (2020). Modeling the estimation of the price bubble probability in the capital market: evidence from Tehran Stock Exchange. *Journal of Investment Knowledge*, 9(34), 371-387. [In Persian]

Tran, K. L., Le, H. A., Lieu, C. P., & Nguyen, D. T. (2023). Machine learning to forecast financial bubbles in stock markets: Evidence from Vietnam. *International Journal of Financial Studies*, 11(4), 133-143. https://doi.org/10.3390/ijfs11040133

Wever, M., Shah, M., & O'Leary, N. (2022). Designing early warning systems for detecting systemic risk: A case study and discussion. *Futures*, 136, 102882. https://doi.org/10.1016/j.futures.2021.102882

Wockl, I. (2019). *Bubble Detection in Financial Markets: A Survey of Theoretical Bubble Models and Empirical Bubble Detection Tests*. Working Paper, University of Graz, Institute of Finance. https://dx.doi.org/10.2139/ssrn.3460430