

Modeling the Detection of Firms Financial Fraud under The Implementation of Artificial Neural Network's Evaluation Algorithms

Marzieh Poursaedi¹

Department of Accounting, Borujerd Branch, Islamic Azad University, Borujerd, Iran

Mahmood Hematfar^{*2}

Associate Professor, Department of Accounting, Borujerd Branch, Islamic Azad University, Borujerd, Iran

Seyed Enayatallah Alavi³

Assistant professor of computer Department, faculty of Engineering, Shahid Chamran university of Ahvaz, Ahvaz, Iran

Roya Nasirzadeh⁴

Department of Statistics, Faculty of Science, Fasa University, Fasa, Iran

Abstract

The aim of this study is modeling the detection of firms financial fraud under the implementation of artificial neural network's evaluation algorithms. In this study, efforts have been made by using Quadratic Programming "QP" processes in artificial neural network algorithms to determine the basic algorithm in the first place and choose the technical parameters of the artificial neural network in the second place, based on the time data from 2013 to 2022, through several stages. Then, by developing a diagnostic model based on two test and control scales, innovative algorithms that have the highest accuracy coefficients in predicting the accuracy of financial fraud should be investigated at the level of capital market companies. Therefore, based on the systematic sampling process, 95 stock exchange companies were selected, so that based on 950 observations (company-year), the distance between companies with financial health and companies with the possibility of financial fraud was determined through decimalization and the companies placed in the deciles with financial fraud should be examined through the parameters of the artificial neural network's usefulness.

Keywords: Financial Fraud, Artificial Neural Network, Quadratic Programming

¹ 0009-0006-3489-6513

² 0000-0002-3976-9322

³ 0000-0003-0495-5704

⁴ 0000-0002-5302-3789

1. Introduction

With the advent of technology and digital business exchanges, today's era is far more affected by the negative effects of fraud in financial statements than in the past that need to develop fraud detection methods can be considered as a technical process in the fields of financial knowledge. By providing appropriate assessment opportunities for optimal decision-making, highly efficient financial markets facilitate a balanced level of information flow among firms, thereby maintaining the attractiveness of entering this market compared to other markets such as money markets. In particular, implementing such processes can be considered as a strategic financial necessity in developing country economies that face serious challenges due to resource constraints. However, reference to scientific experiences and the operational reality of the financial markets of these countries always indicates the existence of information rents for certain groups of financial decision-makers, which create a level of information asymmetry without the need for expertise or technical evaluation methods and fundamental analysis.

2. Literature Review

Disclosure of transparent financial information is considered an important source in the economic decision-making of stakeholders, which can contribute significantly to the balance of investment markets. However, during the theoretical and paradigmatic structural changes in the field of financial transparency, fraud as a behavioral and functional basis has become a problem for the financial transparency of companies. To understand the official definition of financial fraud, the best reference is Section 240, Section 4 of the Iranian Auditing Standards, which in defining this financial phenomenon refers to the intentional action of companies by executive managers, governing bodies, employees, or third parties that causes the acquisition of illegitimate benefits that result in widespread damage to other stakeholders. However, the important point is that in Section 9 of the same standard, they have distinguished between fraud and error, and they have considered intent and intention as the only distinguishing feature of fraud from error, which is basically not an easy task to reach a specific boundary between these two bases in order to respect the rights of stakeholders.

3. Methodology

In terms of data type, this study is classified as a semi-experimental and post-event study in the field of financial knowledge positive research, which is implemented using the neural network analysis method and other related analyses. Therefore, in terms of results, this study can be classified as an applied research, which is of a correlational and algorithmic type in terms of implementation. Therefore, first, based on a set of analytical instructions through software such as MATLAB and WEKA software, an attempt is made to examine the evaluation processes of artificial neural network algorithms, and then, by comparing the selected algorithms, the best type of analysis is determined from the perspective of evaluating financial ratios to determine the prediction of the probability of fraud in companies. It should be noted that the analytical implementation in this process is

based on three analytical steps, which include; extracting financial ratios, evaluating extracted financial ratios, and finally neural networking of the evaluated algorithms.

4. Result

In this study, first, by systematically reviewing the literature related to the research field over the past few years, an attempt was made to select financial ratios appropriate for evaluating fraud in capital market companies. Then, based on quadratic programming (QP), an attempt was made to determine the basic algorithm for evaluating the accuracy of corporate fraud based on observations (year-company) by eliminating the gap between the predicted and actual data obtained from the identified financial ratios. Therefore, through the adaptive neural fuzzy inference logic (ANFIS) test and the cross-validation process or so-called "k-fold", it was determined that the unsupervised learning algorithm, which includes a set of evaluation parameters based on the meta-heuristic algorithm and has higher accuracy of predictions based on the observed data, was selected as the basis for the algorithms of this study. In order to create a reference index, based on the financial ratios of the companies' fraud probability assessment, the decile process was used to determine which companies from the deciles with a coefficient of " $D > 1$ " can help distinguish between companies in terms of financial health and companies with fraud probability in the test and control evaluation scales, namely, constant return to scale (CRS) and variable return to scale (VRS). The results indicate that companies with fraud probability are placed in 4 deciles, which indicates that two genetic and bee colony selection algorithms were used to further evaluate the accuracy of predicting financial fraud in the decile-classified companies. Finally, it was found that the bee colony algorithm has a higher accuracy coefficient in predicting the accuracy of fraud probability of the companies under study compared to the genetic algorithm. It was also found that the ratio of net profit to sales is the most important criterion for evaluating the accuracy of predicting the probability of fraud in the companies under study.

5. Discussion

In interpreting the results obtained, it should first be noted that the bee colony algorithm has higher functions in solving a complex problem due to its multiple process optimization through collective intelligence. In fact, this algorithm can be more effective in financial decision-making at the capital market level because it has higher convergence power and accuracy in predicting the probability of fraud of the companies under study compared to the genetic algorithm. In addition, the coefficients obtained in the bee colony algorithm indicate a more effective optimization of financial ratios in predicting the probability of fraud of companies. Because financial decision-makers can use this algorithm for more accurate evaluations based on financial ratios so that they can identify companies with a probability of fraud and not buy the shares of these companies in forming a portfolio.

6. Conclusion

Based on the importance of the issue of fraud in financial decision-making, investors are advised to reduce the percentage of possible risks of predicting financial fraud in companies by improving the level of technical analysis training in stock portfolio formation. The most important recognition of analytical techniques can be related to prediction methods based on unsupervised learning algorithms, because focusing on the set of algorithms of this method creates greater recognition in decision-makers who, by focusing on the true nature of the data and without manipulating or mapping them, can identify a set of predictable patterns, structures, and relationships of financial fraud in companies.

Keywords: Financial Fraud, Artificial Neural Network, Quadratic Programming

پیش از انتشار

الگوی تشخیصِ تقلبِ مالی تحتِ اجرای ارزیابی الگوریتم‌های مطلوبیتِ شبکه عصبی مصنوعی

مرضیه پورساعدی^۱ | دانشجوی دکتری، گروه حسابداری، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران

محمود همت‌فر^{۲*} | دانشیار، گروه حسابداری، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران. Email: M.hematfar@iaub.ac.ir.com

سید عنایت‌الله علوی^۳ | استادیار، گروه کامپیوتر، دانشکده مهندسی، دانشگاه شهید چمران اهواز، اهواز، ایران

رویا نصیرزاده^۴ | استادیار، گروه آمار، دانشکده علوم، دانشگاه فسا، فسا، ایران

چکیده

هدف این مطالعه، مدل‌سازی تشخیصِ تقلبِ مالی شرکت‌ها تحتِ اجرای ارزیابی الگوریتم‌های مطلوبیتِ شبکه عصبی مصنوعی می‌باشد. در این مطالعه با استفاده از فرآیندهای برنامه‌ریزی مجددی «QP» در الگوریتم‌های شبکه عصبی مصنوعی، تلاش شده است تا طی چندین مرحله براساس داده‌های زمانی ۱۳۹۲ تا ۱۴۰۱، اقدام به تعیین الگوریتم پایه در وهله اول و انتخاب پارامترهای تکنیکال شبکه عصبی مصنوعی در وهله دوم گردد. سپس با توسعه یک مدل تشخیصی براساس دو مقیاس آزمون و کنترل، الگوریتم‌هایی فرابتکاری که بالاترین ضرایب دقت در پیش‌بینی صحت تقلب مالی را دارند، در سطح شرکت‌های بازار سرمایه مورد بررسی قرار گیرند. لذا براساس فرآیند نمونه‌گیری سیستماتیک، تعداد ۹۵ شرکت بورس اوراق بهادار انتخاب شدند تا براساس ۹۵۰ مشاهده (سال-شرکت)، حد فاصل شرکت‌های دارای سلامت مالی با شرکت‌های دارای احتمال تقلب مالی از طریق دهک‌بندی تعیین گردد و شرکت‌های قرار گرفته در دهک‌های دارای تقلب مالی، از طریق پارامترهای مطلوبیت شبکه عصبی مصنوعی مورد بررسی قرار گیرند. نتایج مطالعه نشان داد، الگوریتم یادگیری بدون نظارت که شامل مجموعه پارامترهای ارزیابی مبتنی بر الگوریتم فراابتکاری است، از صحت پیش‌بینی‌های مبتنی بر داده‌های برآورده شده بالاتری برخوردار می‌باشد. همچنین نتایج ناشی از صحت پیش‌بینی تقلب‌های مالی شرکت‌های دهک‌بندی شده براساس دو الگوریتم انتخابی ژنتیک و کلونی زنبور عسل نشان می‌دهد، الگوریتم کلونی زنبور عسل از ضریب دقت بالاتری در پیش‌بینی صحت احتمال تقلب شرکت‌های مورد بررسی برخوردار است. همچنین مشخص شد، نسبت سود خالص به فروش مهمترین معیار ارزیابی دقت پیش‌بینی احتمال تقلب در شرکت‌های مورد بررسی می‌باشد.

کلیدواژه‌ها: تقلب مالی، شبکه عصبی مصنوعی، برنامه‌ریزی مجددی

¹ 0009-0006-3489-6513

² 0000-0002-3976-9322

³ 0000-0003-0495-5704

⁴ 0000-0002-5302-3789

مقدمه

بازارهای مالی غالباً کارآمد، با در اختیار قراردادن فرصت‌های ارزیابی مناسب برای تصمیم‌گیری مطلوب، سطح متوازی از جریان گردش اطلاعات عملکردی شرکت‌ها را زمینه‌سازی می‌نماید تا جذابیت‌های ورود به این بازار، در مقایسه با سایر بازارها همچون بازارهای پولی به طور متداوم حفظ گردد (Ran et al., 2023). به ویژه پیاده‌سازی چنین فرآیندهایی می‌تواند در زمره ضرورت‌هایی استراتژیک مالی در اقتصاد کشورهای در حال توسعه‌ای تلقی گردد که بدلیل وجود محدودیت‌های تأمین منابع، با چالش‌های جدی مواجه هستند (Lisbinski and Burnquist, 2024). اما ارجاع به تجارب علمی و واقعیت عملکردی بازارهای مالی این کشورها، همواره نشان دهنده وجود رانت‌هایی از اطلاعات برای گروه‌های خاصی از تصمیم‌گیرندگان مالی می‌باشد که بدون داشتن نیاز به تخصص یا شیوه‌های ارزیابی تکنیکال و تحلیل‌های بنیادی، سطحی از عدم تقارن‌پذیری اطلاعات را به وجود می‌آورند (Lusardi and Mitchell, 2014). لذا همانطور که نظریه‌پردازانی همچون Bockel-Rickermann et al (2023) و Spann (2013) اذعان نموده‌اند، نیاز به تدوین الگوهای مدل‌سازی شده‌ی تشخیص سیستماتیک تلقب، می‌تواند تاحدی به دستیابی چنین توازی برای تصمیم‌گیری مالی متوازن مؤثر باشد. لذا از آنجاییکه تقلب زائیده‌ی تفکر فرصت‌طلبانه‌ای، به دلیل وجود شکاف‌های قانونی و استانداردهای اثرگذار مالی و گزارشگری است، که باعث می‌شود تا با تضييع فراگیر حقوق سرمایه‌گذاران و سهامداران، منافع ناشی از دستکاری در صورت‌های مالی و ساختگی‌سازی اطلاعات، صرفاً به گروهی از اقلیت‌های دارای احاطه بر شرایط بازارهای مالی اختصاص یابد، توسعه مدل‌سازی سیستماتیک بر روی این پدیده منفی مالی در بازارهای سرمایه کشورهای در حال توسعه می‌بایست به عنوان یک اهرم مؤثر در تصمیم‌گیری‌های مالی متوازن مدنظر قرار گیرد (Zhou et al., 2024).

براین اساس تقلب در گزارشگری را بدون شک می‌بایست یک مساله جدی در نظام مالی کشورها تلقی نمود که گستره‌ای از ریسک‌های مبتنی بر عدم قطعیت را برای سرمایه‌گذاران و تصمیم‌گیرندگان مالی به همراه دارد (du Toit, 2024). لذا ارجاع به برخی از تجارب شرکت‌های تجاری در عرصه‌ی بازارهای مالی سراسر جهان مانند شرکت توشیبا ژاپن در سال ۲۰۱۵ (Foster, 2015)، قهوه لاکین چین در سال ۲۰۱۹ (Sender et al., 2020) و وایرکارد آلمان در سال ۲۰۲۰ (Teichmann et al., 2023) نشان دهنده‌ی رسوایی مالی ناشی از تقلب، به واسطه تمرکز بیش از اندازه بر تداوم فعالیت‌های حسابرسی بدون توسعه‌ی الگوهای تشخیص سیستماتیک تقلب مالی می‌تواند تلقی شود (یوخنه‌القیانی و همکاران، ۱۴۰۰). به عبارت دیگر، تغییر پارادایم‌های سنتی و کلاسیک در عرصه‌ی تشخیص شیوه‌های تقلب از طریق الگوریتم‌های

مطلوبیت شبکه عصبی مصنوعی، امروزه به یک نیاز تکنیکال جهت ارتقاء تصمیم‌گیری‌های مالی در نظام بازار سرمایه بدل شده است که به واسطه‌ی مدل‌سازی‌های اقتضایی در شناسایی عملکردهای مالی متقلبانه‌ی شرکت‌ها می‌تواند به پویایی بالاتر فرآیند گردش سیستماتیک اطلاعات کمک نماید (Motie and Raahemi, 2024). چراکه با پیچیده‌تر شدن سیستم‌های مالی و افزایش احتمال پنهان‌سازی عملکردهای منفی شرکت‌ها، به واسطه‌ی ظهور کارکردهای وسیع هوش مصنوعی از طریق مدل‌زبانی بزرگ «Large language Models» (LLM) یا توسعه‌ی جی‌پی‌تی «Generative Pre – Input Transformer» (GPT) در بستر یادگیری ماشینی «Machine Learning» (ML) از یک سو و ظهور تبادلات ناشی از دارایی‌های دیجیتال مثل توکن‌های غیرقابل معاوضه «Non – Fungible Token» (NFT) یا انواع رمزارزها از سویی دیگر، نیاز به الگوریتم‌های مدل‌سازی شده‌ی شبکه عصبی برای تشخیص سیستماتیک تقلب را می‌تواند حائز اهمیت نماید.

در واقع ظهور چنین فناوری‌های مالی به عنوان یک شمشیر دولبه در بازار سرمایه، ضمن اینکه می‌تواند به شفافیت بیشتر کمک کند، در عین حال گستردگی تقلب‌های مالی ماحصل دیگری از این تحولات دیجیتال محسوب شود که در این راستا نیاز به مدل‌سازی‌های سیستماتیک شناسایی تقلب شرکت‌ها، را بیش از پیش به یک ابزار استراتژیک در شیوه‌های تحلیل مالی بدل نموده است (Shoetan and Familoni, 2024). شیوه‌هایی که به دلیل ضعف در نظارت‌های ساختاری یا عدم توسعه‌ی ابزارهای مالی تشخیصی مناسب برای کنترل ریسک فاکتورهای مؤثر بر تقلب مالی شرکت‌ها، باعث تحمیل هزینه‌های زیادی بر سرمایه‌گذاران به ویژه در کشورهای در حال توسعه شده است (ملکی کاکلر و همکاران، ۱۴۰۰). به طور مصداقی تر اختلال‌هایی از نوع دخالت نهادی یا حاکمیتی در سطح فرآیندی اجرای نظارت اثربخش بر انعکاس شفاف عملکردهای مالی از یک سو و نبود آموزش‌های مالی بروز شده در بستر نرم‌افزارهای مالی توسعه‌یافته در بازار سرمایه از سویی دیگر، همگی به بخشی از بدنه‌ی نهی سرمایه‌گذاری در نظام مالی بازارهای در حال توسعه بدل شده است. با ارجاع به وقایع بازار سرمایه ایران، در طی سال‌های ۱۳۹۸ تا ۱۴۰۰ می‌توان دریافت که به دلیل ضعف نهادی یا خودخواسته‌ی دولتی، مبنی بر کاهش تورم از طریق جذب سرمایه‌های نقدی عامه‌ی مردم در بورس اوراق بهادار، دستکاری‌های گسترده و متقلبانه‌ی شرکت‌ها و عدم پوشش تمام واقعیت‌های عملکردی به استفاده‌کنندگان اطلاعات کم برخوردار از نفوذ، به ایجاد یک ناترازی مالی گسترده در این بازار منتهی گردید و ریزش شدید قیمت سهام خریداری شده را، برای سرمایه‌گذاران ناآگاه از جریان تحلیلی، به همراه داشت (دادگر و همکاران، ۱۴۰۲).

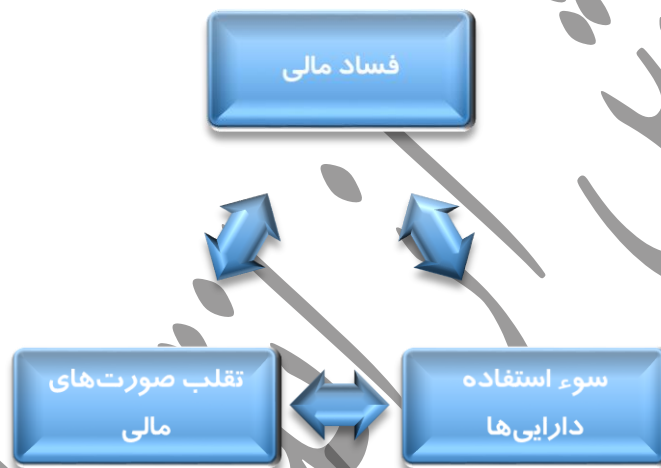
لذا این مطالعه با درک اهمیت شیوه‌های تحلیلی تقلب حتی با وجود پژوهش‌های زیادی که در بازار سرمایه ایران از نظر تحلیل‌های الگوریتمی انجام شده است، به دنبال مدل‌سازی تشخیص سیستماتیک تقلب مالی، تحت اجرای ارزیابی اثربخش الگوریتم‌های مطلوبیت شبکه عصبی مصنوعی می‌باشد. در واقع تفاوت این مطالعه با پژوهش‌هایی همچون آشوروزیا و همکاران (۱۴۰۲)؛ تشدید و همکاران (۱۳۹۸) و بهرامی و همکاران (۱۴۰۰) که از طریق الگوریتم‌های مختلف شبکه عصبی، اقدام به ارزیابی زمینه‌های تقلب مالی شرکت‌ها نموده‌اند، این است که مطالعه حاضر تلاش دارد ابتدا با تعیین معیارهای اصلی تأثیرگذار بر شناسایی رویه‌های تقلب مالی شرکت‌های بورس اوراق بهادار تهران در فرآیند بخش کیفی، غربالگری محتوایی سیستماتیک را از پژوهش‌های گذشته با هدف ایجاد یکپارچگی بالاتر انجام دهد تا براساس برنامه‌ریزی مجددی «Quadratic Programming (QP)» در الگوریتم‌های عصبی، با ایجاد زیرمجموعه‌های تصادفی و یا چندبخشی (k-fold) در تفکیک داده‌های واقعی از داده‌های قابل پیش‌بینی، نسبت به انتخاب مهم‌ترین الگوریتم اقدام شود تا با تعیین الگوریتم‌های مرجع، مدلی به واسطه‌ی مقیاس‌های کنترل و آزمون به وجود بیاید تا تعیین‌کننده‌ی مبنای تفاوت بین شرکت‌های متقلب با شرکت‌های دیگر در نظر گرفته شود.

۲- مبانی نظری

افشاء اطلاعات شفاف مالی به عنوان یک منبع مهم در تصمیم‌گیری‌های اقتصادی ذینفعان تلقی می‌شود که می‌تواند به توازن بازارهای سرمایه‌گذاری کمک شایان توجهی نماید (Uras, 2020). اما طی تحولات ساختاری نظری و پارادایمی عرصه‌ی شفافیت‌های مالی، تقلب به عنوان یک مبنای رفتاری و عملکردی به معضلی برای شفافیت‌های مالی شرکت‌ها بدل شده است (Sargiacomo et al., 2024). برای شناخت از تعریف رسمی تقلب مالی، بهترین مرجع، بند ۴ بخش ۲۴۰ استانداردهای حسابرسی ایران می‌باشد که در تعریف این پدیده مالی اشاره به اقدام تعمّدی شرکت‌ها توسط مدیران اجرایی، ارکان راهبری، کارکنان، یا اشخاص ثالث دارد که باعث تصاحب منافع غیر مشروعی می‌گردد که تضییع گسترده‌ی سایر ذینفعان را به همراه دارد (حسن‌پور و همکاران، ۱۳۹۹). اما نکته‌ی مهم این است که در بند ۹ همین استاندارد، بین تقلب و اشتباه تفاوت قائل شده‌اند و تنها ویژگی متمایزکننده تقلب از اشتباه را قصد و نیت تلقی نمودند که اساساً رسیدن به مرز مشخصی از این دو مبنای رعایت حقوق ذینفعان کار راحتی نمی‌باشد (اعتمادی و عبدلی، ۱۳۹۶). لذا تقلب مالی را می‌بایست کارکردی منفی بر تعامل بین شرکت‌ها با سایر استفاده‌کنندگان از اطلاعات تلقی نمود که به دلیل ضعف استانداردها و قوانین تجاری، فرصت‌هایی برای سوء استفاده در اختیار اداره‌کنندگان شرکت‌ها قرار می‌گیرد (کابلی و همکاران، ۱۳۹۹) که این مسئله می‌تواند تا مرز سقوط

و بروز بحران‌های مالی را برای شرکت‌ها به همراه داشته باشد (Smaili et al., 2020). ارجاع به بیانیه شماره ۸۲ هیئت استانداردهای حسابرسی در مورد تقلب نشان می‌دهد که حساب‌برسان به عنوان یکی از ارکان نهادی، ملزم به بررسی تمامی جوانب عملکردی شرکت‌ها هستند تا بتوانند مانع از تضييع حقوق سهامداران و سرمایه‌گذارانی گردند که به دلیل عدم آگاهی از قوانین و ساختارهای استانداردی، معمولاً حقوقشان نادیده گرفته می‌شود (Dezort & Lee, 1998). از طرف دیگر براساس گزارش انجمن بازرسان رسمی تقلب «The Association of Fraud Examiners» (ACFE)، می‌توان بروز تقلب حرفه‌ای را برای شناخت بهتر از ماهیت و نیت آن به سه دسته در قالب شکل (۱) ارائه نمود.

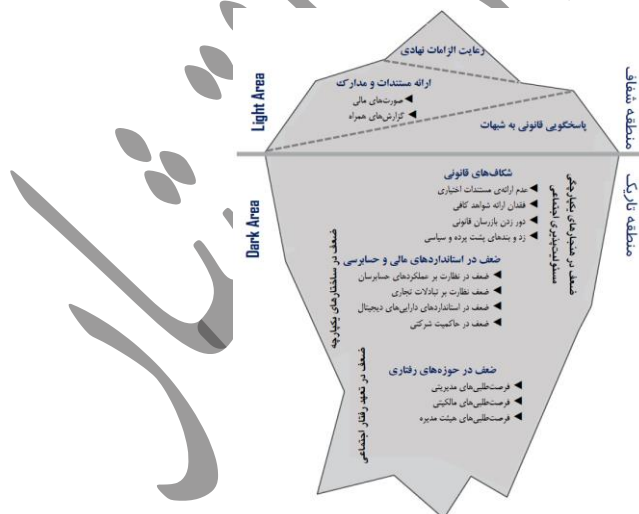
شکل ۱. انواع تقلب بر مبنای رویکرد انجمن بازرسان رسمی تقلب



براساس این رویکرد، می‌توان دریافت تقلب حرفه‌ای ماهیت مستقلی در ارزیابی حقوقی ندارد، بلکه کارکردی وابسته به سه عنصر فساد، سوء استفاده از دارایی‌ها و دستکاری در حساب‌ها برای گمراهی استفاده‌کنندگان از صورت‌های مالی می‌باشد. فساد مالی، را می‌توان تقلبی در سطح فردی و واحد سازمانی تلقی نمود. سوء استفاده از دارایی‌ها را می‌توان رفتاری جمعی در بهره‌برداری نادرست و نامشروع از دارایی‌های شرکت‌ها تلقی نمود و در نهایت تقلب صورت‌های مالی را دستکاری ناشی از منفعت‌طلبی ساختاری شرکت‌ها با هدف فریب استفاده‌کنندگان از صورت‌های مالی تعریف نمود (تشدید و همکاران، ۱۳۹۸). به لحاظ تأثیرگذاری منفی بر تصمیم‌های استفاده‌کنندگان از اطلاعات، می‌بایست وقوع تقلب مبتنی بر عدم شفافیت در صورت‌های مالی را مهمترین خروجی در تعاملات بین شرکت‌ها با ذینفعان تلقی نمود که می‌تواند به بروز شکاف‌های عمیق نمایندگی و ریسک‌هایی همچون سقوط قیمت سهام و ورشکستگی شرکت‌ها منتج گردد. به منظور شناخت بهتر ماهیت تقلب، نظریه‌های چندانی برای تفهیم آن در کارکردهای بازارهای مالی توسعه نیافته است، اما دو نظریه قله کوه یخی «Iceberg Theory» و نظریه سوسک حمام

«Cockroach Theory» احتمالاً سرآمدترین نظریه‌های مرتبط با این پدیده منفی در بازارهای مالی باشند. طبق نظریه قله کوه یخی که در شکل (۲) مشاهده می‌شود، شواهد ارائه شده مالی به صورت گزارشگری در دید همگان قرار دارد که رعایت الزاماتی است که براساس استانداردهای حسابداری می‌تواند مبنای تصمیم‌گیری‌های مالی قرار گیرد که براساس اسناد و مدارک قابل استناد به نهادهای ناظر همچون بازرسان قانونی و حسابرسان ارائه می‌شود. اما نیمه‌ی پایینی کوه یخی که قالب مشاهده نیست، اصطلاحاً «منطقه تاریکی» (Dark Area) شناخته می‌شود، که به واسطه‌ی وجود زمینه‌های رفتاری می‌تواند کارکردهای تقلب‌آمیزی تلقی گردد که به دلیل شکاف‌های قانونی، عدم نظارت‌های نهادی و فرصت‌طلبی‌های ساختاری شرکت‌ها به ضعف در حاکمیت شرکتی منتج می‌گردد و باعث شکاف عمیقی در شناخت از واقعیت‌ها، بین شرکت با سهامداران و سرمایه‌گذاران می‌گردد (Jiang & Cui, 2019). لذا طبق این نظریه، ناظران قانونی و حسابرسان در راستای وظایف محوله و مسئولانه‌ای که دارند می‌بایست به سراغ ناشناخته‌هایی بروند که الزاماً از طریق اسناد و مدارک ارائه شده قابل ارزیابی برای ارتقاء شفافیت‌های اطلاعاتی تلقی نمی‌شوند (Francis & Justine, 2023).

شکل ۲. فرآیندهای نظریه قله کوه یخی



بنابراین این نوع از تقلب‌ها به دلیل ضعف در قانونگذاری، تأمین‌کننده‌ی منافع نامشروعی هستند که باعث تضييع گسترده‌ی منافع سهامداران و سرمایه‌گذارانی می‌شوند که از دسترسی و نفوذ کافی به عملکردهای منفعت‌طلبانه‌ی شرکت‌ها برخوردار نیستند. از طرف دیگر نظریه سوسک حمام که توسط Blakley (2009) مطرح گردید، بر عادی شدن فرآیند تقلب مالی به صورت یک رفتار تکرارپذیر اشاره دارد. این نظریه با تشبیه به مضمون رفتار سوسک در ورود به محیط فاضلاب، اذعان می‌نماید که به دلیل

ویژگی‌های بیولوژیک این حشره، بزنگاهی برای زیستن می‌تواند به افزایش آن‌ها در یک زیستگاه بدل شود. لذا تقلب در محیطی که نظارتی وجود نداشته باشد، می‌تواند به تکثیر رفتارهای مشابهی در یک ساختار منتج شود که حتی در صورت مشاهده، امکان مقابله با آن به دلیل گستردگی فساد وجود ندارد.

لذا همانطور که نظریه‌های مرتبط با تقلب بر آن تأکید دارند، غالباً ماهیت این پدیده در سایه اتفاق می‌افتد جاییکه دسترسی به اسناد اثبات‌کننده رفتارهای ناهنجار مالی معمولاً دشوار است، چراکه تقلب آمیخته با نیاتی است که غالباً ارکان قدرت از آن برای رساندن به اهداف خود بهره می‌برند. از این رو محتمل‌ترین حالت در تفسیر بروز تقلب، پذیرش این ادراک نسبت به پدیده تقلب در ساختارهای شرکت‌ها است که بایستی همواره به صورت یک پیش‌فرض متداوم در اجرای فرآیندهای مالی آن را در نظر گرفت تا بتوان براساس مکانیزم‌هایی که امکان کشف تقلب را برای تصمیم‌گیرندگان مالی مشهود می‌نماید، تأثیرگذاری منفی آن را بر ذینفعان کاهش داد. لذا با اتکاء به این توضیح‌ها و ماهیت مطالعه، سوال‌های پژوهش به ترتیب زیر ارائه می‌شود:

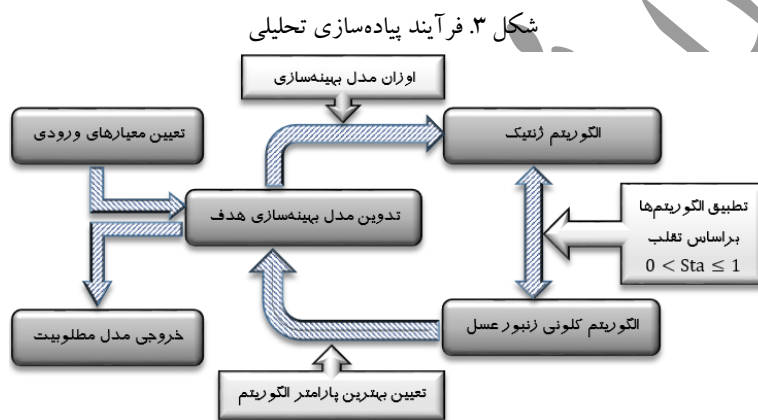
- ❖ سوال اول پژوهش) معیارهای ارزیابی بروز تقلب مالی در شرکت‌های بازار سرمایه کدامند؟
- ❖ سوال دوم پژوهش) الگوریتم پایه شبکه عصبی مصنوعی در ارزیابی بروز تقلب مالی در شرکت‌های بازار سرمایه کدامند؟
- ❖ سوال سوم پژوهش) مطلوب‌ترین الگوریتم‌های پایه شبکه عصبی مصنوعی بر اساس پارامترهای فرا ابتکاری کدامند؟

همانطور که مشاهده می‌شود، سوال اول پژوهش براساس یک فرآیند نظام مند در غربالگری سیستماتیک محتوایی، اقدام به تعیین معیارهای ارزیابی بروز تقلب مالی شرکت‌ها می‌نماید. سپس از طریق مجموع برنامه‌ریزی مجذوری «QP» در الگوریتم‌های عصبی، با ایجاد زیرمجموعه‌های تصادفی و یا چندبخشی (k - fold)، الگوریتم پایه برای پاسخ به سوال دوم پژوهش تعیین می‌شود تا در نهایت با تشکیل مقیاس‌های کنترل و آزمون در الگوریتم فرا ابتکاری به عنوان مبنای تحلیلی الگوریتم یادگیری بدون نظارت، اقدام به انتخاب الگوریتم‌های تکنیکال برای پیش‌بینی صحت زمینه‌های تقلب مالی شرکت‌ها می‌شود.

۳- روش شناسی

این مطالعه از نظر نوع داده در دسته مطالعه‌های نیمه‌تجربی و پس‌رویدادی در حوزه تحقیقات اثباتی دانش مالی قرار می‌گیرد که با استفاده از روش تحلیل شبکه عصبی و سایر تحلیل‌های وابسته، پیاده‌سازی می‌شود. لذا از نظر نتیجه، این مطالعه را می‌توان در دسته پژوهش‌های کاربردی طبقه‌بندی نمود که کارکرد آن به لحاظ اجرا، از نوع همبستگی و الگوریتمی می‌باشد. لذا ابتدا براساس مجموع دستورهای تحلیلی از

طریق نرم‌افزارهایی همچون متلب و نرم‌افزار WEKA تلاش می‌شود تا فرآیندهای ارزیابی الگوریتم‌های شبکه عصبی مصنوعی مورد بررسی قرار گیرد و سپس با مقایسه الگوریتم‌های انتخاب شده، بهترین نوع تحلیل از منظر ارزیابی نسبت‌های مالی جهت تعیین پیش‌بینی احتمال تقلب شرکت‌ها مشخص شود. لازم به ذکر است که پیاده‌سازی تحلیلی در این فرآیند براساس سه گام تحلیلی است که شامل؛ استخراج نسبت‌های مالی، ارزیابی نسبت‌های مالی استخراج شده و در نهایت شبکه‌سازی عصبی الگوریتم‌های مورد ارزیابی می‌باشد. لذا با استناد به توضیح‌های داده شده می‌توان فرآیندهای تشریح شده در پیاده‌سازی تحلیلی پژوهش را به ترتیب زیر ارائه نمود:



این چارچوب شاکله سه مرحله فوق را برای ارائه یک الگوی تشخیص تقلب در شرایط عدم قطعیت را نشان می‌دهد که می‌تواند با ارزیابی نسبت‌های مالی به بررسی این مسئله پردازد که چه سازوکاری در تشخیص تقلب‌های مالی شرکت‌ها می‌تواند به آگاهی‌های تصمیم‌گیرندگان مالی کمک نماید.

جامعه آماری و بازه زمانی پژوهش

واحد مورد بررسی در این مطالعه، شرکت‌های بازار سرمایه‌ای هستند که در بازه ۱۳۹۲ تا ۱۴۰۱ داده‌های مرتبط با هریک از نسبت‌های مالی را می‌توان براساس شرایط زیر، از آن‌ها استخراج نمود.

† در وهله اول شرکت‌هایی در این شرایط قرار می‌گیرند که تاریخ ورود آن به بورس اوراق بهادار قبل بازه زمانی مطالعه باشد و تا پایان دوره مورد بررسی، جزء شرکت‌های بورس اوراق بهادار قلمداد شوند.

† در وهله دوم شرکت‌های مورد مطالعه به عنوان واحد استخراج داده‌ها می‌بایست از سال مالی منتهی به پایان اسفندماه برخوردار باشند.

† همچنین شرکت‌های انتخابی به عنوان واحد استخراج نسبت‌ها، تغییر فعالیت در بازه سال مالی تعیین شده را نداشته باشد.

† شرکت‌های انتخاب شده، جزء شرکت‌های سرمایه‌گذاری و صندوق‌های بازنشستگی یا بیمه‌ای نباشند.

† طول وقفه انجام معاملات شرکت‌های مورد بررسی، بیش از ۶ ماه نباشد.
با مدنظر قراردادن معیارهای غربالگری حذف سیستماتیک، تعداد ۹۵ شرکت (۹۵۰ سال-شرکت) از ۲۵ صنعت مختلف به عنوان جامعه غربالگری شده، انتخاب گردیدند.

متغیرهای پژوهش

در این مطالعه به منظور یکپارچگی بیشتر تعیین معیارهای ارزیابی احتمال تقلب شرکت‌های بازار سرمایه، از فرآیند غربالگری نظام‌مند پژوهش‌های مشابه در بازه زمانی ۴ سال گذشته در داخل و خارج بهره برده شده است. لذا با ارجاع به پایگاه‌های اطلاعاتی مرجع و تعیین کلیدواژگان مشخص طبق جدول (۱)، تلاش شد تا پژوهش‌های مشابه با ماهیت مورد بررسی این مطالعه مورد غربالگری هدفمند قرار گیرند.
جدول ۱. کلمات کلیدی ارزیابی کارکردهای بازارهای بازاریابی بشر دوستانه

کلمات کلیدی جستجو در پژوهش‌های خارجی	کلمات کلیدی جستجو در پژوهش‌های داخلی
<ul style="list-style-type: none"> ▪ Financial Fraud ▪ Neural Network Algorithms for Fraud Prediction ▪ Financial Fraud Risks ▪ Fraudulent Reporting ▪ Data Mining to Detect Fraud 	<ul style="list-style-type: none"> ▪ تقلب مالی ▪ الگوریتم‌های شبکه عصبی پیش‌بینی تقلب ▪ ریسک‌های تقلب مالی ▪ گزارشگری متقلبانه ▪ داده کاوی کشف تقلب

براساس این کلمات کلیدی، مطابق با شکل (۴) اقدام به ارزیابی دو مرحله‌ی پژوهش‌های اولیه شناسایی شده در بازه زمانی ۲۰۲۰ تا ۲۰۲۴ و ۱۳۹۹ تا ۱۴۰۳ می‌شود. در واقع در غربالگری اول ماهیت محتوایی پژوهش‌ها و نزدیکی به نوع تدوین سوالات مدنظر قرار گرفت و در غربالگری دوم نیز، فرآیندهای تحلیلی مورد استفاده بررسی شد.

شکل ۴. ارزیابی دو مرحله‌ای پژوهش‌های اولیه شناسایی شده



با تعیین ۷ پژوهش ناشی از غربالگری نتیجه‌ی ارزیابی دو مرحله‌ی اولیه پژوهش‌های شناسایی شده، در ادامه با مرور نظام‌مند متون پژوهش‌های انتخاب شده، اقدام به تعیین معیارهای مؤثر در پیش‌بینی احتمال تقلب مالی شرکت‌ها می‌شود که نتایج آن در جدول (۲) ارائه شده است.

جدول ۲. غربالگری نظام‌مند شناسایی معیارهای مؤثر در پیش‌بینی احتمال تقلب مالی

معیارهای ارزیابی	Zhou et al (2024)	Motie and Raahemi (2024)	du Toit (2024)	Zhang et al (2022)	Craja et al (2020)	جفری و همکاران (۱۴۰۲)	ملکی کاکر و همکاران (۱۴۰۰)	جمع فراوانی
نسبت جاری	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	۴
نسبت تمرکز سرمایه (وام)	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	-	-	۳
نسبت دارایی جاری به کل دارایی‌ها	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	۵
نسبت انعطاف‌پذیری سرمایه	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	۳
نسبت دارایی ثابت به کل دارایی‌ها	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	۴
نسبت سود انباشته به کل دارایی‌ها	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	۴
نسبت وجوه مالکانه	-	<input checked="" type="checkbox"/>	-	-	-	-	<input checked="" type="checkbox"/>	۲
نسبت سرمایه در گردش به کل دارایی‌ها	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	-	۴
نسبت کل بدهی به کل دارایی‌ها	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	۴
نسبت دوره وصول مطالبات	-	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	-	-	۲
نسبت پوشش هزینه مالی	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	-	-	-	۲
نسبت سود ناخالص به کل دارایی‌ها	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	۴
نسبت سود هر سهم	-	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	-	-	۲
نسبت کل بدهی به حقوق صاحبان سهام	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	۴
نسبت نوسان (انحراف معیار) سودآوری	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	۳
نسبت سود انباشته به کل دارایی‌ها	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	۴
نسبت فروش به کل دارایی‌ها	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	-	-	-	<input checked="" type="checkbox"/>	۴
نسبت دوره بازپرداخت بدهی	-	<input checked="" type="checkbox"/>	-	-	-	<input checked="" type="checkbox"/>	-	۲
تسبیت بدهی بلندمدت به حقوق صاحبان سهام	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	۵
نسبت بهای تمام شده کالای فروش رفته به کل فروش	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	۴
نسبت سود خالص به کل دارایی‌ها	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	۴
نسبت استقلال مالی	<input checked="" type="checkbox"/>	-	-	-	-	-	<input checked="" type="checkbox"/>	۲
نسبت سود ناخالص به فروش	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	-	<input checked="" type="checkbox"/>	۴
نسبت منابع استقراری به دارایی‌های غیر جاری	-	-	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	-
نسبت سود عملیاتی به فروش	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	۴

نسبت آتی	-	-	☑	-	☑	-	-	۲
نسبت سود خالص به حقوق صاحبان سهام	☑	-	☑	☑	-	☑	-	۴
نسبت هزینه‌های مالی به کل بدهی‌ها	-	☑	☑	☑	☑	☑	-	۵
نسبت گردش دارایی‌ها	☑	-	☑	-	-	-	-	۲
نسبت سود خالص به فروش	☑	-	☑	☑	-	☑	-	۴
نسبت هزینه‌های عملیاتی به فروش	-	☑	-	☑	☑	☑	-	۴
نسبت خالص سرمایه در گردش به کل بدهی‌ها	☑	-	-	-	-	-	-	۲
نسبت حساب‌های دریافتی به فروش	☑	-	-	☑	☑	-	-	۴
نسبت وام اخذ شده به وجود مالکانه	-	☑	-	-	-	-	☑	۲
نسبت موجودی‌ها به فروش	-	☑	-	☑	-	☑	☑	۴
نسبت گردش دارایی ثابت	☑	-	☑	-	-	-	-	۲
نسبت موجودی نقد به کل دارایی‌ها	☑	-	☑	-	☑	☑	-	۴
نسبت گردش سرمایه گذاری	-	☑	-	-	-	-	☑	۲
نسبت سود خالص به سود ناخالص	☑	-	☑	☑	☑	-	☑	۵
نسبت جریان وجه نقد عملیاتی به کل دارایی‌ها	-	☑	☑	☑	-	☑	-	۴
نسبت بازده دارایی‌ها	☑	-	-	☑	-	-	-	۳

لذا همانطور که مشاهده می‌شود، ۲۴ نسبت مالی برای ارزیابی پیش‌بینی تقلب مالی شرکت‌های بورس اوراق بهادار تهران انتخاب شدند تا از طریق الگوریتم‌های شبکه عصبی مورد بررسی قرار گیرند.

یافته‌های پژوهش

باتوجه به تعیین معیارهای ارزیابی تقلب شرکت‌ها در بخش کیفی که شامل ۲۴ نسبت مالی می‌باشد، در ادامه مجموعه براساس برنامه‌ریزی مجذوری «QP» که در مطالعه‌هایی با توالی تکنیک‌های یادگیری ماشین بردار در الگوریتم‌های شبکه عصبی اجرا می‌شود و از روش‌های لاگرانژ افزوده به عنوان مبنای حل بهینه در مسائل استفاده می‌کند، بهره برده می‌شود. برای این منظور ابتدا می‌بایست براساس سه مبنای پایه

ی

❖ الگوریتم‌های یادگیری نظارت شده یا نظارتی «Supervised Learning Algorithms»

❖ الگوریتم‌های یادگیری بدون نظارت «Unsupervised Learning Algorithms»

❖ الگوریتم‌های تقویتی «Reinforcement learning algorithms»

از طریق روش آموزش (Train)، نسبت به واریانس اعتبار (CV) به عنوان یک روش توسعه یافته و مورد پذیرش برای آنالیز صحت پیش‌بینی در شبکه عصبی برای انتخاب یکی از سه الگوریتم یاد شده، اقدام شود تا امکان ارزیابی مناسب را همراستا با داده‌های مطالعه ایجاد نماید. لذا به طور خلاصه ابتدا هر سه الگوریتم فوق توضیح داده می‌شود تا در ادامه براساس زیرمجموعه‌های تصادفی و یا چندبخشی ($k -$

fold) در تفکیک داده‌های واقعی از داده‌های قابل پیش‌بینی، نسبت به انتخاب مهم‌ترین الگوریتم در این مطالعه اقدام شود.

🌀 الگوریتم‌های یادگیری نظارت شده یا نظارتی

در این الگوریتم معمولاً داده‌هایی که در محیط آزمایشگاهی نگاشت می‌شوند استفاده می‌شود تا از طریق تکامل داده‌ها، نسبت به ارزیابی تغییرات آن اقدام شود. در یادگیری نظارت شده، الگوریتم با مجموعه‌ای از داده‌های ورودی همراه با خروجی‌ها یا برجسب‌های مورد نظر مربوطه ارائه می‌شود. هدف یادگیری یک تابع نگاشت است که بتواند خروجی ورودی‌های جدید و نادیده را به دقت پیش‌بینی کند.

🌀 الگوریتم‌های یادگیری بدون نظارت

الگوریتم‌های یادگیری بدون نظارت، دسته‌ای از الگوریتم‌های عصبی، تلقی می‌شوند که با تمرکز بر روی ماهیت واقعی داده‌ها و بدون برجسب زنی یا نگاشت آن‌ها در پی کشف الگوها، ساختارها و روابطی هستند که الزاماً ممکن است شواهدی برای آن در گذشته وجود نداشته باشد. این الگوریتم برخلاف یادگیری تحت نظارت که در آن الگوریتم از داده‌های برجسب‌گذاری شده یاد می‌گیرد، یادگیری بدون نظارت بر یافتن ساختارها و الگوهای ذاتی درون خود داده تمرکز می‌کند.

🌀 الگوریتم‌های تقویتی

الگوریتم‌های یادگیری تقویتی دسته‌ای از الگوریتم‌های عصبی هستند که از طریق تعامل با یک محیط برای به حداکثر رساندن سیگنال عملکردی آن‌ها مورد بررسی قرار می‌گیرند. لذا با ترکیب با متغیرهای ثانویه، تلاش می‌شود تا ماهیت درونی داده‌های مورد بررسی از طریق آزمون و خطا مشخص شوند.

لذا با تعیین معیارهای ارزیابی احتمال تقلب مالی که از طریق فرآیند غربالگری محتوایی سیستماتیک تعیین گردید، اقدام به تفکیک ارزش واقعی با ارزش فازی می‌شود. برای این منظور با تعیین مقادیر فازی و واقعی براساس مجموع نسبت‌های مالی طبق ۹۵۰ مشاهده (سال-شرکت) از طریق دو معیار « R^2 » و «MSE» درصد پیش‌بینی صحیح مقادیر شاخص‌های مالی نسبت به مقدار واقعی تعیین می‌شود. براساس این نتیجه مشخص شده است، هر قدر مجموع شاخص‌های مالی به ۱/۰۰ نزدیک‌تر باشند، می‌تواند در ارزیابی الگوریتم‌های شبکه عصبی مورد استفاده قرار گیرد. لذا طبق نتیجه جدول (۳) شاخص‌های تقلب مالی براساس دو معیار « R^2 » و «MSE» نشان دهنده‌ی تفاوت مقادیر واقعی و فازی براساس ۹۵۰ مشاهده می‌باشد.

جدول ۳. مقادیر واقعی و پیش‌بینی شده در خصوص پیش‌بینی نسبت‌های مالی

مشاهده واقعی الگوریتم شبکه عصبی

R ²		MSE	
۰.۵۵۵	۰.۳۶	۰.۱۱۱	۱
۰.۷۴۵	۰.۴۵۳	۰.۰۵۳	۲
۰.۷۶۹	۰.۴۸۵	۰.۰۴۱	۳
۰.۷۹۸	۰.۴۴۶	۰.۰۱	۴
۰.۸۸۲	۰.۵۸۲	۰.۱۶۶	۵
۰.۵۰۸	۰.۴۳	۰.۲۶۶	۶
۰.۷۹۵	۰.۳۰۹	۰.۱۵۱	۷
۰.۸۷۱	۰.۱۹۴	۰.۱۰۴	۸
۰.۸۹۳	۰.۱۰۲	۰.۱۰۴	۹
۰.۸۹۵	۰.۲۸۲	۰.۴۸۵	۱۰
...
۰.۹۴۱	۰.۰۳	۰.۰۴۸	۹۵۰

با تعیین این مقادیر براساس ۹۵۰ مشاهده انجام شده، جهت تعیین درصد پیش‌بینی صحیح نسبت‌های مالی برای ارزیابی احتمال تقلب نسبت به مقدار واقعی، می‌بایست از کدهای دستوری نروفازی (ANFIS) در پایتون به عنوان مبنای ارزیابی الگوریتم‌های شبکه عصبی بهره برده می‌شد، که اطلاعات آن در شکل (۵) ارائه شده است.

شکل ۵. تعیین درصد تناسبی پیش‌بینی صحیح مقادیر شاخص مالی تعیین تقلب نسبت به مقدار واقعی

array: array_like of rank N

Input array

pad_width : {sequence, array_like, int}

Number of values padded to the edges of each axis. ((before_1, after_1), ... (before_N, after_N))

unique pad widths for each axis. ((before, after),) yields same before and after pad for each axis.

(pad,) or int is a shortcut for before = after = pad width for all axes.

mode : str or function

One of the following string values or a user supplied function.

'constant'

Pads with a constant value.

'edge'

Pads with the edge values of array.

'linear_ramp'

Pads with the linear ramp between end_value and the array edge value.

'maximum'

Pads with the maximum value of all or part of the vector along each axis.

'mean'

Pads with the mean value of all or part of the vector along each axis.

'median'

Pads with the median value of all or part of the vector along each axis.

'minimum'

Pads with the minimum value of all or part of the vector along each axis.

‘reflect’

Pads with the reflection of the vector mirrored on the first and last values of the vector along each axis.

‘symmetric’

Pads with the reflection of the vector mirrored along the edge of the array.

‘wrap’

Pads with the wrap of the vector along the axis. The first values are used to pad the end and the end values are used to pad the beginning.

<function>

Padding function, see Notes.

stat_length : sequence or int, optional

Used in ‘maximum’, ‘mean’, ‘median’, and ‘minimum’. Number of values at edge of each axis used to calculate the statistic value.

((before_1, after_1), ... (before_N, after_N)) unique statistic lengths for each axis.

((before, after),) yields same before and after statistic lengths for each axis.

(stat_length,) or int is a shortcut for before = after = statistic length for all axes.

Default is **None**, to use the entire axis.

constant_values : sequence or int, optional

Used in ‘constant’. The values to set the padded values for each axis.

((before_1, after_1), ... (before_N, after_N)) unique pad constants for each axis.

((before, after),) yields same before and after constants for each axis.

(constant,) or int is a shortcut for before = after = constant for all axes.

Default is 0.

end_values : sequence or int, optional

Used in ‘linear_ramp’. The values used for the ending value of the linear_ramp and that will form the edge of the padded array.

((before_1, after_1), ... (before_N, after_N)) unique end values for each axis.

((before, after),) yields same before and after end values for each axis.

(constant,) or int is a shortcut for before = after = end value for all axes.

Default is 0.

reflect_type : {‘even’, ‘odd’}, optional

Used in ‘reflect’, and ‘symmetric’. The ‘even’ style is the default with an unaltered reflection around the edge value. For the ‘odd’ style, the extended part of the array is created by subtracting the reflected values from two times the edge value.

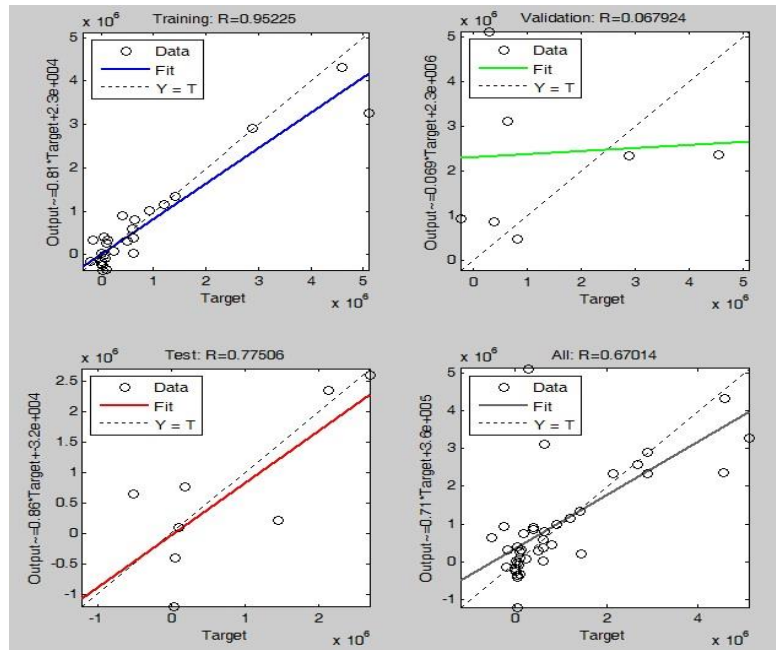
نتایج حاصل نشان می دهد، طبق دو مقیاس « R^2 » و «MSE»، تقریباً ۶۶٪ درصد پیش بینی نسبت های

تعیین شده، به درستی احتمال تقلب های مالی شرکت ها را شناسایی می کنند و درصد خطای احتمالی نیز

براساس تعداد مشاهدات، برابر با ۰/۰۶ است. فرآیند کسب شده در شکل (۶) نشان دهنده صحت درصد

پیش بینی صحیح نسبت های مالی تعیین شده برای ارزیابی احتمال تقلب مالی شرکت ها می باشد.

شکل ۶. درصد پیش بینی صحیح مقادیر نسبت های مالی ارزیابی تقلب نسبت به مقدار واقعی



در ادامه و براساس منطق استنتاج فازی عصبی انطباق‌پذیر «Adaptive Neuro – Fuzzy Inference System» (ANFIS) می‌بایست، منطقی جهت انجام آزمون واری اعتباری برای تعیین بهترین مقادیر ایجاد نمود. در واقع این آزمون که اصطلاحاً به آن روش آموزش گفته می‌شود، اقدام به ارزیابی مطلوبیت فرآیندهای تحلیلی شبکه عصبی فازی برای تعیین اعتبارسنجی انتخاب الگوریتم‌ها می‌نماید. لذا از طریق از روش آموزش (Train) به وسیله معیار واری اعتبار (CV) اقدام کرد. بر این اساس معیارهای MMC، f -measure، recall، precision و accuracy مبنای تعیین مطلوبیت الگوریتم‌های شبکه عصبی قرار می‌گیرند. براساس مراحل زیر و بسط معادلات ریاضی اقدام به انجام تحلیل روابط برای تعیین مقادیر مشاهده شده تا مقادیر پیش‌بینی شده را در بازه ۱ تا ۱- نشان می‌دهد.

اعتبارسنجی ضربداری یا اصطلاحاً k -fold یکی از عمومی‌ترین انواع اعتبارسنجی در تحلیل‌های فازی است که با استفاده از گام‌های زیر انجام می‌شود. مجموعه داده اصلی را به k زیرمجموعه مساوی تقسیم می‌کنیم. هر زیرمجموعه یک fold نامیده می‌شود که برای تعریف فولدها به صورت f_1, f_2, \dots, f_k نام گذاری می‌شود.

For $i = 1$ to $i = k$

رابطه (۱)

فولد f_i را به عنوان مجموعه اعتبارسنجی محسوب می‌شود و همه $k - 1$ فولد باقی مانده را در

مجموعه آموزشی اعتبارسنجی ضربداری «Cross validating training set» برآورد می‌شود.

سپس براساس یادگیری ماشین بردار با استفاده از مجموعه داده‌های قرار گرفته شده در موقعیت فازی سلسله مراتبی؛ ویکور و تاپسیس که از طریق نرم‌افزار WEKA ترتیب داده می‌شوند، میزان صحت هر کدام از آن‌ها در هر سه حالت فوق مورد بررسی قرار می‌گیرد. در این پژوهش، از روش اعتبارسنجی k -باره (k -تایی) استفاده شد. در این روش کل داده‌ها به K دسته تقریباً مساوری تقسیم می‌شوند. $(K - 1)$ دسته برای آموزش مدل و دسته باقیمانده برای آزمایش مدل به کار می‌رود. به این ترتیب به تعداد K مرتبه مدل آموزش و آزمایش مورد محاسبه قرار می‌گیرد (He et al., 2019). لذا برای تقسیم‌بندی کل داده‌ها به مجموعه داده‌های آموزش (سه حالت موردنظر) و آزمایش (تعاریف پیش فرض براساس داده‌ها) به روش اعتبارسنجی ۱۰ باره استفاده شده است. لذا براساس دستور Stratified cross-validation ۲۴ نسبت مالی ارزیابی احتمال تقلب مالی طبق نتیجه جدول (۴) تعیین کننده الگوریتم پایه براساس روش آموزش و معیار اعتبار واری می‌باشد.

جدول ۴. اعتبارسنجی گزاره‌های پژوهش

مقادیر	MMC	f-measure	recall	precision	accuracy	Rank
الگوریتم‌های یادگیری نظارت شده یا نظارتی	۷۱/۲۹	۵۲/۱۹	۷۰/۵۴	۶۶/۴۵	۸۹/۶۶	3 rd
الگوریتم‌های یادگیری بدون نظارت	۸۳/۸۷	۷۰/۱۶	۶۵/۴۷	۸۹/۱۰	۹۲/۰۹	1 st
الگوریتم‌های تقویتی	۶۹/۳۰	۵۷/۱۷	۸۳/۱۱	۷۰/۳۶	۸۴/۸۱	2 nd

همانطور که مشاهده می‌شود، مقدار الگوریتم‌های یادگیری بدون نظارت معیار متناسب تری از استنتاج فازی عصبی انطباق پذیر جهت سنجش نسبت‌های تعیین شده ارزیابی احتمال تقلب مالی محسوب می‌شود. لذا با توجه به اینکه الگوریتم فرا ابتکاری، مهمترین مبنای این نوع از فرآیندهای تحلیلی شبکه عصبی می‌باشد، در ادامه تلاش می‌شود تا نسبت به انتخاب بهترین الگوریتم فرا ابتکاری در پیش‌بینی تقلب مالی شرکت‌ها اقدام شود. لذا براساس تعاریف عملیاتی هریک از نسبت‌های مالی مؤثر در پیش‌بینی تقلب مالی، مدلی به ترتیب زیر با ضرایب الگوریتم فرا ابتکاری که پایایی آن در پژوهش Hidayattullah et al (2020) مورد تأیید قرار گرفته است، به ترتیب زیر ارائه نمود:

$$Sta(\sigma) = \sum_{i=1}^n \int_{i=1}^n \varepsilon_i \ln \prod_{j=1}^n Activ\ index \quad \text{رابطه (۲)}$$

در این رابطه؛ $Sta(\sigma)$ ضریب تقلب مالی است. $\sum_{i=1}^n Activ\ index$ مجموع نسبت‌های مالی شناسایی شده جهت ارزیابی تقلب شرکت‌ها می‌باشد. « $Activ\ index$ » اشاره به صحت داده‌های مورد بررسی در بازه زمانی « t » می‌باشد. ε_i ضریب محاسبه‌ی نسبت‌های ارزیابی تقلب مالی « $Activ\ index$ » می‌باشد. $\prod_{j=1}^n Activ\ index$ ادغام عملکرد مجموع ۲۴ نسبت ارزیابی تقلب مالی می‌باشد. در ادامه می‌بایست به پیروی از مطالعه (Ngai et al (2011)، منابع تجمعی مالی شرکت‌های i در سال t ، با عنوان $Sta_{i,t}$ ، به صورت رابطه (۳) تعریف شده است:

$$Sta_{i,t} = \text{Ln} [\sigma_{i,t} + \sum_1^t (1 - \gamma)^{\tau} \sigma_{i,t-\tau}] \quad \text{رابطه (۳)}$$

که در آن:

$Sta_{i,t}$ شاخص تقلب ناشی از تجمیع منابع مالی شرکت‌های i در سال t است و γ مجموعه نسبت‌های مالی ارزیابی تقلب شرکت‌ها می‌باشد.^۱ با تعیین مدل برای ورودی داده‌ها به الگوریتم فرا ابتکاری می‌بایست با تعیین دو بازه ۰ و ۱، مجموع معیارهای سنجش را بر مبنای تعیین تقلب یا عدم تقلب مالی شرکت‌ها محاسبه نمود. برای این منظور از شاخص ترکیبی «Composite Index» (CI) استفاده می‌شود.

برای پیاده‌سازی چنین فرآیندی، لازم بود تا نسبت به تعیین اوزان هر یک از نسبت‌های قرار گرفته در شاخص معیارهای شاخص ایجاد شده «CI» به گونه‌ای اقدام شود تا امکان ایجاد یک معیار مشخص برای ارزیابی تقلب مالی شرکت‌ها در قالب یک الگوی شبکه عصبی ممکن باشد. براین اساس، این فرآیند با ترکیب معیارهای استخراج شده در مرحله اول، امکان برآزش مطلوبیت الگوریتم‌های منتخب را برای تشخیص تقلب می‌دهد. بنابراین ۲۴ نسبت مالی ارزیابی تقلب انتخاب شده، مبنای تعیین تفاوت بین شرکت‌های متقلب با شرکت‌های دیگر قرار می‌گیرد. لذا رابطه (۴) برای مشترک کردن شاخص «CI» استفاده می‌شود.

$$Y = F(x_1, x_2, \dots, x_n) \quad \text{رابطه (۴)}$$

که در این رابطه؛

Y متغیر وابسته یا نماد $Sta(\sigma)$ مبنی بر سنجش تقلب مالی است، که تفاوت بین شرکت‌های دارای احتمال تقلب با شرکت‌های دیگر را نشان می‌دهد. به طوریکه اگر نسبت‌های مالی تعیین شده نشان دهنده‌ی سلامت مالی بالاتر باشند، شاخص ترکیبی (CI) برابر یک و در شرایطی که نسبت‌های مالی محاسبه شده، احتمال تقلب را نشان دهند، در این صورت شاخص ترکیبی (CI) برابر صفر منظور می‌شود. به علاوه بایستی بیان شود، طبق روش تحلیل تشخیصی، X_i نشان دهنده‌ی متغیرهای توضیحی می‌باشد که هر یک از پارامترهای ترکیب خطی را برای شناسایی شرکت‌های متقلب از طریق رابطه (۵) پیش‌بینی می‌کند:

$$D = V_1 X_1 + V_2 X_2 + \dots + V_i X_i \quad \text{رابطه (۵)}$$

که در این رابطه؛ D تابع تشخیصی؛ V وزن هر معیار در تابع؛ X متغیرهای توضیحی در تابع و i تعداد متغیرهای توضیحی می‌باشد.

لذا براساس این روابط، می‌بایست با توجه به نسبت‌های مالی تعیین شده جهت تفکیک شرکت‌ها براساس مشاهدات (سال-شرکت) به دو گروه احتمال تقلب و سلامت مالی، ضرایب استاندارد با استفاده از

^۱ حرف τ یک کلمه یونانی است که اشاره t سال در بررسی‌های داده‌های شرکت‌ها دارد.

^۲ این مطالعه برای سنجش مقادیر γ و τ از فروض گریلینز (۱۹۸۴) مقدار ثابت $\gamma = 0.4$ و دوره زمانی $\tau = 10$ را در رابطه (۱) استفاده نموده است.

روش تحلیل تشخیصی برآورد و در شاخص ترکیبی تعیبه شوند. لذا می‌بایست شاخص ترکیبی را براساس ۲۴ نسبت مالی شناسایی شده برای سنجش احتمال شرکت‌های دارای تقلب مالی، از طریق مجموع مشاهدات (شرکت-سال)، دهک‌بندی نمود تا تفاوت بین شرکت‌ها مشخص گردد. به عبارت دیگر می‌بایست از طریق دهک‌بندی مشاهدات (سال-شرکت) براساس خروجی داده کاوی نسبت‌های مالی، تفاوت بین شرکت‌ها از منظر تقلب و سلامت مالی مشخص شوند. طبق این الگو، مشاهدات با امتیاز پایین‌تر از نظر نسبت‌های سلامت مالی در دهک اول و مشاهدات با بالاترین سطح امتیاز نسبت‌های مالی تعیین شده، در دهک آخر قرار می‌گیرند. در ادامه نیز می‌بایست تمامی رتبه‌های دهک‌های تعیین شده در شاخص «CI» بر کل نسبت‌های مالی تقسیم گردد تا قرار گرفتن مشاهدات در رتبه‌های یک تا ده تعیین‌کننده‌ی تفاوت مبنای احتمال تقلب با سلامت مالی باشد. به طوریکه مقادیر بزرگتر (کوچک‌تر) بیانگر میزان سلامت مالی بالاتر (پایین‌تر) در مشاهدات مورد بررسی تلقی می‌گردد. استفاده از این شاخص ترکیبی، همچنین چولگی ناشی از محاسبه‌ی هریک از نسبت‌های مالی قابل سنجش را کاهش داده و معیار دقیق‌تری را برای آزمون فراهم می‌آورد.

جدول ۵. محاسبه شاخص ترکیبی تعیین تقلب از سلامت مالی

تکرار مشاهدات	مجموع شاخص	$D \geq 1392$	$D \geq 1393$	$D \geq 1394$	$D \geq 1395$	$D \geq 1396$	$D \geq 1397$	$D \geq 1398$	$D \geq 1399$	$D \geq 1400$	$D \geq 1401$	(MAX θ)	دهک‌ها
۴۳۵	۱/۰۰۰	۰/۰۹۷	۰/۰۷۳	۰/۰۴۷	۰/۰۲۱	۰/۰۲۳	۰/۰۹۸	۰/۱۸۷	۰/۱۶۷	۰/۱۰۶	۰/۸۰۷	پایینی	دهک اول
۱۰۹	۱/۰۰۶	۱/۰۰۰	۱/۰۰۰	۰/۱۱۶	۰/۸۰۲	۰/۴۰۳	۱/۰۰۰	۰/۴۷۱	۰/۶۴۳	۱/۰۰۰	۰/۹۸۳	مطلوب	دهک دوم
۸۷	۱/۳۳۲	۰/۴۲۴	۰/۰۹۸	۱/۰۰۰	۱/۰۰۰	۰/۵۴۹	۰/۸۹۴	۰/۹۲۲	۰/۷۴۵	۱/۰۰۰	۰/۵۵۶	مطلوب	دهک سوم
۱۴	۰/۸۹۸	۰/۸۴۷	۱/۰۰۰	۰/۵۵۲	۰/۴۱۱	۰/۶۲۵	۰/۱۱۱	۰/۲۳۹	۰/۱۳۲	۰/۲۸۵	۰/۳۱۷	بحرانی	دهک چهارم
۱۲۳	۱/۰۰۲	۰/۳۵۲	۰/۳۲۴	۰/۳۱۲	۱/۰۰۰	۰/۷۱۲	۰/۹۸۵	۰/۸۶۴	۱/۰۰۰	۰/۳۴۹	۰/۳۲۹	مطلوب	دهک پنجم
۳۱	۰/۰۷۴	۰/۹۱۱	۰/۲۲۲	۰/۳۰۵	۰/۳۲۶	۰/۳۳۷	۰/۲۴۵	۰/۲۱۸	۰/۴۲۴	۰/۱۹۶	۰/۱۲۹	بحرانی	دهک ششم
۶۵	۱/۸۳۹	۰/۷۴۲	۱/۰۰۰	۱/۰۰۰	۰/۹۲۸	۰/۷۴۳	۱/۰۰۰	۱/۰۰۰	۱/۰۰۰	۰/۶۳۵	۰/۷۶۳	عالی	دهک هفتم
۲۶	۰/۸۸۷	۰/۲۲۹	۰/۳۴۳	۰/۷۲۹	۰/۲۲۲	۰/۲۱۰	۰/۴۱۴	۰/۵۳۷	۰/۳۰۱	۰/۵۴۶	۰/۲۹۱	بحرانی	دهک هشتم

دهک نهم	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰
دهک دهم	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰	۱/۰

نتایج این جدول نشان می‌دهد، به دلیل اینکه مشاهدات ارزیابی شده، حکایت از قرار گرفتن دهک‌های چهارم؛ ششم؛ هشتم و دهم برابر با « $D > 1$ » با تعداد مجموع مشاهدات ۸۷ احتمال دارای ریسک تقلب نسبت به سایر مشاهدات در دهک‌های دیگر با ۸۶۳ مشاهده می‌باشد، در ادامه می‌بایست تفاوت بین شرکت‌های دارای سلامت مالی با شرکت‌های دارای احتمال تقلب را از طریق آزمون‌های باکس، لامبدای ویلکز و تشخیص کلونی، از نظر اعتبار مدل مورد بررسی قرار داد که نتایج آن در جدول (۶) مشخص شده است.

جدول ۶. نتایج آزمون باکس و لامبدای ویلکز و تابع تحلیل تشخیصی کانونی


نوع آزمون	مقدار آماره	سطح معناداری
باکس	۶۰/۳۰۹	۰/۰۰۰
لامبدای ویلکز	لامبدا ۰/۳۱۹	۰/۰۰۰
	Chi-Square ۱۹۳۷/۱۱	
تعداد مشاهدات (سال-شرکت) دارای احتمال سلامت مالی مطلوب یا متوسط از مجموع ۹۵۰ مشاهده	۸۶۳	
تعداد مشاهدات (سال-شرکت) دارای احتمال تقلب مالی از مجموع ۹۵۰ مشاهده	۸۷	
درصد پیش‌بینی صحیح مشاهدات (سال-شرکت) دارای احتمال سلامت مالی	۹۰/۸۴	
درصد پیش‌بینی صحیح مشاهدات (سال-شرکت) دارای احتمال تقلب مالی	۹/۱۶	
درصد پیش‌بینی صحیح احتمال تقلب مالی براساس تعداد مشاهدات	۰/۸۱۶	
ضریب همبستگی کلونی	۰/۸۱۶	

همانطور که نتایج نشان می‌دهد، ماتریس کواریانس دو گروه تفاوت معناداری با یکدیگر دارند. همچنین مقدار لامبدای ویلکز نیز بیانگر این است که نسبت مجذورات درون گروهی به کل مجموع مجذورات کوچک بوده و میانگین دو گروه با یکدیگر تفاوت دارند. این مقادیر از قدرت تشخیص بالای تابع حکایت داشته و نشان می‌دهد که مدل تحلیل تشخیصی برآورد شده از لحاظ آماری معنادار است. به علاوه مقدار ضریب همبستگی تابع تحلیل تشخیصی کلونی که برابر با ۰/۸۱۶ می‌باشد، نشان می‌دهد، صحت درصد تفاوت بین سلامت مالی شرکت‌ها با شرکت‌های دارای احتمال تقلب برابر با ۸۱/۶ درصد می‌باشد و این به معنای آن است که معیارهای شناسایی شده، از قابلیت مطلوبی برای ارزیابی شرکت‌های دارای احتمال تقلب برخوردار هستند، چراکه صحت پیش‌بینی صورت گرفته بیشتر از ۵۰ درصد می‌باشد. در واقع از آنجاییکه، مبنای تعیین درصد احتمال تقلب با سلامت مالی، مشاهدات مطالعه می‌باشد، لذا براساس دهک‌بندی مشخص شد، از مجموع ۹۵۰ مشاهده، تعداد مشاهدات دارای احتمال سلامت مالی مطلوب یا

متوسط برابر با ۸۶۳ مورد ($\vartheta = 863/950$) با درصد پیش‌بینی ۹۰/۸۴٪ و تعداد مشاهدات دارای احتمال تقلب مالی برابر با ۸۷ مورد ($\vartheta = 87/950$) با درصد پیش‌بینی ۹/۱۶٪ هستند که تفاضل یا حد فاصل پیش‌بینی در دو گروه (۹۰.۸۴٪ - ۹.۱۶٪) ($\vartheta = 90.84\% - 9.16\%$) حکایت از تعیین ۸۱/۶۸٪ صحت پیش‌بینی انجام شده براساس الگوی شاخص ترکیبی و داده کاوی مبتنی بر دهک‌بندی شرکت‌ها می‌باشد.

بنابراین می‌توان استنباط نمود، اگر مقادیر نسبت‌های مالی در شاخص مرجع مساوی یا بیش از ۱ ($\sigma \leq 1$) باشند، این به معنای آن است که احتمال سلامت مالی شرکت‌های مورد بررسی براساس مشاهدات (سال-شرکت) بالاتر از حد متوسط بازار سرمایه است و این موضوع نشان‌دهنده‌ی پایین بودن درجه آسیب‌پذیری در برابر ریسک‌های احتمالی همچون ریسک ورشکستگی می‌باشد که به آن عدد ۱ تعلق می‌گیرد. اما اگر مقادیر نسبت‌های مالی شرکت‌های مورد بررسی براساس مشاهدات (سال-شرکت) کوچکتر از ۰ ($\sigma > 0$) باشند، این به معنای آن است که احتمال سلامت مالی شرکت‌های مورد بررسی براساس مشاهدات (سال-شرکت) پایین‌تر از حد متوسط بازار سرمایه است و این موضوع نشان‌دهنده‌ی بالا بودن درجه احتمال تقلب مالی شرکت‌ها و افزایش ریسک‌های احتمالی همچون ریسک ورشکستگی می‌باشد که به آن عدد ۰ تعلق می‌گیرد. لذا براساس شکل (۸) براساس دو محور ورودی و خروجی مدل، دو مبنای بازده ثابت نسبت مقیاس (CRS) و بازده متغیر نسبت به مقیاس (VRS) مبنای تفکیک بین شرکت‌ها از نظر سلامت مالی با شرکت‌های دارای احتمال تقلب براساس مشاهدات (سال-شرکت) تلقی می‌شوند.

شکل ۸ مبنای شرکت‌ها از نظر احتمال تقلب با سلامت مالی



طبق شکل (۸) می‌توان دریافت با در نظر گرفتن مشاهده (سال-شرکت) i که در نقطه F فعالیت می‌کند، پایین بودن احتمال سلامت مالی، تحت بازده ثابت نسبت به مقیاس (CRS) با فاصله بین نقاط E و F (EF) نشان داده می‌شود. از طرف دیگر، تفاوت بین EF و UF ، یعنی EU ، نشان دهنده احتمال سلامت مالی بالاتر در نقطه G است. به عبارت دیگر، هر قدر نسبت‌های مالی ارزیابی احتمال تقلب در بازده متغیر نسبت به مقیاس (VRS) به نقطه‌ی بهینه « G » حرکت کنند، این به معنای آن است که سطح مطلوبیت سلامت مالی

بالاتر است، در حالیکه، قرار گرفتن مشاهده (سال-شرکت) در حد فاصل نقاط «F» و «U» می تواند به عنوان پایین بودن مبنای سلامت مالی و افزایش احتمال تقلب مالی شرکت های مورد بررسی قلمداد گردد. لذا با توجه به توضیح های داده شده، داده های دهک های بحرانی که مبنای تعیین احتمال شرکت های متقلب هستند، می بایست برای تعیین دو الگوریتم مطلوب از میان الگوریتم های فرا ابتکاری انتخاب شوند. به عبارت دیگر، شرکت های قرار گرفته در دهک های با ضریب « $D > 1$ » مبنای بررسی پارامترهای الگوریتم فرا ابتکاری می باشد. برای این منظور براساس توابع برازش مختلف، هریک از نزدیک ترین الگوریتم های فرا ابتکاری با مقادیر بحرانی دهک های تعیین شده، نسبت به انتخاب اقدام نمود. نکته ای قابل توجه این است که با توجه به اینکه هدف مطالعه در این بخش، دستیابی به مؤثرترین نسبت تعیین تقلب مالی شرکت ها براساس الگوریتم های شبکه عصبی یادگیری بدون نظارت می باشد که به عنوان پایه ارزیابی مبتنی بر صحت پیش بینی احتمال تقلب مالی شرکت ها در بخش اول تحلیل ها انتخاب شد، در این بخش از مجموعه ای الگوریتم فرا ابتکاری بهره برده می شود تا متناسب ترین الگوریتم های اجرایی برای ارزیابی احتمال تقلب بتواند مورد استفاده تصمیم گیرندگان مالی قرار گیرد.

برای این منظور می بایست، ابتدا نسبت به ایجاد تعداد «M» جواب تصادفی و فازی براساس دو معیار ارزش واقعی ایجاد نمود. تا بتوان نسبت به محاسبه تابع هدف و تعیین بهترین و بدترین جواب (X_{best}^R) اقدام لازم را انجام داد. سپس می بایست نسبت به تقسیم بازه های تعریف شده به صورت مساوی برای تعیین مطلوبترین منطقه انجام تحلیل اقدام نمود. براین اساس اگر N جمعیت کل باشد، k برابر است با یک چهارم N. لذا $X_i^{gp} = X_i^R$ و $i = 1, 2, \dots, k$ و $p = 1, 2, 3, 4, \dots, X_i^{gp}$ به شرطی این معادله برقرار است که در فضای جواب، بهترین الگوریتم بالاتر از ۱ قرار بگیرد. لذا می بایست جمعیت اولیه (الگوریتم های بهینه سازی فرا ابتکاری) را در تابع تعریف شده قرار داد تا X_j^I تا $j = 1, 2, \dots, N$ به طوریکه هریک از الگوریتم های برازش شده براساس مقیاس ها از طریق تابع $X_{best}^R = X_1^I \Rightarrow X_{best}^R = X_7^I$ مشخص می نمایند، کدام الگوریتم ها امکان دستیابی به مطلوبیت یکپارچه را دارند. لذا طبق جدول (۷) اقدام به ارزیابی می شود.

جدول ۷. مبنای انتخاب بهترین الگوریتم فرا ابتکاری

مبنای الگوریتم	الگوریتم گرگ خاکستری	الگوریتم بهینه سازی وال	الگوریتم کلونی زنبور عسل*	الگوریتم ازدحام ذرات	مبنای الگوریتم
میانگین	۰/۰۲۴۲۲	۰/۰۳۳۹۲	۰/۰۸۸۷۶	۰/۰۲۹۷۱	۰/۰۷۲۸۳
بهترین نتیجه	۰/۰۶۱۰۹	۰/۰۷۳۶۹	۱/۲۰۰۸	۰/۰۶۸۲۴	۱/۱۸۷۱
بدترین نتیجه	۱/۲۲۰۱	۰/۳۰۹۱۱	۰/۰۵۹۲۸	۱/۲۸۴۱۳	۰/۰۶۳۵۴
انحراف معیار	۱/۵۶۸۱	۱/۲۱۲۷	۰/۰۱۹۱۱	۱/۶۳۰۴	۰/۰۱۵۵۷

بر اساس نتایج کسب شده، مشخص شد، دور الگوریتم ژنتیک و الگوریتم کلونی زنبور عسل، به دلیل کسب ضریب بالاتر از ۱ در معیار بهترین نتیجه و ضریب پایین تر از ۱ در معیار بدترین نتیجه، از کارکرد مطلوب تری برای تعیین صحت پیش بینی تقلب مالی شرکت های مورد بررسی برخوردار هستند. لذا در ادامه ابتدا هر الگوریتم به صورت مجزا ارزیابی می شود و سپس بر اساس دو معیار تعیین شده ی بازده ثابت نسبت مقیاس (CRS) و بازده متغیر نسبت به مقیاس (VRS) اقدام به انتخاب بهترین الگوریتم فرا ابتکاری برای تعیین قابلیت بالاتر نسبت های مالی در پیش بینی تقلب مالی می شود.

الگوریتم ژنتیک

برای اجرای الگوریتم ژنتیک از طریق آموزش داده ها اقدام به دسته بندی شرکت های قرار گرفته در دهک احتمال تقلب می گردد. لذا تابع هدفی که الگوریتم ژنتیک تلاش دارد تا با بهینه سازی آن، به تعیین ضرایب پیش بینی دست یابد طبق رابطه (۶) تا (۸) ارائه می شود.

$$L(B.X) = \frac{1}{1+e^{XBt}} \quad \text{رابطه (۶)}$$

$$r = (B.X) = \begin{cases} 1 & \text{if } L(B.X) \geq 0.5 \\ 0 & \text{if } L(B.X) \leq 0.5 \end{cases} \quad \text{رابطه (۷)}$$

$$\Omega = (B.X.Y) = \{\sum_{i=1}^n (Y - \Gamma_i[B.X])\} / N \quad \text{رابطه (۸)}$$

در این روابط، تابع «L» تابعی از مبنای لوجستیک می باشد که به صورت ماتریسی محاسبه می شود. همچنین تابع «Γ» تعیین کننده ی اختصاص خروجی به صفر یا یک می باشد و در نهایت تابع «Ω» مبنای هزینه ای است که الگوریتم به دنبال بهینه یابی آن است. بنابراین، الگوریتم ژنتیک با تابع هزینه فوق به دنبال کاهش مجموع اختلاف خطای دسته بندی در داده های آموزشی شرکت هایی است که در دهک بندی های انجام شده، از احتمال تقلب مالی برخوردار می باشند. لذا در جدول (۸) خروجی های ناشی از داده های آموزش مربوط به این الگوریتم ارائه شده است.

جدول ۸. خروجی داده های آموزش مربوط به الگوریتم ژنتیک

معیارهای ارزیابی صحت داده های آموزش	دهک چهارم	دهک ششم	دهک هشتم	دهک دهم
درصد طبقه بندی صحیح داده های آموزش	۶۰/۱۸	۶۳/۳۷	۶۵/۱۰	۵۹/۴۲
درصد طبقه بندی داده های اعتبارسنجی	۷۱/۲۳	۷۳/۸۱	۷۵/۶۴	۷۰/۳۸
درصد طبقه بندی صحیح داده های آزمون	۴۹/۵۱	۴۱/۰۳	۵۰/۵۳	۴۲/۳۳
درصد طبقه بندی کل داده ها	۷۴/۲۹	۷۵/۲۹	۷۶/۲۱	۷۲/۲۸

جدول (۸) نشان می دهد، اجرای داده های آموزش ناشی از الگوریتم ژنتیک برای صحت پیش بینی تقلب مالی شرکت های دهک بندی شده مشخص می نماید که تمامی دهک ها از درصد بالایی برای پیش بینی صحت تقلب مالی شرکت ها برخوردار هستند. لذا در ادامه و بر اساس پارامترهایی همچون نرخ همبندی^۱ و

¹ Crossover Percentage

نرخ جهش^۱ توابع الگوریتم ژنتیک در پیش‌بینی صحیح احتمال تقلب براساس طبقه‌بندی صحیح داده‌های آموزش مورد محاسبه قرار می‌گیرد.

شکل ۹. نتایج ناشی از پیش‌بینی احتمال تقلب براساس براساس طبقه‌بندی صحیح داده‌های آموزش

Output Class	Target Class		
	1	2	
1	163 38.72%	333 61.78%	74.11% 23.06%
2	206 38.22%	258 62.28%	71.23% 24.06%
	76.94% 23.44%	74% 21%	73.51% 21.34%

پارامترهای نهایی بدست آمده نشان دهنده‌ی تعداد ۴۲۱ مشاهده از مجموع ۹۶۰ مشاهده برای صحت پیش‌بینی تقلب در شرکت‌های مورد بررسی می‌باشد که با نرخ همبندی بین ۷۰٪ تا ۷۵٪ و نرخ جهش بین ۲۱٪ تا ۲۴٪ می‌توان اقدام به صحت پیش‌بینی تقلب براساس نسبت‌های مالی انتخاب شده نمایند. لذا این نتایج نشان می‌دهد، بالاترین صحت پیش‌بینی مربوط به شرکت‌های دارای تقلب ۶۲/۲۸٪ می‌باشد که درصد احتمالی داده‌های کنترل برابر با ۳۸/۷۲٪ می‌باشد. لذا تعداد ۲۵۸ شرکت قرار گرفته در دهک‌بندی‌های دارای احتمال بالا در تقلب، با صحت پیش‌بینی ۶۲/۲۸٪ می‌تواند به درستی توسط نسبت‌های مالی تعیین شده، شناسایی شوند.

جدول ۹. پارامترهای آماری تابع هدف در روش الگوریتم ژنتیک

پارامتر	بیشینه	کمینه	متوسط	انحراف معیار	ضریب تغییرات
CRS	۱/۶۶۱	۱/۲۰۱	۱/۳۲۷	۰/۰۳۲۰۱	۰/۰۱۷۷
VRS	۱۵/۱۰۱	۱۲/۴۳۷	۱۳/۳۶۵	۱/۵۸۳	۰/۲۰۶

ضرایب ارائه شده، نشان از تأیید پارامترهای هر یک از نسبت‌های مالی مؤثر در پیش‌بینی صحت تقلب مالی شرکت‌ها براساس الگوریتم ژنتیک می‌باشد.

الگوریتم کلونی زنبور عسل

این الگوریتم براساس موقعیت اصطلاحی شناسایی گرده گیاهان توسط زنبور عسل، به دنبال بهینه‌ترین راه حل در انتخاب یک پاسخ محتمل می‌باشد. لذا این الگوریتم از طریق رابطه (۹) قابل بسط در این مطالعه می‌باشد.

¹ Mutation Percentage

$$p_i = \frac{fit_i}{\sum_{n=1}^{sn} fit_n} \quad \text{رابطه (۹)}$$

در این رابطه؛ « fit_i » مطلوبیت الگوریتمی براساس ارزیابی راه حل i تعیین می‌شود، که این ارزیابی متناسب با مقدار شهد منبع غذایی در موقعیت « i » می‌باشد. « sn » تعداد منابع غذایی است که برابر با تعداد زنبورهای کارگر «BN» است. لذا در جدول (۱۰) خروجی‌های ناشی از داده‌های آموزش مربوط به این الگوریتم ارائه شده است.

جدول ۱۰. خروجی داده‌های آموزش مربوط به الگوریتم کلونی زنبور عسل

معیارهای ارزیابی صحت داده‌های آموزش	دهک چهارم	دهک ششم	دهک هشتم	دهک دهم
درصد طبقه‌بندی صحیح داده‌های آموزش	۵۶/۲۲	۶۲/۶۶	۶۵/۳۵	۵۰/۴۶
درصد طبقه‌بندی داده‌های اعتبارسنجی	۵۹/۰۳	۶۴/۰۷	۶۲/۲۹	۵۴/۹۸
درصد طبقه‌بندی صحیح داده‌های آزمون	۳۹/۱۷	۵۸/۲۲	۶۷/۷۸	۴۸/۸۲
درصد طبقه‌بندی کل داده‌ها	۵۸/۱۱	۶۹/۱۸	۶۶/۱۹	۵۷/۷۳

این جدول نشان می‌دهد، اجرای داده‌های آموزش ناشی از الگوریتم کلونی زنبور عسل برای صحت پیش‌بینی تقلب مالی شرکت‌های دهک‌بندی شده مشخص می‌نماید که تمامی دهک‌ها از درصد متناسبی برای پیش‌بینی صحت تقلب مالی شرکت‌ها برخوردار هستند. لذا در ادامه و براساس پارامترهایی همچون حد فراموشی «Abandonment Limit» و حداکثر ضریب شتاب «Acceleration Coefficient Upper» توابع الگوریتم کلونی زنبور عسل در پیش‌بینی صحیح احتمال تقلب براساس طبقه‌بندی صحیح داده‌های آموزش و داده‌های کنترل مورد محاسبه قرار می‌گیرد.

شکل ۱۰. نتایج ناشی از پیش‌بینی احتمال تقلب براساس براساس طبقه‌بندی صحیح داده‌های آموزش

Output Class	Target Class		Overall Accuracy
	1	2	
1	116 33.63%	379 61.62%	79.69% 27.99%
2	236 38.37%	229 66.37%	78.33% 28%
	72% 23.44%	73.22% 22.05%	79.91% 23%

پارامترهای نهایی بدست آمده نشان دهنده‌ی تعداد ۳۴۵ مشاهده از مجموع ۹۶۰ مشاهده برای صحت پیش‌بینی تقلب در شرکت‌های مورد بررسی می‌باشد که با حد فراموشی بین ۰.۷۸ تا ۰.۷۹٪ و حداکثر ضریب شتاب بین ۰.۲۳ تا ۰.۲۸٪ می‌توان اقدام به صحت پیش‌بینی تقلب براساس نسبت‌های مالی انتخاب شده نمایند. لذا این نتایج نشان می‌دهد، بالاترین صحت پیش‌بینی مربوط به شرکت‌های دارای تقلب ۶۶/۳۷٪ می‌باشد

که درصد احتمالی داده‌های آزمون کنترل برابر با $33/63\%$ می‌باشد. لذا تعداد ۲۲۹ شرکت قرار گرفته در دهک‌بندی‌های دارای احتمال بالا در تقلب، با صحت پیش‌بینی $66/37\%$ می‌تواند به درستی توسط نسبت‌های مالی تعیین شده، شناسایی شوند.

جدول ۱۱. پارامترهای آماری تابع هدف در روش الگوریتم کلونی زنبور عسل

پارامتر	بیشینه	کمینه	متوسط	انحراف معیار	ضریب تغییرات
CRS	۱/۵۲۷	۱/۲۹۱	۱/۳۱۹	۰/۰۴۳۱	۰/۰۱۹۸
VRS	۱۴/۴۴۳	۱۳/۵۶۱	۱۳/۷۳۸	۱/۷۱۲	۰/۲۲۸

ضرایب ارائه شده، نشان از تأیید پارامترهای هریک از نسبت‌های مالی مؤثر در پیش‌بینی صحت تقلب مالی شرکت‌ها براساس الگوریتم کلونی زنبور عسل می‌باشد.

لذا نتایج بدست آمده از هر دو الگوریتم، نشان دهنده توازن نسبی صحت برابر پیش‌بینی احتمال تقلب مالی شرکت‌های دهک‌بندی شده می‌باشد. لذا در گام آخر می‌بایست براساس دو مقیاس ایجاد شده، مشخص نمود، کدام نسبت مالی و کدام الگوریتم از ظرفیت‌های بالاتری بر کمک به تصمیم‌گیرندگان مالی برای پیش‌بینی صحیح تقلب در شرکت‌های مورد بررسی برخوردار هستند. برای این منظور از آزمون ویلکا کسون و ارزیابی ضرایب هریک از نسبت‌های مالی بر در الگوریتم‌های فرا ابتکاری بهره برده می‌شود.

جدول ۱۲. نتایج ارزیابی الگوریتم‌های فرا ابتکاری براساس نسبت‌های ارزیابی تقلب مالی

ردیف	معیارهای شناسایی شده	Code	مقیاس	الگوریتم ژنتیک	الگوریتم کلونی زنبور عسل
۱	نسبت جاری	CRS	۲.۲۱۴	۲/۴۸۷	۴/۴۳۸
		VRS	۱۰.۴۲۴		
۲	نسبت دارایی جاری به کل دارایی‌ها	CRS	۱.۹۶۹	۲/۶۵۹	۳/۲۸۱
		VRS	۱۱.۷۰۷		
۳	نسبت دارایی ثابت به کل دارایی‌ها	CRS	۲.۲۶۹	۳/۲۸۵	۵/۰۲۸
		VRS	۱۲.۸۲۵		
۴	نسبت سود انباشته به کل دارایی‌ها	CRS	۱.۵۸۵	۲/۵۲۷	۴/۳۳۲
		VRS	۱۲.۲۶۸		
۵	نسبت سرمایه در گردش به کل دارایی‌ها	CRS	۱.۷۶۱	۳/۱۴۴	۳/۱۹۲
		VRS	۱۰.۴۶۳		
۶	نسبت کل بدهی به کل دارایی‌ها	CRS	۱.۸۵۲	۳/۲۳۲	۴/۱۷۲
		VRS	۱۱.۸۶۱		
۷	نسبت سود ناخالص به کل دارایی‌ها	CRS	۲.۰۸۳	۳/۸۷۴	۴/۰۴۵
		VRS	۱۱.۵۷۶		
۸	نسبت کل بدهی به حقوق صاحبان سهام	CRS	۱.۹۹۴	۲/۹۵۷	۳/۲۲۸
		VRS	۱۳.۰۱۲		

۴/۱۹۲	۳/۴۱۴	۲۰۰۷۶ ۱۰۵۳۱	CRS VRS	σ_9	نسبت سود انباشته به کل دارایی‌ها	۹
۵/۳۸۲	۴/۰۱۹	۱۲۰۱۹۳ ۱۰۴۶۶	CRS VRS	σ_{10}	نسبت فروش به کل دارایی‌ها	۱۰
۴/۸۸۷	۳/۲۹۱	۱۰۰۴۸۹ ۱۰۷۳۸	CRS VRS	σ_{11}	نسبت بدهی بلندمدت به حقوق صاحبان سهام	۱۱
۳/۱۹۵	۲/۷۸۸	۲۰۰۹۱ ۱۳۰۴۵۵	CRS VRS	σ_{12}	نسبت بهای تمام شده کالای فروش رفته به کل فروش	۱۲
۳/۸۱۶	۳/۰۶۳	۲۰۲۶۳ ۱۱۰۵۷۴	CRS VRS	σ_{13}	نسبت سود خالص به کل دارایی‌ها	۱۳
۶/۰۰۸	۴/۱۱۰	۲۰۲۷۸ ۱۲۰۲۸۴	CRS VRS	σ_{14}	نسبت سود ناخالص به فروش	۱۴
۳/۲۲۸	۲/۵۶۴	۲۰۵۴۴ ۱۲۰۵۸۸	CRS VRS	σ_{15}	نسبت سود عملیاتی به فروش	۱۵
۵/۷۸۶	۳/۹۸۵	۱۰۱۹۸ ۲۰۴۹۶	CRS VRS	σ_{16}	نسبت سود خالص به حقوق صاحبان سهام	۱۶
۴/۱۱۱	۳/۰۹۱	۲۰۱۵ ۱۲۰۹۷	CRS VRS	σ_{17}	نسبت هزینه‌های مالی به کل بدهی‌ها	۱۷
۶/۰۷۱	۴/۱۶۲	۲۰۲۲۴ ۱۲۰۵۶۵	CRS VRS	σ_{18}	نسبت سود خالص به فروش	۱۸
۴/۲۱۷	۳/۱۷۱	۱۰۳۷۷ ۱۲۰۷۹۵	CRS VRS	σ_{19}	نسبت هزینه‌های عملیاتی به فروش	۱۹
۴/۹۲۱	۳/۲۸۴	۱۰۹۱۴ ۱۲۰۱۵۴	CRS VRS	σ_{20}	نسبت حساب‌های دریافتی به فروش	۲۰
۴/۲۲۵	۳/۴۰۵	۱۰۹۱۲ ۱۳۰۳۵	CRS VRS	σ_{21}	نسبت موجودی‌ها به فروش	۲۱
۶/۰۴۶	۴/۱۲۸	۱۰۳۴۵ ۱۱۰۶۳۷	CRS VRS	σ_{22}	نسبت موجودی نقد به کل دارایی‌ها	۲۲
۳/۳۲۱	۲/۸۱۶	۱۰۱۶ ۱۲۰۳۱۵	CRS VRS	σ_{23}	نسبت سود خالص به سود ناخالص	۲۳
۴/۸۷۱	۲/۷۳۱	۱۰۳۷۲ ۱۳۰۰۱۸	CRS VRS	σ_{24}	نسبت جریان وجه نقد عملیاتی به کل دارایی‌ها	۲۴

همانطور که دو مقیاس بازده ثابت نسبت مقیاس (CRS) و بازده متغیر نسبت به مقیاس (VRS) نشان می‌دهد، تمامی ضرایب بالاتر از ۱ می‌باشد که نشان می‌دهد، هر دو الگوریتم از سطح بهینگی لازم در پیش‌بینی احتمال تقلب مالی شرکت‌ها برخوردار می‌باشند. اما ضرایب الگوریتم‌های فرا ابتکاری نشان

می دهد، کلونی زنبور عسل نسبت به الگوریتم ژنتیک از دقت بالاتری برخوردار می باشد. همچنین مشخص شد، نسبت سود خالص به فروش « σ_{18} » با ضریب « $6/071$ » بالاترین نسبت تأثیرگذار در پیش بینی صحت مالی شرکت های دهک بندی شده در هر دو الگوریتم کلونی زنبور عسل و الگوریتم ژنتیک را دارد. در ادامه جهت صحت این نتایج از آزمون ویلکاکسون بهره برده می شود تا براساس مجموع ضرایب نسبت های مالی مقایسه ی دو الگوریتم مورد توجه در این مطالعه، از حیث دقت آزمون طبق جدول (۱۳) مورد بررسی قرار گیرد.

جدول ۱۳. تفاوت ارزیابی الگوریتم های فرا ابتکاری شبکه عصبی براساس نسبت های ارزیابی تقلب

الگوریتم	تعداد ارزیابی تابع هدف	مقدار تابع ا کلی	میانگین ضرایب	مجموع ضریب	نتیجه ارزیابی
الگوریتم ژنتیک	۲۹۰۰۰	-۰/۰۰۰۲۹۵	۱۱/۱۹	۰/۳۰۱	Bee > GEN
الگوریتم کلونی زنبور عسل	۲۹۰۰۰	۰/۰۰۰۰۵۶	۱۲/۵۵	۰/۳۶۶	
			Z		
					Asymp. Sig. (2-tailed)
					۰/۰۰۰
					-۰/۳۸۲

همان طور که براساس نتایج آزمون ویلکاکسون مشاهده می شود، ضریب معنی داری بدست آمده با توجه به اینکه کوچکتر از $0/05$ می باشد، می تواند بیان کننده ی این مسئله باشد که الگوریتم کلونی زنبور عسل نسبت به الگوریتم ژنتیک، به لحاظ آماره الگوریتمی، با دقت بالاتری در پیش بینی صحت احتمال تقلب شرکت های مورد بررسی همراه می باشد.

بحث و نتیجه گیری

هدف این مطالعه، مدل سازی تشخیص تقلب مالی شرکت ها تحت ارزیابی الگوریتم های مطلوبیت شبکه عصبی مصنوعی می باشد. در این مطالعه ابتدا با مرور نظام مند ادبیات مرتبط با حوزه پژوهش در طی چندسال گذشته، تلاش شد تا نسبت های مالی متناسب با ارزیابی تقلب شرکت های بازار سرمایه انتخاب شدند. سپس براساس برنامه ریزی مجددوری «QP» تلاش شد تا با حذف فاصله بین داده های ناشی از پیش بینی و واقعی حاصل از نسبت های مالی شناسایی شده، الگوریتم پایه ارزیابی صحت تقلب شرکت ها براساس مشاهدات (سال-شرکت) تعیین گردد. لذا طی آزمون منطق استنتاج فازی عصبی انطباق پذیر (ANFIS) و فرآیند اعتبارسنجی ضربدیری یا اصطلاحاً «k-fold»، مشخص شد، الگوریتم یادگیری بدون نظارت که شامل مجموعه پارامترهای ارزیابی مبتنی بر الگوریتم فرا ابتکاری است و از صحت پیش بینی های مبتنی بر داده های برآورده شده بالاتری برخوردار می باشد، به عنوان پایه ی الگوریتم های این مطالعه انتخاب شد. در ادامه به منظور ایجاد شاخص مرجع، براساس نسبت های مالی ارزیابی احتمال تقلب شرکت ها از فرآیند دهک بندی بهره برده شد تا مشخص شود، چه شرکت هایی از دهک های دارای ضریب « $D > 1$ » می توانند

در مقیاس‌های ارزیابی آزمون و کنترل، یعنی بازده ثابت نسبت مقیاس (CRS) و بازده متغیر نسبت به مقیاس (VRS) به تفکیک بین شرکت‌ها از نظر سلامت مالی با شرکت‌های دارای احتمال تقلب کمک نمایند. نتایج از قرار گرفتن شرکت‌های دارای احتمال تقلب در ۴ دهک حکایت دارد که برای ارزیابی‌های بیشتر صحت پیش‌بینی تقلب‌های مالی شرکت‌های دهک‌بندی شده از دو الگوریتم انتخابی ژنتیک و کلونی زنبور عسل بهره برده شد. در نهایت نیز مشخص شد، الگوریتم کلونی زنبور عسل نسبت به الگوریتم ژنتیک، از ضریب دقت بالاتری در پیش‌بینی صحت احتمال تقلب شرکت‌های مورد بررسی برخوردار است. همچنین مشخص شد، نسبت سود خالص به فروش مهمترین معیار ارزیابی دقت پیش‌بینی احتمال تقلب در شرکت‌های مورد بررسی می‌باشد.

در تفسیر نتایج کسب شده، ابتدا می‌بایست اشاره گردد که الگوریتم کلونی زنبور عسل به دلیل برخورداری از بهینه‌سازی فرآیندی چندگانه به واسطه‌ی هوش جمعی، از کارکردهای بالاتری در حل یک مسئله پیچیده برخوردار می‌باشد. در واقع این الگوریتم به دلیل اینکه از قدرت همگرایی و دقت بالاتری در پیش‌بینی احتمال تقلب شرکت‌های مورد بررسی نسبت به الگوریتم ژنتیک، برخوردار می‌باشد می‌تواند کارایی اثربخش‌تری در تصمیم‌گیری‌های مالی در سطح بازار سرمایه داشته باشد. به علاوه ضرایب کسب شده در الگوریتم کلونی زنبور عسل، حکایت از بهینه‌سازی اثربخش‌تر نسبت‌های مالی در پیش‌بینی احتمال تقلب شرکت‌ها دارد. چراکه تصمیم‌گیرندگان مالی می‌توانند از این الگوریتم برای ارزیابی‌های دقیق‌تر مبتنی بر نسبت‌های مالی بهره‌برند تا بتوانند، شرکت‌های دارای احتمال تقلب را شناسایی کنند و در تشکیل پرتفوی سهام این شرکت‌ها را خریداری نکنند. از طرف دیگر مشخص گردید، شرکت‌های دارای نسبت سود خالص به فروش پایین‌تر می‌تواند معیار مناسبی در پیش‌بینی ضرایب الگوریتم کلونی زنبور عسل تلقی شود. چراکه این نسبت مالی این امکان را در ارزیابی تقلب شرکت‌ها مهیا می‌نماید که نشان‌دهنده‌ی این مسئله است که به دلیل عدم کنترل هزینه‌ها، شرکت‌های ظرفیت‌های مناسبی برای بالاتر بردن سود خالص از محل فروش را ندارند و این مسئله به دلیل اینکه واکنش منفی سرمایه‌گذاران را به همراه دارد، احتمال افزایش تقلب از طریق پوشش و دستکاری در حساب را در شرکت‌ها می‌تواند افزایش دهد. لذا کاهش این نسبت می‌تواند در ضریب الگوریتم کلونی زنبور عسل، مبنایی برای پیش‌بینی دقت تقلب در شرکت‌های مورد بررسی تلقی گردد. همچنین ارجاع به بازده ثابت نسبت به مقیاس (CRS) و بازده متغیر نسبت به مقیاس (VRS) نشان می‌دهد، کارکردهای عملیاتی شرکت‌های دارای احتمال تقلب بالاتر در یک بازار رقابتی، توانمندی‌های کسب سودهای خالص شرکت از محل فروش که براساس نوع مدیریت و بازده کارایی

دارایی‌ها می‌تواند حادث شود، را به تدریج از دست می‌دهند. لذا نکته‌ای که از مبانی تعیین ارزیابی تطبیقی بین الگوریتم‌ها یعنی بازده ثابت نسبت مقیاس (CRS) و بازده متغیر نسبت به مقیاس (VRS) می‌توان استنباط نمود این است که، شرکت‌های دارای احتمال تقلب مالی بالاتر، با بازدهی سرمایه پایین‌تری مواجه هستند که در بلندمدت می‌تواند ضمن تشدید تعهدات و نسبت اهرمی بالاتر برای شرکت، شکاف بین بازده مورد انتظار با بازده واقعی را نیز عمیق‌تر نماید. نتایج این مطالعه به لحاظ ماهیت اجرای الگوریتم‌های فرا ابتکاری و مقایسه بین اجزای آن اگرچه در پژوهش‌های گذشته مورد توجه نبوده است تا بتوان مقایسه‌ی دقیقی بین نتایج کسب شده با نتایج آن‌ها انجام داد، اما می‌توان به لحاظ ماهیت مفهومی و همراستا با اهمیت بکارگیری الگوریتم‌های فرا ابتکاری نتایج این مطالعه را با پژوهش‌هایی همچون تشیدی و همکاران (۱۳۹۸)؛ Zhou et al (2024) و du Toit (2024) مورد مقایسه قرار داد.

بر اساس اهمیت مسئله تقلب در تصمیم‌گیری‌های مالی، به سرمایه‌گذاران توصیه می‌شود تا از طریق ارتقاء سطح آموزش تحلیل‌های تکنیکال در تشکیل سبد سهام، درصد ریسک‌های احتمالی پیش‌بینی تقلب مالی شرکت‌ها را کاهش دهند. مهمترین شناخت تکنیک‌های تحلیلی می‌تواند مربوط به روش‌های پیش‌بینی باشد که بر پایه‌ی الگوریتم‌های یادگیری بدون نظارت ایجاد شده باشد، چراکه تمرکز بر روی مجموع الگوریتم‌های این روش، شناخت بیشتری را در تصمیم‌گیرندگان ایجاد می‌نماید که با تمرکز بر روی ماهیت واقعی داده‌ها و بدون دستکاری یا یا نگاهت آن‌ها، مجموعه‌ای از الگوها، ساختارها و روابط قابل پیش‌بینی از تقلب مالی شرکت‌ها را می‌توانند شناسایی نمایند. همچنین با توجه به اینکه غالباً بخش مهمی از علل اثرگذار بر تقلب مالی شرکت‌ها، شکاف‌های قانونی هستند که امکان دستکاری و ساختگی‌سازی حساب‌ها را به شرکت‌ها می‌دهند، ضرورت توسعه ظرفیت‌های بازرسی‌های قانونی دوره‌ای مبنی بر نظارت اثربخش‌تر بر شفافیت‌های مالی شرکت‌ها به حدی از ضرورت برخوردار است که غالباً بخش مهمی از عملکردهای متقلبانه می‌تواند به واسطه‌ی فقدان استانداردها یا نظارت‌های قانونی توسط شرکت‌ها به وجود بیاید.

منابع

آشاوروزنیا، کتابون، پورآقاجان، عباسعلی، نسل موسوی، سیدحسین. (۱۴۰۲). رویکردی نوین به پیش‌بینی تقلب در صورت‌های مالی (مقایسه مدل‌های سنتی و شبیه‌سازی و مدرن)، تحقیقات حسابداری و حسابرسی، ۱۵(۵۷): ۱۴۱-۱۶۰.

<https://doi.org/10.22034/IAAR.2023.172761>

اعتمادی، حسین، عبدلی، لیلا. (۱۳۹۶). کیفیت حسابرسی و تقلب در صورت‌های مالی، دانش حسابداری مالی، ۴(۴): ۲۳-۴۳.

https://jfab.journals.ikiu.ac.ir/article_1308.html?lang=fa

- بهرامی، آسو، نوروش، ایرج، راد، عباس، محمدملقونی، عطاله. (۱۴۰۰). تقلب در صورت‌های مالی و تکنیک‌های نوین مورد استفاده جهت کشف آن، مطالعات حسابداری و حسابرسی، ۱۰(۳۸): ۱۰۵-۱۱۸.
<https://doi.org/10.22034/iaas.2021.13454>
- تشدید، الهه، سپاسی، سحر، اعتمادی، حسین، آذر، عادل. (۱۳۹۸). ارائه رویکردی نوین در پیش‌بینی و کشف تقلب صورت‌های مالی با استفاده از الگوریتم زنبور عسل، مجله دانش حسابداری، ۱۰(۳): ۱۳۹-۱۶۷.
<https://doi.org/10.22103/jak.2019.13616.2927>
- جعفری، محمد، رضایی، ندا، سلگی، محمد. (۱۴۰۲). استفاده از شبکه عصبی مصنوعی پیشخور چند لایه در تشخیص گزارشگری مالی متقلبان در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، مطالعات حسابرسی مطهر، ۱(۲): ۹۳-۱۱۳.
https://masji.ihu.ac.ir/article_208557.html
- حسن‌پور، داود، ولیان، حسن، صفری‌گرایلی، مهدی، طهماسبی‌زاده، رضا. (۱۳۹۹). بکارگیری مدل‌های تئوری راف توسعه‌یافته (ERST) و تحلیل تفسیری-ساختاری (ISM) و درخت تصمیم (CART) برای کمک به حسابرسان جهت شناخت تقلب در صورت‌های مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار ایران، دانش سرمایه‌گذاری، ۹(۳۳): ۱۷۹-۲۰۸.
http://www.jik-ifea.ir/article_15665.html?lang=en
- دادگر، بداله، درگاهی، حسن، قلی‌زاده، سعید. (۱۴۰۲). نقش احساسات سرمایه‌گذاران و رفتار دولت در نوسانات بازار بورس اوراق بهادار تهران: رویکرد اقتصاد رفتاری، نظریه‌های کاربردی اقتصاد، ۱۰(۱): ۱۹۱-۲۱۴.
<https://doi.org/10.22034/ecoj.2023.53000.3091>
- کابلی، مونا سادات، رحمانی، علی، نیکومرام، هاشم و رهنمای رودپشتی، فریدون. (۱۳۹۹). اثربخشی ارزش‌های انگیزشی شوآرتز و اخلاق حرفه‌ای حسابداری بر گزارشگری مالی متقلبان، مطالعات تجربی حسابداری مالی، ۱۷(۶۶): ۲۷-۵۰.
<https://doi.org/10.22054/qjma.2019.45619.2042>
- ملکی‌کاکلر، حسن، بحری‌ثالث، جمال، جبارزاده‌کنگرویی، سعید، آشتاب، علی. (۱۴۰۰). کارایی مدل‌های آماری و الگوهای یادگیری ماشین در پیش‌بینی گزارشگری مالی متقلبان، نشریه اقتصاد مالی، ۱۵(۵۴): ۲۶۷-۲۹۲.
<https://doi.org/20.1001.1.25383833.1400.15.54.11.2>
- یوخنه‌القینانی، ماریام، بحری‌ثالث، جمال، جبارزاده‌کنگرویی، سعید و زواری رضایی، اکبر. (۱۴۰۰). تبیین گزارشگری مالی/مالیاتی متقلبان شرکت‌ها: رویکرد ترکیبی داده‌کاوی کلاسیک، ANFIS و الگوریتم‌های فراابتکاری، مطالعات تجربی حسابداری مالی، ۱۸(۷۱): ۸۷-۱۱۲.
<https://doi.org/10.22054/qjma.2021.59092.2234>
- Blakley, M. (2009). Fraud detection using a database platform. Available online at: <http://www.slideshare.net/mblakley>
- Bockel-Rickermann, Ch., Verdonck, T. and Verbeke, W. (2023). Fraud analytics: A decade of research: Organizing challenges and solutions in the field, Expert Systems with Applications, 232(2): 65-89. <https://doi.org/10.1016/j.eswa.2023.120605>
- Craja, P., Kim, A. and Lessmann, S. (2020). Deep learning for detecting financial statement fraud, Decision Support Systems, 139(2): 47-71. <https://doi.org/10.1016/j.dss.2020.113421>
- Dezort, F, T. & Lee, Th, A. (1998). The Impact of SAS No. 82 on Perceptions of External Auditor Responsibility for Fraud Detection, International Journal of Auditing, 2(2): 167-182. <https://doi.org/10.1111/1099-1123.00037>
- du Toit, E. (2024). The red flags of financial statement fraud: a case study, Journal of Financial Crime, 31(2): 311-321. <https://doi.org/10.1108/JFC-02-2023-0028>

- Foster, M. (2015). Toshiba scandal sheds harsh light on Japan's corporate governance. <https://www.theguardian.com/business/2015/jul/21/toshiba-scandal-sheds-harsh-light-on-japans-corporate-governance>
- Francis, S. A., & Justine, C. (2023). Corruption and National Development: The Consequential Effects on the Sustainability in Ghana. *American Journal of Multidisciplinary Research and Innovation*, 2(3): 32–40. <https://doi.org/10.54536/ajmri.v2i3.1434>
- He, H., Sheng, Y., Yang, X. et al. (2019). Constructing an Associative Memory System Using Spiking Neural Network, *Neuromorphic Engineering*, 13(2): 33-51. <https://doi.org/10.3389/fnins.2019.00650>
- Hidayattullah, S., Surjandari, I. and Laoh, E. (2020). Financial Statement Fraud Detection in Indonesia Listed Companies using Machine Learning based on Meta-Heuristic Optimization, *International Workshop on Big Data and Information Security (IWBIS)*, Depok, Indonesia, 79-84. <https://doi.org/10.1109/IWBIS50925.2020.9255563>
- Jiang, W. & Cui, H. (2019). The View on Curbing Financial Fraud of Listed Companies, *Proceedings of the 2019 International Conference on Economic Management and Cultural Industry (ICEMCI 2019)*, 1-21. <https://doi.org/10.2991/aebmr.k.191217.069>
- Lisbinski, F.C. and Burnquist, H.L. (2024). Institutions and financial development: Comparative analysis of developed and developing economies, *Economia*, 25(2): 347-376. <https://doi.org/10.1108/ECON-11-2023-0201>
- Lusardi, A. and Mitchell, O. S. (2014). The Economic Importance of Financial Literacy: Theory and Evidence. *Journal of Economic Literature*, 52(1): 5-44. <https://doi.org/10.1257/jel.52.1.5>
- Motie, S. and Raahemi, B. (2024). Financial fraud detection using graph neural networks: A systematic review, *Expert Systems with Applications*, 240(2): 101-125. <https://doi.org/10.1016/j.eswa.2023.122156>
- Ngai, E.W.T., Hu, Y., Wong, Y. H., Chen, Y. and Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature, *Decision Support Systems*, 50(3): 559-569. <https://doi.org/10.1016/j.dss.2010.08.006>
- Ran, R., Wang, L., Fu, L. (2023). Exploring the Existence of Efficiency in the Financial Markets, *Advances in Economics Management and Political Sciences*, 13(1): 335-342. <https://doi.org/10.54254/2754-1169/13/20230741>
- Sargiacomo, M., Everett, J., Ianni, L., D'Andre Matteo, A. (2024). Auditing for fraud and corruption: A public-interest-based definition and analysis, *The British Accounting Review*, 56(2): 1-23. <https://doi.org/10.1016/j.bar.2024.101355>
- Sender, H., Weinland, D. and Hume, N. (2020). Luckin Coffee scandal catches and world's most powerful investors. <https://www.ft.com/content/59191f9d-f2ce-4dda-8756-283aae6e9e83>
- Shoetan, Ph, O. and Familoni, B, T. (2024). Transforming Fintech Fraud Detection with Advanced Artificial Intelligence Algorithms, *Finance & Accounting Research Journal*, 6(4): 602-625. <https://doi.org/10.51594/farj.v6i4.1036>
- Smaili, N., Arroyo, P. and Issa, F.A. (2022). The dark side of blockholder control: evidence from financial statement fraud cases, *Journal of Financial Crime*, 29(3); 816-835. <https://doi.org/10.1108/JFC-05-2021-0113>

- Spann, D. D. (2013). *Fraud Analytics: Strategies and Methods for Detection and Prevention*, Wiley Corporate F&A, 3rd Edition, pp: 1-326.
- Teichmann, F., Boticiu, S. R. and Sergi, B. (2023). Wirecard scandal. A commentary on the biggest accounting fraud in Germany's post-war history. *Journal of Financial Crime*, 2(3): 37-56. <https://doi.org/10.1108/JFC-12-2022-0301>
- Uras, B. R. (2020). Finance and development: Rethinking the role of financial transparency, *Journal of Banking & Finance*, 111(1): 45-61. <https://doi.org/10.1016/j.jbankfin.2019.105721>
- Zhang, X., Su, J. and Zhou, L. (2022). Fraud identification of financial reports based on neural network algorithm, 40th Chinese Control Conference (CCC), Shanghai, China, pp. 8045-8049. <https://doi.org/10.23919/CCC52363.2021.9549887>
- Zhou, Y., Xiao, Zh., Gao, R. and Wang, Ch. (2024). Using data-driven methods to detect financial statement fraud in the real scenario, *International Journal of Accounting Information Systems*, 54(2): 1-31. <https://doi.org/10.1016/j.accinf.2024.100693>

[References In Persian]

- Asharoonia, K. , Pouraghajan, A. A. and Naslmosavi, S. (2023). A New Approach to Predicting Fraud in Financial Statements (Compare models and simulations traditional and modern). *Accounting and Auditing Research*, 15(57): 141-160. <https://doi.org/10.22034/IAAR.2023.172761> [In Persian].
- Etemadi, H. and abdoli, L. (2018). Audit Quality and Financial statement fraud. *Financial Accounting Knowledge*, 4(4), 23-43. https://jfak.journals.ikiu.ac.ir/article_1308.html?lang=fa [In Persian].
- Bahrami, A. , Noravesh, I. , Raad, A. and Mohammadi Molgharni, A. (2021). Financial Statements Fraud and new techniques used to detect it. *Accounting and Auditing Studies*, 10(38): 105-118. <https://doi.org/10.22034/raas.2021.13454> [In Persian].
- Tashdidi, E. , Sepasi (Ph.D), S. , Etemadi (Ph.D), H. and Azar (Ph.D), A. (2019). New Approach to Predicting and Detecting Financial Statement Fraud, Using the Bee Colony. *Journal of Accounting Knowledge*, 10(3): 139-167. <https://doi.org/10.22103/jak.2019.13616.2927> [In Persian].
- Jafari, Mohammad., Rezaei, Neda., Selgi, Mohammad. (2023). Using a Multilayer Feedforward Artificial Neural Network in Detecting Fraudulent Financial Reporting in Companies Listed on the Tehran Stock Exchange, *Motahar Audit Studies*, 1(2): 93-113. https://masj.ihu.ac.ir/article_208557.html [In Persian].
- Hasanpoor, D. , valiyan, H. , safari griyly, M. and Tahmasbizadeh, R. (2020). Applying Rough Developed theoretical Models (ERST), Interpretation-Structural Analysis (ISM) and Decision Tree (CART) for Help Auditors to Identify Fraud in the Financial Statements of Companies Listed on the Stock Exchange of Iran. *Journal of Investment Knowledge*, 9(33), 179-208. http://www.jik-ifea.ir/article_15665.html?lang=en [In Persian].
- Dadgar, Y. , Dargahi, H. and Gholizadeh, S. (2023). The Role of Investor Sentiment and Government Behaviour in Volatility of Tehran Stock Exchange Market: A Behavioural Economics Approach. *Quarterly Journal of Applied Theories of Economics*, 10(1): 191-214. <https://doi.org/10.22034/ecej.2023.53000.3091> [In Persian].
- Kaboli, M. S. , Rahmani, A. , Nikoomaram, H. and RahnamayRoodposhti, F. (2020). Effectiveness of Schwartz's Motivational Values and Accounting Code of Ethics on

- Fraudulent Financial Reporting. *Empirical Studies in Financial Accounting*, 17(66), 27-50. <https://doi.org/10.22054/qjma.2019.45619.2042> [In Persian].
- Malekikalger, H., Bahrisesales, J., Jabbarzadeh Kangarlouie, S. and Ashtab, A. (2021). The effectiveness of statistical models and machine learning patterns in predicting fraudulent financial reporting, *Journal of Financial Economics*, 15(54): 267-292. <https://doi.org/20.1001.1.25383833.1400.15.54.11.2> [In Persian].
- Yokhanehalghyani, M., Bahrisesales, J., Jabbarzadeh Kangarluei, S. and Zavari Rezaei, A. (2021). Combination of CDM, ANFIS & MH Algorithms in a model to determine Fraudulent Financial-Tax Report. *Empirical Studies in Financial Accounting*, 18(71), 87-112. <https://doi.org/10.22054/qjma.2021.59092.2234> [In Persian].

پیش از انتشار