

Audit Risk Prediction Based on Long Short-Term Memory (LSTM) Algorithm

1. Rasha Mhmood Ali^{id}: PhD student, Department of Accounting, Isf.C., Islamic Azad University, Isfahan, Iran

2. Hamidreza Azizi^{id}*: Department of Accounting, Ard.C., Islamic Azad University, Ardabil, Iran. Email: gh_azizi60@iau.ac.ir (Corresponding Author)

3. Siraj Razooqi Abbas^{id}: Department of Accounting, Faculty of Finance and Accounting, Wasit Provincial University, Iraq

4. Rahman Saedi^{id}: Department of Accounting, Isf.C., Islamic Azad University, Isfahan, Iran

Article history



Received: 23 March 2025

Revised: 22 May 2025

Accepted: 31 May 2025

Published: 20 June 2025

Abstract:

The objective of the present study is to predict audit risk using the Long Short-Term Memory (LSTM) algorithm in companies listed on the Tehran Stock Exchange and to compare its results with those of other deep learning algorithms. To achieve this objective, a total of 1,650 firm-year observations (150 companies over 11 years) were collected from the annual financial reports of companies listed on the Tehran Stock Exchange during the period from 2013 to 2023. In this study, four deep learning algorithms—including Long Short-Term Memory (LSTM), Support Vector Machine (SVM), Convolutional Neural Network (CNN), and Recurrent Neural Network (RNN)—were utilized. Additionally, to select the final research variables for model construction, the two-sample mean comparison test method was applied. The results of the deep learning algorithms show that the overall accuracy of the LSTM, SVM, CNN, and RNN algorithms was 99.1%, 89.6%, 85.8%, and 96.4%, respectively, indicating that the LSTM algorithm has the best performance and the CNN algorithm the poorest performance in predicting audit risk. In other words, the results demonstrate the superior efficiency of the Long Short-Term Memory (LSTM) algorithm compared to other deep learning algorithms. Therefore, in companies listed on the Tehran Stock Exchange, the LSTM algorithm provides the most efficient model for audit risk prediction. The findings of this study can offer useful insights into enhancing the prediction of audit risk and minimizing errors in evaluating financial statement information, improving the assessment of audit evidence based on data, and facilitating auditors' ability to issue more reality-based opinions.

Keywords: Audit Risk Prediction, Deep Learning, Long Short-Term Memory Algorithm (LSTM)

Citation: Mhmood Ali, R., Azizi, H., Razooqi Abbas, S., & Saedi, R. (2025). Audit Risk Prediction Based on Long Short-Term Memory (LSTM) Algorithm, *Accounting, Finance and Computational Intelligence*, 3(1), 1-22.



Copyright: © 2025 by the authors. Published under the terms and conditions of Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

Extended Abstract

Introduction

Audit risk, defined as the probability that an auditor will unknowingly fail to appropriately modify their opinion on materially misstated financial statements, has garnered increasing attention in financial governance literature. In today's complex and rapidly evolving economic landscape, ensuring the integrity and reliability of financial statements is more crucial than ever, particularly for public companies whose financial disclosures directly influence investment decisions and market trust. However, traditional audit risk assessment approaches are often insufficient in detecting anomalies and hidden risks within high-dimensional and time-dependent financial datasets. As such, there is a growing imperative to employ more sophisticated predictive tools based on artificial intelligence and deep learning algorithms (Cohen et al., 2014; DeFond & Zhang, 2014).

Prior research has illustrated that audit quality and auditor characteristics play a pivotal role in mitigating audit risk. For instance, factors such as auditor tenure, auditor specialization, audit fees, and audit committee effectiveness have been consistently linked to variations in audit quality and risk exposure (Cohen et al., 2010; Kim et al., 2015; Krishnan et al., 2013). At the same time, macroeconomic conditions such as inflation rates, interest rates, and exchange rate volatility significantly affect audit risk, particularly in emerging markets (Darabi et al., 2020; Deng et al., 2023). Consequently, a comprehensive model for predicting audit risk should consider both firm-level and external environmental variables.

The emergence of deep learning techniques has opened new avenues for modeling complex relationships among these variables. Recurrent Neural Networks (RNN), Convolutional Neural Networks (CNN), and Support Vector Machines (SVM) have shown promising results in various financial applications. However, among these methods, Long Short-Term Memory (LSTM) networks—a special kind of RNN—stand out due to their ability to learn long-term dependencies in time-series data. LSTM networks have demonstrated superior performance in tasks such as financial forecasting, anomaly detection, and predictive auditing (Al-Din et al., 2023; O. Abu-Mehsen et al., 2023; Wu & Wilson, 2016). Despite their proven advantages, few studies have employed LSTM for audit risk prediction within the context of the Tehran Stock Exchange (TSE), where the dynamic and turbulent financial environment poses unique challenges for audit quality assessment.

This study addresses this gap by applying the LSTM algorithm to predict audit risk in TSE-listed firms and comparing its performance with three alternative deep learning algorithms: SVM, CNN, and basic RNN. Additionally, the study integrates a robust variable selection process based on t-test comparisons to enhance model precision. In doing so, it seeks not only to contribute methodologically by employing advanced AI techniques in audit analytics but also to provide practical insights for auditors, regulators, and investors in high-risk financial environments (Faridi Mayvan et al., 2022; Hamti & Tolouei Ashlaghi, 2022; Porcuna-Enguix et al., 2021; Sujana & Dharmawan, 2023).

Methods and Materials

This applied research employed a post-event (ex post facto) design utilizing historical financial data of 150 publicly listed companies on the Tehran Stock Exchange over an 11-year period (2013–2023), resulting in a total of 1,650 firm-year observations. Data were collected from audited financial statements, annual reports, and regulatory filings, along with macroeconomic indicators sourced from official databases.

To construct the predictive models, a total of 40 financial, governance, auditor-related, and macroeconomic variables were initially selected based on theoretical foundations and prior empirical literature. The t-test was then employed to determine

which variables showed statistically significant differences between high and low audit risk groups, narrowing the set to 25 final predictor variables.

Four machine learning models were applied and compared: LSTM, SVM, CNN, and RNN. Each model was trained on 75% of the dataset and tested on the remaining 25%, with the process repeated 50 times to calculate the average prediction accuracy. Accuracy metrics were derived from confusion matrices and included true positives, true negatives, false positives, and false negatives.

Findings

The LSTM model demonstrated the highest prediction accuracy among the algorithms tested. The overall accuracy rate of LSTM was 99.1%, with only 0.5% false negatives and 1.3% false positives. In contrast, the SVM model achieved an accuracy of 89.6%, CNN achieved 85.8%, and RNN reached 96.4%. The LSTM model outperformed the others by a significant margin, particularly in identifying high audit risk companies.

The t-test analysis revealed that 25 out of the 40 initial variables showed significant differences between the high and low audit risk groups. These included auditor tenure, audit fee, audit delay, audit committee independence, company size, leverage ratio, liquidity, profitability, firm age, growth opportunities, industry size, industry competitiveness, state ownership, institutional ownership, managerial ownership, and macroeconomic factors such as inflation, interest rates, and currency exchange rates.

The chi-square test confirmed significant associations between audit risk and auditor-related variables such as audit firm size, auditor change, auditor ranking, opinion type, and auditor specialization. Interestingly, the type of ownership (public vs. private) did not show a significant relationship with audit risk status.

Overall, the LSTM model was found to be the most effective for audit risk prediction in this study, offering a near-perfect classification of firms into high-risk and low-risk audit categories using a comprehensive set of variables.

Discussion and Conclusion

The findings of this study underscore the superior performance of LSTM networks in predicting audit risk, particularly in environments characterized by data complexity and economic volatility. The model's high accuracy and minimal classification errors highlight its practical applicability for auditors, regulatory bodies, and investors seeking early warning systems for audit risk.

This study aligns with prior research emphasizing the role of auditor characteristics, firm fundamentals, and macroeconomic conditions in influencing audit outcomes. The integration of deep learning with rigorous variable selection offers a methodological advancement over traditional regression-based approaches. It also reaffirms that audit risk is a multidimensional phenomenon best captured through advanced computational models capable of accommodating non-linear, time-dependent relationships.

The successful implementation of LSTM in this context suggests that audit firms, especially in emerging markets like Iran, can enhance their risk assessment capabilities by adopting such technologies. Doing so would enable more efficient audit planning, resource allocation, and evidence collection, ultimately contributing to higher audit quality and financial transparency.

In conclusion, this research contributes to the growing body of literature on AI in auditing by empirically validating the use of LSTM networks for audit risk prediction. The study offers a practical framework that combines statistical rigor with deep learning capabilities, making it a valuable reference for future academic and professional endeavors in the auditing field.

Authors' Contributions

Authors equally contributed to this article.

Acknowledgments

Authors thank all participants who participate in this study.

Declaration of Interest

The authors report no conflict of interest.

Funding

According to the authors, this article has no financial support.

Ethical Considerations

All procedures performed in this study were under the ethical standards.

پیش بینی ریسک حسابرسی براساس الگوریتم حافظه طولانی کوتاه مدت (LSTM)



تاریخچه مقاله

تاریخ دریافت: ۳ فروردین ۱۴۰۴

تاریخ بازنگری: ۱ خرداد ۱۴۰۴

تاریخ پذیرش: ۱۰ خرداد ۱۴۰۴

تاریخ انتشار: ۳۰ خرداد ۱۴۰۴

۱. رشا محمود علی^{ID}: دانشجوی دکتری، گروه حسابداری، واحد اصفهان (خورسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران

۲. حمیدرضا عزیزی^{ID}*: گروه حسابداری، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران. ایمیل:

gh_azizi60@iau.ac.ir (نویسنده مسئول)

۳. سراج رزوقی عباس^{ID}: گروه حسابداری، دانشکده مالی و حسابداری، دانشگاه استان واسط، عراق

۴. رحمان ساعدی^{ID}: گروه حسابداری، واحد اصفهان (خورسگان)، دانشگاه آزاد اسلامی، اصفهان، ایران

چکیده

هدف پژوهش حاضر پیش بینی ریسک حسابرسی براساس الگوریتم حافظه طولانی کوتاه مدت در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران و مقایسه نتایج حاصل از آن با سایر الگوریتم‌های یادگیری عمیق می‌باشد. به منظور نیل به این هدف ۱۶۵۰ سال-شرکت (۱۵۰ شرکت برای ۱۱ سال) مشاهده جمع آوری شده از گزارش‌های مالی سالیانه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در طی دوره زمانی ۱۳۹۲ تا ۱۴۰۲ مورد آزمون قرار گرفته اند. در پژوهش حاضر از چهار الگوریتم یادگیری عمیق (شامل الگوریتم‌های حافظه طولانی کوتاه مدت (LSTM)، ماشین بردار پشتیبان (SVM)، شبکه عصبی پیچشی (CNN) و شبکه عصبی بازگشتی (RNN)) و همچنین جهت انتخاب متغیرهای نهایی پژوهش از روش آزمون مقایسه میانگین دو نمونه جهت ایجاد مدل استفاده شده است. نتایج حاصل از الگوریتم‌های یادگیری عمیق نشان می‌دهد که صحت کلی الگوریتم‌های LSTM، SVM، CNN و RNN به ترتیب ۹۹.۱٪، ۸۹.۶٪، ۸۵.۸٪ و ۹۶.۴٪ می‌باشد که نشان دهنده این است الگوریتم LSTM بهترین عملکرد و الگوریتم CNN بدترین عملکرد را در پیش بینی ریسک حسابرسی دارد. به عبارت دیگر، نتایج نشان دهنده کارآ بودن الگوریتم حافظه طولانی کوتاه مدت (LSTM) نسبت به سایر الگوریتم‌های یادگیری عمیق می‌باشد. بنابراین در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران الگوریتم LSTM کارترین مدل را برای پیش بینی ریسک حسابرسی فراهم می‌کند. یافته‌های پژوهش حاضر می‌تواند اطلاعات سומندی بر بهبود پیش بینی ریسک حسابرسی و کاهش خطا در ارزیابی اطلاعات صورت‌های مالی، ارزیابی بهتر شواهد حسابرسی بر مبنای اطلاعات و اتخاذ اظهارنظر مبتنی بر واقعیت توسط حسابرسان فراهم کند.

کلیدواژگان: پیش بینی ریسک حسابرسی، یادگیری عمیق، الگوریتم حافظه طولانی کوتاه مدت

شیوه استناددهی: محمود علی، رشا، عزیزی، حمیدرضا، رزوقی عباس، سراج، و ساعدی، رحمان. (۱۴۰۴). پیش بینی ریسک حسابرسی براساس الگوریتم حافظه طولانی کوتاه مدت (LSTM). *حسابداری، امور مالی و هوش محاسباتی*، ۳(۱)، ۲۲-۱.



نقش حسابرسی به عنوان یک سازوکار نظارتی و تضمینی برای صحت و قابلیت اعتماد گزارش‌های مالی اهمیت فزاینده‌ای یافته است. وجود تقلب، خطا یا تحریف در صورت‌های مالی می‌تواند به فروپاشی اعتماد عمومی، اتخاذ تصمیمات نادرست اقتصادی، و ناتوانی در تخصیص بهینه منابع منجر شود. بنابراین، پیش‌بینی و ارزیابی دقیق ریسک حسابرسی، یکی از دغدغه‌های اصلی حساب‌رسان، تنظیم‌گران بازار و فعالان اقتصادی محسوب می‌شود (Cohen et al., 2014; DeFond & Zhang, 2014).

ریسک حسابرسی، به طور عام به احتمال ارائه اظهارنظر نادرست از سوی حساب‌رسان نسبت داده می‌شود و خود شامل ریسک ذاتی، ریسک کنترل و ریسک کشف است (International & Assurance Standards, 2011). این مسئله زمانی اهمیت دوچندان می‌یابد که بدانیم در شرایط اقتصادی ناپایدار، میزان تحریف صورت‌های مالی افزایش یافته و به تبع آن، احتمال اشتباه در قضاوت حرفه‌ای حساب‌رسان نیز بیشتر می‌شود (Darabi et al., 2020; Deng et al., 2023).

در چنین شرایطی، ابزارهای سنتی ارزیابی ریسک، توان چندانی در تشخیص روابط پیچیده و غیرخطی بین متغیرهای مالی و غیرمالی ندارند. روش‌های متداول آماری و مبتنی بر قضاوت حرفه‌ای، اغلب به دلیل محدودیت در پردازش داده‌های حجیم و متنوع، در شناسایی ریسک‌های پنهان با شکست مواجه می‌شوند (Hamti et al., 2020; Zariaeian & Hejazi, 2023). از این رو، در سال‌های اخیر توجه پژوهشگران به استفاده از فناوری‌های هوش مصنوعی و الگوریتم‌های یادگیری ماشین برای پیش‌بینی ریسک حسابرسی جلب شده است (Al-Din et al., 2023; O. Abu-Mehsen et al., 2023).

یکی از قدرتمندترین الگوریتم‌های مورد استفاده در این زمینه، الگوریتم حافظه طولانی کوتاه‌مدت (LSTM) است که توانایی فوق‌العاده‌ای در تحلیل داده‌های سری زمانی و شناسایی وابستگی‌های بلندمدت دارد (Kim et al., 2015; Wu & Wilson, 2016). این ویژگی‌ها موجب شده‌اند که LSTM در مقایسه با الگوریتم‌هایی نظیر ماشین بردار پشتیبان (SVM)، شبکه عصبی پیچشی (CNN) و شبکه عصبی بازگشتی (RNN)، عملکرد بهتری در تحلیل نوسانات مالی و پیش‌بینی ریسک از خود نشان دهد (Hamti & Tolouei Ashlaghi, 2022; Sujana & Dharmawan, 2023).

مطالعات اخیر نیز بیانگر آن‌اند که استفاده از مدل‌های ترکیبی بر پایه LSTM با انتخاب دقیق متغیرهای موثر، می‌تواند سطح دقت پیش‌بینی ریسک حسابرسی را به بیش از ۹۰ درصد برساند و در نتیجه، فرآیند تصمیم‌گیری برای حساب‌رسان و ذی‌نفعان را به طور چشمگیری ارتقاء بخشد (Gholami & Dashtbani, 2021; Porcuna-Enguix et al., 2021). به‌ویژه در محیط‌هایی چون بازار سرمایه ایران که با چالش‌هایی نظیر عدم شفافیت، نوسانات شدید اقتصادی و ریسک‌های نهادی مواجه است، استفاده از چنین رویکردهای نوین می‌تواند تأثیر بسزایی بر ارتقاء کیفیت حسابرسی و ثبات بازار داشته باشد (Bagheri & Lotfallian, 2024; Yarifard & Hashemi, 2024).

ریسک حسابرسی به طور مستقیم تحت تأثیر عوامل متعددی نظیر اندازه شرکت، ساختار مالکیت، شفافیت گزارش‌گری، ساختار هیأت مدیره، اثربخشی کمیته حسابرسی، و شرایط اقتصادی کلان قرار دارد (Faridi Mayvan et al., 2022; Heydinejad et al., 2021; Kurt, 2022). به عنوان نمونه، تحقیقات نشان می‌دهند که حساب‌رسان برای شرکت‌های با مالکیت دولتی، ساختار هیأت‌مدیره ضعیف یا افشای ناقص مسئولیت‌های اجتماعی، تمایل بیشتری به دریافت حق الزحمه بالاتر به دلیل افزایش ریسک دارند (Cohen et al., 2010; Krishnan et al., 2013).

از سوی دیگر، گزارش‌هایی از مؤسسات بین‌المللی نظیر PCAOB و IOSCO نیز بر ضرورت توسعه شاخص‌های کیفی برای ارزیابی ریسک حسابرسی و عملکرد حساب‌رسان تأکید کرده‌اند (International Organization of Securities, 2009; Public Company Accounting Oversight, 2010). در این راستا، محققان به بررسی نقش متغیرهایی چون تغییر حساب‌رسان، رتبه‌بندی مؤسسه حسابرسی، نوع اظهارنظر، و تخصص صنعت‌محور حساب‌رسان در پیش‌بینی ریسک حسابرسی پرداخته‌اند (Krishnan & Visvanathan, 2009; Robin & Wu, 2017).

نکته قابل توجه این است که برخلاف مدل‌های سنتی، LSTM با استفاده از معماری گیت‌بندی شده خود، می‌تواند هم اطلاعات تاریخی و هم تغییرات پویای محیط اقتصادی را درک کند و آن‌ها را به تصمیم‌گیری دقیق‌تری در خصوص پذیرش مشتریان پرریسک یا برنامه‌ریزی حسابرسی منجر سازد (Engel et al., 2010; Nurmawanti et al., 2024). بر اساس مطالعات قبلی، یکی از چالش‌های اساسی در پیش‌بینی ریسک حسابرسی، فقدان الگوهای دقیق مبتنی بر داده‌های واقعی بوده است که این پژوهش با

طراحی مدل تجربی و بهره‌گیری از داده‌های واقعی شرکت‌های ایرانی تلاش می‌کند این خلأ را برطرف سازد (Al-Din et al., 2023; Sujana & Dharmawan, 2023). در مجموع، با توجه به نتایج پژوهش‌های پیشین و نیاز به پیش‌بینی دقیق‌تر ریسک حسابرسی، طراحی و توسعه الگوریتم‌های مبتنی بر یادگیری عمیق از جمله LSTM، می‌تواند نه‌تنها منجر به افزایش دقت قضاوت حرفه‌ای حساب‌رسان شود، بلکه کارایی سرمایه‌گذاری و نظارت نهادهای بازار سرمایه را نیز بهبود بخشد (Hammersley et al., 2011; Hamti & Tolouei Ashlaghi, 2022).

پژوهش حاضر در پی پاسخ به این خلأ نظری و کاربردی است که آیا الگوریتم LSTM در مقایسه با الگوریتم‌های دیگر، توانایی بیشتری در پیش‌بینی ریسک حسابرسی در بازار سرمایه ایران دارد؟ و آیا می‌توان از طریق شناسایی متغیرهای موثر، دقت مدل‌های یادگیری عمیق را افزایش داد؟

روش پژوهش و مواد

این پژوهش از لحاظ هدف کاربردی است. طرح پژوهش آن از نوع پژوهش‌های شبه تجربی و پس‌رویدادی است و با استفاده از اطلاعات تاریخی انجام می‌شود. برای گردآوری اطلاعات مبانی نظری پژوهش از نشریات، کتب و همچنین پایگاه‌های اطلاعاتی در دسترس استفاده شده است. همچنین، داده‌های مورد نیاز برای تجزیه و تحلیل، از نرم افزار "ره آورد نوین" و سایت‌های اینترنتی "مدیریت پژوهش، توسعه و مطالعات اسلامی سازمان بورس اوراق بهادار"، کدال، بانک مرکزی و مرکز آمار ایران گردآوری شده است. جامعه آماری پژوهش حاضر، کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. بازه زمانی نیز یک دوره زمانی ۱۱ ساله براساس صورت‌های مالی سال‌های ۱۳۹۲ تا ۱۴۰۲ شرکت‌های نمونه می‌باشد.

در پژوهش حاضر برای تعیین نمونه آماری، از روش غربالگری استفاده شده است. بدین منظور آن دسته از شرکت‌های جامعه آماری که شرایط زیر را دارا باشند به عنوان نمونه آماری انتخاب و مابقی حذف می‌شوند.

۱. سال مالی شرکت منتهی به تاریخ پایان اسفند ماه هر سال باشد.
 ۲. شرکت طی دوره مورد بررسی تغییر سال مالی نداده باشد.
 ۳. شرکت‌های تحت بررسی جزء شرکتهای سرمایه گذاری، هلدینگ، واسطه‌گری مالی و بیمه نباشند.
 ۴. اطلاعات و داده‌های آن‌ها در دسترس باشد.
- با توجه به شرایط و محدودیت‌های فوق، از بین شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در مجموع ۱۵۰ شرکت به عنوان نمونه آماری پژوهش انتخاب شده است.

جدول ۱: نحوه نمونه‌گیری

۵۷۷	تعداد کل شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران
	کسر می‌شود:
(۹۳)	تعداد شرکت‌هایی که سال مالی آن‌ها منتهی به پایان اسفند نمی‌باشد و یا طی دوره تحقیق تغییر سال مالی داده باشند.
(۱۲۴)	تعداد شرکت‌هایی که در گروه شرکت‌های هلدینگ، سرمایه‌گذاری و یا واسطه‌گری‌های مالی بوده‌اند.
(۹۹)	تعداد شرکت‌هایی که در قلمرو زمانی ۱۳۹۱-۱۴۰۲ اطلاعات کامل آن‌ها در دسترس نمی‌باشد.
(۱۱۱)	تعداد شرکت‌هایی که در قلمرو زمانی ۱۳۹۱-۱۴۰۲ بیش از سه ماه توقف معاملاتی داشته‌اند.
۱۵۰	تعداد شرکت‌های نمونه

متغیر وابسته (پاسخ):

در این پژوهش، ریسک حسابرسی به عنوان متغیر وابسته تعریف شده و بر اساس مطالعات پیشین، به صورت یک متغیر ساختگی سنجیده می شود. بدین ترتیب، اگر یکی از دو نوع خطای حسابرسی (نوع اول یا دوم) رخ دهد، مقدار متغیر برابر با ۱ و در غیر این صورت برابر با ۰ در نظر گرفته می شود. خطای نوع اول زمانی رخ می دهد که حسابرس گزارش غیرمقبول صادر کند اما صورت های مالی در سال بعد تجدید ارائه نشود. خطای نوع دوم نیز زمانی است که حسابرس گزارش مقبول دهد اما در سال بعد، صورت های مالی تجدید ارائه گردد.

متغیرهای مستقل (پیش بینی کننده):

در این پژوهش، ریسک حسابرسی با در نظر گرفتن سه دسته از عوامل شامل ویژگی های حسابرس، ویژگی های صاحبکار و شرایط بازار و اقتصاد کلان بررسی شده است. نوآوری اصلی تحقیق در تحلیل همزمان این سطوح است. در بخش ویژگی های حسابرس، سه متغیر اندازه حسابرس (در قالب متغیر ساختگی)، دوره تصدی حسابرس (تعداد سال های همکاری متوالی)، و استقلال حسابرسی (با استفاده از ارقام تعهدی اختیاری) به عنوان شاخص های کلیدی در نظر گرفته شده اند. این متغیرها از گزارش های حسابرسی و هیأت مدیره استخراج شده و نقش مهمی در ارزیابی دقیق ریسک حسابرسی ایفا می کنند. لذا به منظور محاسبه آن از مدل تعدیل شده جونز ارائه شده توسط دجو و دیگران (۱۹۹۵)^۱ استفاده می شود. لذا ابتدا کل ارقام تعهدی با استفاده از رابطه ذیل برآورد می شود:

رابطه (۱):

$$TACC_{it} / TA_{it-1} = \alpha \cdot (1 / TA_{it-1}) + \beta_1 (\Delta REV_{it} - \Delta REC_{it} / TA_{it-1}) + \beta_2 (PPE_{it} / TA_{it-1}) + \varepsilon_{it}$$

که در آن:

$TACC_{it}$ = کل ارقام تعهدی شرکت i در دوره t

TA_{it-1} = جمع دارایی های شرکت i در دوره $t-1$

ΔREV_{it} = تغییرات فروش شرکت i طی سالهای $t-1$ تا t

ΔREC_{it} = تغییرات حساب های دریافتی شرکت i طی سالهای $t-1$ تا t

PPE_{it} = مبلغ ناخالص اموال، ماشین آلات و تجهیزات شرکت i در دوره t

ε_{it} = خطا یا ارقام باقی مانده مدل می باشد که نشان دهنده ارقام تعهدی اختیاری می باشد.

تغییر حسابرس (Auditorchange): یک متغیر ساختگی است در صورتی که حسابرس مستقل شرکت (موسسه حسابرسی) نسبت به سال قبل تغییر کرده باشد، عدد یک و در غیر این صورت عدد صفر تعلق می گیرد.

رتبه بندی مؤسسه حسابرسی (AUD_Rank): یک متغیر ساختگی است در صورتی که حسابرس مستقل شرکت (موسسه حسابرسی) از لحاظ رتبه بندی در گروه الف باشد، عدد یک و در غیر این صورت عدد صفر تعلق می گیرد.

نوع اظهار نظر حسابرسی (AUDOPIN): یک متغیر ساختگی است در صورتی که اظهار نظر حسابرسی مقبول باشد عدد یک و در غیر این صورت عدد صفر تعلق می گیرد. اطلاعات مربوط به این متغیر از گزارش حسابرس مستقل شرکت و یا گزارش هیأت مدیره استخراج می گردد.

تأخیر در ارائه گزارش حسابرسی (AUD_Lag): از طریق لگاریتم طبیعی تعداد روزهای بین تاریخ ترازنامه و تاریخ ارائه گزارش حسابرسی اندازه گیری می شود.

تخصص حسابرس (Specialist): در این پژوهش مشابه پژوهش صورت گرفته توسط اعتمادی و همکاران (۱۳۸۹) از سهم بازار به عنوان شاخصی برای تخصص حسابرس در صنعت بهره گرفته می شود؛ زیرا الویت صنعت را نسبت به سایر حسابسان نشان می دهد (اعتمادی و همکاران، ۱۳۸۹).

هرچه سهم بازار حسابرِس بیشتر باشد، تخصص صنعت و تجربه حسابرِس نسبت به سایر رقیبان بیشتر است. داشتن سهم غالب بازار اشاره دارد به اینکه حسابرِس به طور موفقیت آمیزی خود را از سایر رقیبان از لحاظ کیفیت حسابرِسی متمایز کرده است (اعتمادی و همکاران، ۱۳۸۹). سهم بازار حسابرِسان به صورت زیر محاسبه می‌شود: رابطه (۲):

$$\text{سهم بازار حسابرِسان} = \frac{(\text{مجموع دارایی تمام‌های صاحبکاران هر موسسه حسابرِسی خاص در صنعت خاص})}{(\text{مجموع دارایی تمام‌های صاحبکاران در این صنعت})}$$

موسساتی در این پژوهش به عنوان متخصص صنعت در نظر گرفته می‌شوند که سهم بازارشان (یعنی معادله فوق) بیش از $1/2 \times$ [شرکتهای موجود در یک صنعت/1] باشد (پالم رز، ۱۹۸۶).

حق الزحمه حسابرِس مستقل (AUDFEE): از طریق لگاریتم طبیعی حق الزحمه پرداختی به حسابرِس محاسبه می‌شود. اطلاعات مربوط به این متغیر از گزارش حسابرِس مستقل شرکت و یا گزارش هیأت مدیره استخراج می‌گردد.

تأخیر در ارائه گزارش حسابرِس مستقل (ARL): از طریق لگاریتم طبیعی تفاوت بین تعداد روزهای بین پایان سال مالی و تاریخ ارائه گزارش حسابرِسی محاسبه می‌شود.

اندازه شرکت (SIZE): برابر است با لگاریتم طبیعی کل دارایی‌های شرکت. اطلاعات مربوط به این متغیر از صورت‌های مالی استخراج می‌گردد.

نقدینگی شرکت (LIQID): برابر است با نسبت دارایی‌های جاری بر بدهی‌های جاری. اطلاعات مربوط به این متغیر از صورت‌های مالی استخراج می‌گردد.

نسبت بدهی شرکت (DEBT): برابر است با نسبت کل بدهی‌های شرکت بر کل دارایی‌های شرکت. اطلاعات مربوط به این متغیر از صورت‌های مالی استخراج می‌گردد.

سودآوری شرکت (PROF): برابر است با تقسیم سود عملیاتی بر کل دارایی‌های شرکت. اطلاعات مربوط به این متغیر از صورت‌های مالی استخراج می‌گردد.

عمر شرکت (AGE): برابر است با لگاریتم طبیعی تعداد سال‌های تأسیس شرکت تا سال جاری. اطلاعات مربوط به این متغیر از یادداشت‌های توضیحی صورت‌های مالی و یا گزارش هیأت مدیره استخراج می‌گردد.

فرصت رشد شرکت (GROWTH): برابر است با نسبت ارزش بازار حقوق صاحبان سهام بر ارزش دفتری حقوق صاحبان سهام. اطلاعات مربوط به این متغیر از صورت‌های مالی استخراج می‌گردد.

اندازه صنعت (INDSIZE): برابر است با لگاریتم طبیعی کل دارایی‌های صنعتی که شرکت متعلق به آن است (کیم و همکاران، ۲۰۱۶). برابر است با لگاریتم طبیعی تعداد سال‌های تأسیس شرکت تا سال جاری. اطلاعات مربوط به این متغیر از گزارش هیأت مدیره استخراج می‌گردد.

سطح رقابت صنعت (PMC): در این پژوهش به منظور اندازه گیری رقابت بازار محصول از شاخص هرفیندال-هیرشمن استفاده می‌شود. شاخص هرفیندال-هیرشمن از حاج جمع توان دوم سهم بازار تمامی بنگاه‌های فعال در صنعت به صورت فرمول زیر به دست می‌آید (چن و همکاران، ۲۰۱۲):

رابطه (۳):

$$HHI = \sum_{i=1}^k S_i^2$$

که در آن HHI شاخص هرفیندال-هیرشمن، k تعداد بنگاه‌های فعال در بازار و S_i سهم بازار شرکت i ام است که از رابطه زیر به دست می‌آید:

رابطه (۴):

$$S_i = X_j / \sum_{j=1}^n X_j$$

¹-Palmrose

که در آن X_j نشان دهنده فروش شرکت j ام و A نشان دهنده نوع صنعت است. شاخص هرفیندال-هیرشمن، میزان تمرکز صنعت را اندازه گیری می کند. هر چه این شاخص بزرگتر باشد، میزان تمرکز بیشتر بوده و رقابت کمتری در صنعت وجود دارد و بالعکس. لازم به ذکر است که این شاخص در پژوهش های چن و همکاران (۲۰۱۲)؛ چنگ و همکاران (۲۰۱۳)؛ نمازی و ابراهیمی (۱۳۹۱)؛ خواجوی و همکاران (۱۳۹۲) و نمازی و رضایی (۱۳۹۳) نیز استفاده شده است.

نوع مالکیت (دولتی یا خصوصی) (TypeOWN): یک متغیر ساختگی است اگر بیش از پنجاه درصد سهام شرکت تحت تملک بخش خصوصی باشد عدد یک و در غیر این صورت عدد صفر می گیرد (کیم و همکاران، ۲۰۱۵). اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد. مالکیت دولتی (GOWN): از طریق تقسیم تعداد سهام تحت تملک سهامداران دولتی بر کل تعداد سهام منتشره شرکت بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

مالکیت نهادی (INSOWN): از طریق تقسیم تعداد سهام تحت تملک سهامداران نهادی بر کل تعداد سهام منتشره شرکت بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

مالکیت مدیریتی (MOWN): از طریق تقسیم تعداد سهام تحت تملک مدیران شرکت بر کل تعداد سهام منتشره شرکت بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

مالکیت سهامدار عمده (BOWN): از طریق تقسیم تعداد سهام تحت تملک بزرگترین سهامدار شرکت بر کل تعداد سهام منتشره شرکت بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

اندازه کمیته حسابرسی (ACSIZE): نشان دهنده تعداد اعضای کمیته حسابرسی می باشد. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

استقلال کمیته حسابرسی (ACIND): از طریق تقسیم اعضای مستقل کمیته حسابرسی بر کل تعداد اعضای کمیته حسابرسی بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

تخصص مالی کمیته حسابرسی (ACSEP): از طریق تقسیم اعضای کمیته حسابرسی دارای تخصص مالی (دارای مدرک تحصیلی حسابداری، حسابرسی، مدیریت و اقتصاد) بر کل تعداد اعضای کمیته حسابرسی بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

اندازه هیأت مدیره (BS): برابر است با تعداد اعضای هیأت مدیره شرکت (الکدای و هنیفا، ۲۰۱۲). برابر است با لگاریتم طبیعی تعداد سال های تأسیس شرکت تا سال جاری. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

استقلال هیأت مدیره (BI): برابر است با نسبت تعداد اعضای غیر موظف در هیأت مدیره شرکت بر تعداد اعضای هیأت مدیره شرکت (الکدای و هنیفا، ۲۰۱۲). برابر است با لگاریتم طبیعی تعداد سال های تأسیس شرکت تا سال جاری. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد. دوره تصدی مدیر عامل (TENUREM): نشان دهنده تعداد سال هایی است که یک شخص به طور متوالی مسئولیت مدیر عاملی یک شرکت را به عهده دارد. اطلاعات مربوط به این متغیر از گزارش هیأت مدیره استخراج می گردد.

تخصص مالی هیأت مدیره (BSEP): از طریق تقسیم اعضای هیأت مدیره دارای تخصص مالی (دارای مدرک تحصیلی حسابداری، حسابرسی، مدیریت و اقتصاد) بر کل تعداد اعضای هیأت مدیره بدست می آید. اطلاعات مربوط به این متغیر از یادداشت های توضیحی صورت های مالی و یا گزارش هیأت مدیره استخراج می گردد.

ریسک سیستماتیک (SYSR): با استفاده از برآورد مدل CAPM بتا برای هر شرکت در طول سال بدست می آید (بلو و همکاران، ۲۰۱۷).

ریسک غیر سیستماتیک (NSYSR): ریسک غیر سیستماتیک که با برآورد انحراف استاندارد باقیمانده از مدل CAPM روزانه محاسبه است (بلو و همکاران، ۲۰۱۷).


نرخ تورم (INF): برابر است با نرخ تورم (شاخص قیمت مصرف کننده) (انتیم و همکاران، ۲۰۱۵). که اطلاعات مربوط به آن از سایت بانک مرکزی و یا سایت مرکز آمار ایران استخراج می‌گردد.

نرخ بهره (INT): برابر است با نرخ بهره (انتیم و همکاران، ۲۰۱۵). که اطلاعات مربوط به آن از سایت بانک مرکزی و یا سایت مرکز آمار ایران استخراج می‌گردد.

نرخ ارز (CURR): برابر است با نرخ ارز (انتیم و همکاران، ۲۰۱۵). که اطلاعات مربوط به آن از سایت بانک مرکزی و یا سایت مرکز آمار ایران استخراج می‌گردد.

نرخ رشد اقتصادی (GGDP): برابر است با تغییرات تولید ناخالص داخلی، که اطلاعات مربوط به آن از سایت بانک مرکزی و یا سایت مرکز آمار ایران استخراج می‌گردد.

الگوریتم حافظه‌ی طولانی کوتاه مدت (LSTM^۱): حافظه طولانی کوتاه مدت (LSTM) یک معماری شبکه عصبی بازگشتی است که در سال ۱۹۹۷ میلادی توسط سپ هوخرایتر و یورگن اشمیدهورر ارائه شد، و بعداً در سال ۲۰۰۰ میلادی توسط فیلیکس ژرس و دیگران بهبود داده شد. در شبکه عصبی بازگشتی برخلاف شبکه عصبی پیشخور، ورودی می‌تواند به صورت دنباله (مثل صوت یا ویدیو) باشد. این ویژگی باعث شده شبکه‌های عصبی بازگشتی برای پردازش داده‌های زمانی بسیار مناسب باشند زیرا الگوها در داده‌های سری زمانی می‌توانند در فواصل مختلف واقع شوند. برای مثال، شبکه LSTM در حوزه‌هایی همچون تشخیص دست خط، ترجمه ماشینی، تشخیص گفتار، کنترل ربات‌ها و بازی‌های ویدیویی قابل استفاده است.



شکل ۱. یک بلوک حافظه طولانی کوتاه مدت


یک بلوک LSTM به طور کلی از وزن‌های محتوای سلول (C_t), دروازه ورودی (i_t), دروازه خروجی (O_t) و دروازه فراموشی (f_t) تشکیل شده است. محتوای سلول می‌تواند در بازه زمانی طولانی محتوای خود را حفظ کند و در واقع اطلاعات پیشین را به خاطر بسپارد. دروازه‌ها نیز بردارهایی با مقادیر بین ۰ و ۱ هستند که چگونگی پیشروی اطلاعات قدیمی و اضافه شدن اطلاعات جدید را مشخص می‌کنند. به طور کلی ۱ به معنای عبور و ۰ به معنای حذف اطلاعات است. دروازه ورودی مشخص می‌کند چه بخش‌هایی از داده ورودی و به چه مقدار به محتوای سلول اضافه شوند. دروازه فراموشی مشخص می‌کند که چه بخش‌هایی از محتوای سلول از آن حذف شوند. دروازه خروجی نیز مشخص می‌کند محتوای وضعیت مخفی (h_t) حاوی چه بخشی از محتوای سلول باشد.

^۱-Long short-term memory

یکی از مشکلات اصلی شبکه‌های عصبی بازگشتی، مشتق ناپدیدشونده^۱ و مشتق انفجاری^۲ است. در بلوک LSTM به منظور حل این دو مشکل، راه‌هایی برای انتقال اطلاعات مهم پیشین در هنگام پیشروی ایجاد شده‌است. این مهم به طور کلی از طریق ضرب بردارهایی تحت عنوان دروازه، در ورودی‌های بلوک صورت می‌پذیرد. شبکه حافظه طولانی کوتاه‌مدت (LSTM) با استفاده از سلول‌هایی که می‌توانند اطلاعات را در بازه‌های زمانی طولانی حفظ کنند، مشکلات شبکه‌های عصبی بازگشتی مانند مشتق ناپدیدشونده و انفجاری را با بهره‌گیری از دروازه‌هایی برای کنترل ورود، خروج و فراموشی اطلاعات حل می‌کند.

ماشین بردار پشتیبان (SVM) روشی نظارت‌شده برای طبقه‌بندی و رگرسیون است که با تبدیل داده‌ها به فضای ابعادی بالاتر و استفاده از توابع هسته‌ای مختلف، داده‌های پیچیده را به خوبی دسته‌بندی می‌کند.

شبکه عصبی پیچشی (CNN) نوعی شبکه عمیق است که بیشتر برای داده‌های بصری کاربرد دارد و از لایه‌های نورونی با وزن و بایاس قابل یادگیری تشکیل شده است. هر نورون ورودی‌ها را ضرب داخلی کرده، با بایاس جمع می‌کند و نتیجه را به تابع غیرخطی می‌فرستد.



شکل ۲. یک بلوک شبکه عصبی پیچشی


فرآیند بالا لایه به لایه انجام می‌شود و در نهایت به لایه خروجی می‌رسیم. لایه خروجی، پیش‌بینی شبکه را تولید می‌کند.

شبکه عصبی بازگشتی (RNN^۳): شبکه عصبی بازگشتی (RNN) نوعی شبکه عصبی مصنوعی است که برای پردازش داده‌های ترتیبی مانند تشخیص گفتار و پردازش زبان طبیعی به کار می‌رود. برخلاف شبکه‌های پیش‌خور مانند CNN که سیگنال فقط در یک جهت حرکت می‌کند و حافظه‌ای از داده‌های قبلی ندارند، RNN دارای حلقه بازخوردی است که خروجی قبلی را به همراه ورودی جدید به شبکه بازمی‌گرداند. این ساختار به RNN امکان می‌دهد حافظه داخلی داشته باشد و اطلاعات لحظات قبل را حفظ کرده و در پردازش دنباله‌ای از داده‌ها از آن استفاده کند.

^۱-vanishing gradient problem

^۲-exploding gradient

^۳-Recurrent Neural Networks



An unrolled recurrent neural network.

شکل ۳. یک بلوک شبکه عصبی بازگشتی

همانطور که در شکل فوق مشاهده می‌شود، x_t را از دنباله ورودی می‌گیرد، خروجی h_t به همراه x_1 ورودی مرحله بعدی است. در مرحله بعد، خروجی h_1 و x_2 ورودی مرحله بعد است. به این ترتیب، شبکه در هنگام آموزش قادر به یادآوری ورودی‌های قبلی خواهد بود.

شبکه عصبی بازگشتی می‌تواند کاربردهایی به شرح زیر داشته باشد:

۱. شرح نویسی عکس^۱: شبکه عصبی بازگشتی با تحلیل حالت کنونی عکس، برای شرح نویسی عکس به کار می‌رود.
۲. پیش بینی سری‌های زمانی^۲: هر مسئله سری زمانی مانند پیش بینی قیمت یک سهام در یک ماه خاص، با RNN قابل انجام است.
۳. پردازش زبان طبیعی^۳: کاوش متن و تحلیل احساسات می‌تواند با استفاده از RNN انجام شود.
۴. ترجمه ماشینی^۴: شبکه RNN می‌تواند ورودی خود را از یک زبان دریافت و آن را به عنوان خروجی به زبان دیگری ترجمه کند.

یافته‌ها

در جدول (۲)، پتل الف، برخی از مفاهیم آمار توصیفی متغیرها، شامل میانگین، میانه، حداقل مشاهدات، حداکثر مشاهدات و انحراف معیار ارائه شده است. به عنوان مثال، است. میانگین متغیر نقدینگی شرکت ۱۶۱۴ می‌باشد که به توجه به انحراف معیار (۰.۸۱۸) از نوسان پذیری پایینی برخوردار است. میانگین متغیر سودآوری شرکت ۰.۱۶۳ می‌باشد که به توجه به انحراف معیار (۰.۱۳۵) از نوسان پذیری پایینی برخوردار میانگین نسبت بدهی شرکت ۰.۵۵۳ می‌باشد که نشان دهنده این است که ۵۵.۳٪ منابع مالی شرکت از طریق بدهی تأمین مالی شده است.

جدول ۲. آمار توصیفی متغیرهای پژوهش

پتل الف: متغیرهای پیوسته					
نام متغیرها	تعداد مشاهدات	میانگین	میانه	حداکثر	حداقل
دوره تصدی حسابرس	۱۶۵۰	۴.۰۲۰	۳.۰۰۰	۱۶.۰۰۰	۱.۰۰۰
استقلال حسابرسی	۱۶۵۰	۰.۰۵۲	۰.۰۳۹	۰.۱۵۴	۰.۰۰۴
تأخیر در ارائه گزارش حسابرسی	۱۶۵۰	۴.۳۴۳	۴.۴۱۹	۴.۷۷۱	۳.۶۸۹
حق الزحمه حسابرس	۱۶۵۰	۵.۲۶۰	۶.۸۱۸	۸.۵۴۷	۴.۵۱۴
اندازه شرکت	۱۶۵۰	۱۴.۸۵۱	۱۴.۶۳۶	۱۸.۰۶۷	۱۲.۴۲۱
نقدینگی شرکت	۱۶۵۰	۱۶۱۴	۱.۳۸۷	۳.۸۹۴	۰.۶۳۳

¹-Image Captioning

²-Time Series Prediction

³-Natural Language Processing

⁴-Machine Translation

حسابداری، امور مالی و هوش محاسباتی

نسبت بدهی شرکت	۱۶۵۰	۰.۵۵۳	۰.۵۵۹	۰.۹۰۹	۰.۱۷۴	۰.۲۰۶
سودآوری شرکت	۱۶۵۰	۰.۱۶۳	۰.۱۳۵	۰.۴۳۵	-۰.۰۴۹	۰.۱۳۵
عمر شرکت	۱۶۵۰	۳.۷۱۹	۳.۸۰۷	۴.۱۴۳	۳.۰۹۱	۰.۳۱۸
فرصت رشد شرکت	۱۶۵۰	۷۰.۵۷	۴.۴۱۱	۲۸.۵۸۷	۱۰.۲۹	۷.۱۶۸
اندازه صنعت	۱۶۵۰	۱۸.۷۴۱	۱۸.۷۷۱	۲۱.۲۹۲	۱۵.۸۹۷	۱.۵۷۹
سطح رقابت صنعت	۱۶۵۰	۰.۱۶۹	۰.۱۶۷	۰.۳۸۹	۰.۰۱۱	۰.۱۳۹
مالکیت دولتی	۱۶۵۰	۰.۴۴۷	۰.۵۴۲	۰.۸۹۱	۰.۰۰۰	۰.۳۳۶
مالکیت نهادی	۱۶۵۰	۰.۵۳۹	۰.۶۴۰	۰.۹۱۸	۰.۰۴۶	۰.۳۲۱
مالکیت مدیریتی	۱۶۵۰	۰.۲۱۴	۰.۲۲۷	۰.۳۰۲	۰.۰۳۱	۰.۰۷۰
مالکیت سهامدار عمده	۱۶۵۰	۰.۴۹۶	۰.۵۱۰	۰.۸۶۳	۰.۱۲۷	۰.۲۰۴
اندازه کمیته حسابرسی	۱۶۵۰	۲.۹۰۱	۳.۰۰۰	۵.۰۰۰	۰.۰۰۰	۰.۸۵۰
استقلال کمیته حسابرسی	۱۶۵۰	۰.۶۶۸	۰.۶۶۷	۱.۰۰۰	۰.۰۰۰	۰.۲۶۰
تخصص مالی کمیته حسابرسی	۱۶۵۰	۰.۸۵۸	۱.۰۰۰	۱.۰۰۰	۰.۰۰۰	۰.۲۶۸
اندازه هیأت مدیره	۱۶۵۰	۵.۰۲۵	۵.۰۰۰	۷.۰۰۰	۵.۰۰۰	۰.۲۲۴
استقلال هیأت مدیره	۱۶۵۰	۰.۶۵۱	۰.۶۰۰	۱.۰۰۰	۰.۰۰۰	۰.۱۸۴
دوره تصدی مدیر عامل	۱۶۵۰	۳.۸۰۹	۲.۰۰۰	۱۳.۰۰۰	۱.۰۰۰	۳.۴۱۹
تخصص مالی هیأت مدیره	۱۶۵۰	۰.۶۸۴	۰.۸۰۰	۰.۸۰۰	۰.۱۳۳	۰.۱۹۱
ریسک سیستماتیک	۱۶۵۰	۰.۶۹۳	۰.۶۰۹	۲.۲۷۹	-۰.۵۹۳	۰.۷۵۵
ریسک غیر سیستماتیک	۱۶۵۰	۰.۱۵۱	۰.۱۴۳	۰.۳۰۵	۰.۰۴۶	۰.۰۷۳
نرخ تورم	۱۶۵۰	۲۹.۳۶۴	۳۴.۷۰۰	۴۶.۵۰۰	۹.۰۰۰	۱۴.۲۳۲
نرخ بهره	۱۶۵۰	۱۸.۶۷۷	۱۸.۰۰۰	۲۳.۶۶۰	۱۲.۵۰۰	۳.۳۸۹
نرخ ارز	۱۶۵۰	۱۴۸۲۴۹	۴۲۰۰۰	۵۹۹۰۰۰	۲۵۱۰۲	۲۰۸۸۱۴
نرخ رشد اقتصادی	۱۶۵۰	۱.۵۳۶	۳.۶۰۰	۸.۳۰۰	-۷.۰۰۰	۴.۵۳۴

پنل ب: آزمون t در شرکت‌های دارای ریسک حسابرسی بالا و ریسک حسابرسی پایین

نام متغیرها	ریسک حسابرسی بالا (تعداد مشاهدات = ۵۰۳)	ریسک حسابرسی پایین (تعداد مشاهدات = ۱۱۹۱)	آماره t
دوره تصدی حسابرس	۳.۲۹۸	۴.۶۲۹	-۳.۲۲۱***
استقلال حسابرسی	۰.۰۴۰	۰.۰۵۷	-۸.۲۴۳***
تأخیر در ارائه گزارش حسابرسی	۳.۸۲۲	۴.۵۵۱	-۱.۷۲۶*
حق الزحمه حسابرس	۵.۰۷۲	۵.۸۱۵	-۵.۶۶۸***
اندازه شرکت	۱۴.۴۳۸	۱۵.۱۹۶	-۱۱.۴۵۳***
نقدینگی شرکت	۱.۲۰۱	۱.۷۸۱	-۱۵.۵۹۳***
نسبت بدهی شرکت	۰.۶۳۳	۰.۵۲۱	۱۰.۳۱۴***
سودآوری شرکت	۰.۰۳۷	۰.۲۱۳	-۳۹.۰۶۶***
عمر شرکت	۳.۷۰۱	۳.۷۲۸	-۱.۵۲۴
فرصت رشد شرکت	۶.۲۹۰	۷.۳۶۷	-۲.۶۱۶***
اندازه صنعت	۱۸.۷۰۰	۱۸.۷۵۸	-۰.۶۷۶
سطح رقابت صنعت	۰.۱۶۱	۰.۱۷۴	-۱.۶۷۶*
مالکیت دولتی	۰.۴۸۸	۰.۴۲۵	۲.۷۷۳***
مالکیت نهادی	۰.۵۰۶	۰.۵۹۹	-۲.۲۰۰**
مالکیت مدیریتی	۰.۱۶۲	۰.۲۴۴	-۴.۲۹۵***
مالکیت سهامدار عمده	۰.۵۰۶	۰.۴۹۳	۱.۱۵۹
اندازه کمیته حسابرسی	۲.۹۰۳	۲.۹۰۰	۰.۰۷۸
استقلال کمیته حسابرسی	۰.۶۶۶	۰.۶۶۸	-۰.۱۵۲
تخصص مالی کمیته حسابرسی	۰.۷۴۱	۰.۸۹۱	-۳.۸۳۳***

محمود علی و همکاران

اندازه هیأت مدیره	۵۰۳۰	۵۰۳۴	۰۴۶۳
استقلال هیأت مدیره	۰۵۹۱	۰۶۶۶	-۳۸۱۷***
دوره تصدی مدیر عامل	۳۵۳۹	۳۹۱۸	-۲۰۱۵۶**
تخصص مالی هیأت مدیره	۰۶۳۸	۰۶۹۸	-۲۰۱۴۶**
ریسک سیستماتیک	۰۷۴۱	۰۶۵۶	۴۳۳۶***
ریسک غیر سیستماتیک	۰۰۱۷۸	۰۰۱۳۳	۲۰۱۲۶**
نرخ تورم	۳۰۸۷۴	۲۵۶۲۷	۶۷۶۹***
نرخ بهره	۱۸۹۹۴	۱۷۸۹۴	۶۲۰۳***
نرخ ارز	۱۶۸۷۴۴۵۶۲	۹۵۴۲۵۳۴۷	۶۶۰۲***
نرخ رشد اقتصادی	۱۰۲۸۳	۱۶۳۹	-۱۰۳۷۸
* معناداری در سطح اطمینان ۹۰٪، ** معناداری در سطح اطمینان ۹۵٪ و *** معناداری در سطح اطمینان ۹۹٪			

پنل پ: آزمون کای دو در شرکت دارای ریسک حسابرسی بالا و ریسک حسابرسی پایین			
نام متغیرها	ریسک حسابرسی بالا (تعداد مشاهدات = ۵۰۳)	ریسک حسابرسی پایین (تعداد مشاهدات = ۱۱۹۱)	آماره کای دو
اندازه حسابرس	۸۹	۳۲۸	۲۳۰۲۵۵***
تغییر حسابرس	۳۶۷	۲۳۲	۴۰۱۸۰**
رتبه بندی مؤسسه حسابرسی	۱۰۳	۳۶۰	۲۶۰۱۷۸***
نوع اظهارنظر حسابرسی	۱۶۴	۷۶۲	۱۴۰۳۳۳***
تخصص حسابرس	۱۷۱	۶۹۸	۵۰۱۴۷**
نوع مالکیت (خصوصی در مقابل دولتی)	۱۹۴	۵۳۰	۲۰۴۹۸*
* معناداری در سطح اطمینان ۹۰٪، ** معناداری در سطح اطمینان ۹۵٪ و *** معناداری در سطح اطمینان ۹۹٪			
منبع: یافته‌های پژوهشگر			

نتایج آزمون χ^2 در پنل ب نشان می‌دهد که در سطح اطمینان ۹۵٪ متغیرهای دوره تصدی حسابرس، استقلال حسابرسی، حق الزحمه حسابرس، اندازه شرکت، نقدینگی، سودآوری، فرصت رشد، مالکیت نهادی و مدیریتی، تخصص مالی کمیته حسابرسی، استقلال هیأت مدیره، دوره تصدی مدیرعامل و تخصص مالی هیأت مدیره بین شرکت‌های دارای ریسک حسابرسی بالا و پایین تفاوت معنادار دارند؛ به طوری که میانگین این متغیرها در شرکت‌های دارای ریسک بالا کمتر است. همچنین، نسبت بدهی، مالکیت دولتی، ریسک سیستماتیک و غیرسیستماتیک، نرخ تورم، نرخ بهره و نرخ ارز در شرکت‌های با ریسک بالا به‌طور معناداری بیشتر از شرکت‌های با ریسک پایین است.

در مقابل، متغیرهای تأخیر در ارائه گزارش حسابرسی، عمر شرکت، اندازه و سطح رقابت صنعت، مالکیت سهامدار عمده، اندازه و استقلال کمیته حسابرسی، اندازه هیأت مدیره و نرخ رشد اقتصادی تفاوت معناداری بین دو گروه ندارند.

بر اساس نتایج آزمون کای دو در پنل پ، اندازه حسابرس، تغییر حسابرس، رتبه‌بندی مؤسسه حسابرسی، نوع اظهارنظر حسابرسی و تخصص حسابرس تفاوت معناداری بین شرکت‌های با ریسک حسابرسی بالا و پایین نشان می‌دهد، ولی نوع مالکیت (خصوصی یا دولتی) تفاوت معناداری ندارد.

به منظور پاسخگویی به سوالات و همچنین دستیابی به اهداف پژوهش ابتدا مدل‌های مورد نظر در تحقیق حاضر را شامل مدل‌های ایجاد با الگوریتم‌های حافظه طولانی کوتاه مدت (LSTM)، ماشین بردار پشتیبان (SVM)، شبکه عصبی پیچشی (CNN) و شبکه عصبی بازگشتی (RNN) و با استفاده از متغیرهای انتخاب شده بر اساس آزمون مقایسه میانگین دو نمونه را ایجاد و به مقایسه نتایج ایجاد شده خواهیم پرداخت.

به منظور تعیین متغیرهای نهایی (با اهمیت) پژوهش از میان متغیرهای اولیه پژوهش (۴۰ متغیر انتخاب شده براساس مبانی نظری و مطالعات تجربی)، از آزمون مقایسه میانگین دو نمونه مستقل استفاده می‌کنیم. به منظور بررسی مقایسه میانگین دو نمونه، ابتدا باید واریانس دو نمونه را مقایسه نمود به عبارت دیگر آزمون تساوی واریانس‌ها مقدم بر آزمون تساوی میانگین‌ها است. جهت تساوی واریانس‌ها از آزمون لوین که مبتنی بر آماره فیشر است، استفاده می‌کنیم. در این آزمون نیازی نیست که توزیع داده‌ها نرمال باشد.

آماره t جهت آزمون تساوی میانگین دو نمونه، در حالت تساوی و عدم تساوی واریانس دو نمونه مورد نظر، محاسبه می‌شود. در حالت تساوی واریانس‌ها از رابطه (۵) برای محاسبه آماره t استفاده می‌کنیم که در این حالت درجه آزادی برابر $df=n_1+n_2-2$ است.

رابطه (۵):

$$t = \frac{(\bar{x}_1 - \bar{x}_2) - (u_1 - u_2)}{S_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

رابطه (۶):

$$S_p = \sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}}$$

در حالت عدم تساوی واریانس‌ها آماره t از رابطه (۷) و درجه آزادی از رابطه (۸) محاسبه می‌شود.

رابطه (۷):

$$t = \frac{(\bar{x}_1 - \bar{x}_2) - (u_1 - u_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$$

رابطه (۸):

$$t = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{\left(\frac{S_1^2}{n_1}\right)^2}{n_1 - 1} + \frac{\left(\frac{S_2^2}{n_2}\right)^2}{n_2 - 1}}$$

که در آن‌ها n_1 و n_2 تعداد اعضای نمونه اول و نمونه دوم و S_1 و S_2 انحراف معیار نمونه اول و دوم هستند.

سپس براساس عدد t محاسبه شده طبق روابط فوق و عدد t طبق جدول با توجه به سطح خطای ۵ درصد به تفسیر نتایج خواهیم پرداخت، اگر عدد t محاسبه شده از عدد t

طبق جدول کوچک تر باشد ($p\text{-value} < 0.05$)، معنادار بودن تفاوت میانگین‌های دو گروه پذیرفته می‌شود و در غیر این صورت رد خواهد شد.

نتایج آزمون t در جدول ۲ نشان می‌دهد که در سطح اطمینان ۹۵٪، بین شرکت‌های دارای ریسک حسابرسی بالا و پایین، ۲۵ متغیر شامل دوره تصدی حسابرس، استقلال حسابرسی، حق الزحمه حسابرس، اندازه و نقدینگی شرکت، سودآوری، فرصت رشد، مالکیت نهادی و مدیریتی، تخصص مالی کمیته حسابرسی، استقلال و تخصص مالی هیأت مدیره، دوره تصدی مدیر عامل، نسبت بدهی، مالکیت دولتی، ریسک سیستماتیک و غیرسیستماتیک، نرخ تورم، بهره، ارز، اندازه و تغییر حسابرس، رتبه‌بندی مؤسسه حسابرسی، نوع اظهارنظر و تخصص حسابرس تفاوت معناداری دارند. بنابراین، این ۲۵ متغیر برای پیاده‌سازی الگوریتم یادگیری عمیق به عنوان متغیرهای پیش‌بین انتخاب شده‌اند.

برای پیاده‌سازی و ارزیابی الگوریتم‌ها، داده‌های پژوهش به دو مجموعه آموزش و آزمایش تقسیم شدند. داده‌های آموزش برای ساخت مدل و داده‌های آزمایش برای ارزیابی عملکرد مدل استفاده می‌شوند. تکنیک‌های دسته‌بندی بر اساس معیارهایی مانند صحت (تعداد پیش‌بینی‌های درست)، سرعت (زمان ساخت و اجرای مدل) و پایداری (مقاومت در برابر داده‌های غیرمعمول یا مفقود) با هم مقایسه می‌شوند. برای ارزیابی دقیق‌تر، داده‌ها ۵۰ بار به‌صورت تصادفی تقسیم شده‌اند؛ در هر بار، ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد برای آزمایش به کار رفته و میانگین نتایج ۵۰ اجرای مدل به‌عنوان نتیجه نهایی گزارش شده است.

جدول ۳. پارامترهای شبیه‌سازی

پارامتر شبیه‌سازی	مقدار
تعداد نمونه‌ها کل دیتاست	۱۶۵۰ سال-شرکت (مشاهده)
تعداد ویژگی هر نمونه	۲۵ ویژگی
تعداد نمونه‌های آموزش مدل	۱۲۳۸
تعداد نمونه‌های تست مدل	۴۱۲

تشخیص یک روش دسته‌بندی بر روی داده‌ها که تنها دارای دو کلاس می‌باشد با یکی از موارد مثبت درست (TP)، منفی نادرست (FN)، منفی درست (TN) و مثبت نادرست (FP) بیان می‌شود. بر این اساس می‌توان پارامتر صحت (یا دقت)^۱ را تعریف نمود. دقت، استانداردترین متریک برای خلاصه سازی عملکرد تشخیص در تمامی کلاس‌ها می‌باشد که بصورت فرمول زیر محاسبه می‌شود.

رابطه (۱۳):

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

همانگونه که در جدول (۴) نشان داده شده است، برای محاسبه دقت دسته‌بندی ابتدا باید ماتریس اغتشاش^۲ محاسبه شود. داده‌های روی قطر اصلی، تشخیص‌های درست روش دسته‌بندی استفاده شده است.

جدول ۴. ماتریس اغتشاش

True Positives (TP)	False Positives (FP)
False Negatives (FN)	True Negatives (TN)

با توجه به هدف پژوهش حاضر که پیش بینی ریسک حسابرسی است پارامترهای ماتریس اغتشاش به صورت زیر تعریف می‌شود:

TP: درصد تشخیص درست شرکت‌های دارای ریسک حسابرسی بالا

TN: درصد تشخیص درست شرکت‌های ریسک حسابرسی پایین

FP: درصد تشخیص غلط شرکت‌های دارای ریسک حسابرسی بالا به عنوان شرکت‌های دارای ریسک حسابرسی پایین

FN: درصد تشخیص غلط شرکت‌های دارای ریسک حسابرسی پایین به عنوان شرکت‌های دارای ریسک حسابرسی بالا

در ادامه ماتریس اغتشاش هر روش دسته‌بندی در پیش بینی ریسک حسابرسی نشان داده شده است.

نتایج الگوریتم حافظه طولانی کوتاه مدت (LSTM) که در جدول (۵) به صورت ماتریس اغتشاش ارائه شده است، نشان می‌دهد خطای مدل در شناسایی شرکت‌های با ریسک حسابرسی بالا و پایین به ترتیب ۰.۵٪ و ۱.۳٪ است. به طور کلی، دقت پیش‌بینی این مدل برای ریسک حسابرسی شرکت‌های بورس تهران حدود ۹۹.۱٪ برآورد شده که حاکی از توانایی بالای LSTM در شناسایی صحیح شرکت‌های پرریسک با استفاده از متغیرهای انتخاب شده به روش آزمون t می‌باشد.

جدول ۵. نتایج ماتریس اغتشاش در پیش بینی ریسک حسابرسی (الگوریتم حافظه طولانی کوتاه مدت)

	LSTM & T-test	
	Positive	Negative
Positive	۰.۹۹۵	۰.۰۱۳
Negative	۰.۰۰۵	۰.۹۸۷
Accuracy		۰.۹۹۱

^۱-Accuracy

^۲-Confusion Matrix

نتایج الگوریتم ماشین بردار پشتیبان (SVM) که در جدول (۶) و قالب ماتریس اغتشاش ارائه شده، نشان می‌دهد که خطای مدل در شناسایی شرکت‌های دارای ریسک حسابرسی بالا و پایین به ترتیب ۸.۹٪ و ۱۱.۹٪ است. به طور کلی، دقت این مدل در پیش‌بینی ریسک حسابرسی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران تقریباً ۸۹.۶٪ است، که نشان می‌دهد با استفاده از متغیرهای انتخاب شده به روش آزمون T و الگوریتم SVM، می‌توان با احتمال ۸۹.۶٪ شرکت‌های دارای ریسک حسابرسی بالا را شناسایی کرد.

جدول ۶. نتایج ماتریس اغتشاش در پیش‌بینی ریسک حسابرسی (الگوریتم ماشین بردار پشتیبان)

	SVM & T-test	
	Positive	Negative
Positive	۰.۹۱۱	۰.۱۱۹
Negative	۰.۰۸۹	۰.۸۸۱
Accuracy	۰.۸۹۶	

نتایج الگوریتم شبکه عصبی پیچشی (CNN) که در جدول (۷) و قالب ماتریس اغتشاش ارائه شده، نشان می‌دهد که میزان خطای مدل در شناسایی شرکت‌های دارای ریسک حسابرسی بالا و پایین به ترتیب ۱۳.۳٪ و ۱۵.۱٪ است. به طور کلی، دقت این مدل در پیش‌بینی ریسک حسابرسی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران تقریباً ۸۵.۸٪ است، که بیانگر توانایی شناسایی شرکت‌های دارای ریسک حسابرسی بالا با احتمال ۸۵.۸٪ با استفاده از متغیرهای انتخاب شده به روش آزمون T و الگوریتم CNN می‌باشد.

جدول ۷. نتایج ماتریس اغتشاش در پیش‌بینی ریسک حسابرسی (الگوریتم شبکه عصبی پیچشی)

	CNN & T-test	
	Positive	Negative
Positive	۰.۸۶۷	۰.۱۵۱
Negative	۰.۱۳۳	۰.۸۴۹
Accuracy	۰.۸۵۸	

نتایج حاصل از الگوریتم شبکه عصبی بازگشتی (RNN) که در قالب ماتریس اغتشاش و در جدول (۸) ارائه شده است، نشان می‌دهد که میزان خطای مدل در شناسایی شرکت‌های دارای ریسک حسابرسی بالا و شرکت‌های دارای ریسک حسابرسی پایین به ترتیب ۲.۷٪ و ۴.۵٪ می‌باشد. در حالت کلی نتایج حاصل از الگوریتم RNN نشان می‌دهد که میزان دقت این مدل در پیش‌بینی ریسک حسابرسی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران تقریباً ۹۶.۴٪ است، این موضوع نشان دهنده این است که با توجه به متغیرهای انتخاب شده به روش T-test و الگوریتم شبکه عصبی بازگشتی (RNN)، می‌توان با احتمال ۹۶.۴٪ شرکت‌های دارای ریسک حسابرسی بالا را شناسایی کرد.

جدول ۸. نتایج ماتریس اغتشاش در پیش‌بینی ریسک حسابرسی (الگوریتم شبکه عصبی بازگشتی)

	RNN & T-test	
	Positive	Negative
Positive	۰.۹۷۳	۰.۰۴۵
Negative	۰.۰۲۷	۰.۹۵۵
Accuracy	۰.۹۶۴	

جدول ۹. خلاصه نتایج الگوریتم LSTM و سایر الگوریتم‌های یادگیری عمیق در پیش بینی ریسک حساسی

الگوریتم	Accuracy	FN
LSTM	۰.۹۹۱	۰.۰۰۵
SVM	۰.۸۹۶	۰.۰۸۹
CNN	۰.۸۵۸	۰.۱۳۳
RNN	۰.۹۶۴	۰.۰۲۷

با توجه به جدول (۹) به طور خلاصه نتایج حاصل از الگوریتم‌های یادگیری عمیق نشان می‌دهد که صحت کلی الگوریتم‌های LSTM، SVM، CNN و RNN به ترتیب ۹۹.۱٪، ۸۹.۶٪، ۸۵.۸٪ و ۹۶.۴٪ می‌باشد که نشان دهنده این است که الگوریتم LSTM بهترین عملکرد و الگوریتم CNN بدترین عملکرد را در پیش بینی شرکت‌های دارای ریسک حساسی بالا دارد. به عبارت دیگر، نتایج نشان دهنده کارآ بودن الگوریتم حافظه طولانی کوتاه مدت (LSTM) نسبت به سایر الگوریتم‌های یادگیری عمیق می‌باشد. بنابراین در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران الگوریتم LSTM کاراترین مدل را برای پیش بینی ریسک حساسی فراهم می‌کند.

بحث و نتیجه‌گیری

یافته‌های پژوهش حاضر نشان می‌دهد که الگوریتم حافظه طولانی کوتاه‌مدت (LSTM) در پیش‌بینی ریسک حساسی، در مقایسه با سایر الگوریتم‌های یادگیری عمیق مانند ماشین بردار پشتیبان (SVM)، شبکه عصبی پیچشی (CNN) و شبکه عصبی بازگشتی (RNN)، عملکرد بهتری دارد. دقت کلی الگوریتم LSTM برابر با ۹۹.۱ درصد بوده است که نسبت به دقت‌های ۸۹.۶ درصد (SVM)، ۸۵.۸ درصد (CNN) و ۹۶.۴ درصد (RNN) از برتری قابل‌توجهی برخوردار است. همچنین میزان خطای شناسایی شرکت‌های با ریسک حساسی بالا در الگوریتم LSTM تنها ۰.۵ درصد گزارش شده است. این ارقام نشان‌دهنده توانایی بالای مدل LSTM در شناسایی دقیق ریسک‌های حساسی در محیط پیچیده و پرریسک بازار سرمایه ایران است؛ به‌ویژه در شرایطی که سیستم‌های سنتی حساسی قادر به پردازش داده‌های سری زمانی پیچیده و متغیرهای گسترده نیستند.

نتایج به‌دست‌آمده با یافته‌های پژوهش‌های پیشین همخوانی دارد. برای مثال، پژوهش او. ابومحسن و همکاران (۲۰۲۳) که از شبکه عصبی سه‌لایه برای پیش‌بینی ریسک حساسی استفاده کرده‌اند، به دقت ۱۰۰ درصدی دست یافته‌اند و نقش مؤثر یادگیری ماشین در بهبود فرایندهای حساسی را تایید کرده‌اند (O. Abu-Mehsen et al., 2023). همچنین، پژوهش الدین و همکاران (۲۰۲۳) نیز با بهره‌گیری از شبکه‌های عصبی، اثربخشی این مدل‌ها را در کشف الگوهای پیچیده و بهبود شفافیت مالی نشان داده‌اند (Al-Din et al., 2023). این یافته‌ها نشان می‌دهد که در عصری که سرعت تحول اطلاعات مالی و اقتصادی بالاست، اتکا به روش‌های سنتی برای تشخیص ریسک حساسی ناکافی خواهد بود و استفاده از مدل‌های پیشرفته‌ای مانند LSTM می‌تواند راهگشا باشد.

همچنین، تفاوت دقت میان الگوریتم‌ها می‌تواند به قابلیت آن‌ها در پردازش وابستگی‌های طولانی‌مدت در داده‌های سری زمانی مرتبط باشد. الگوریتم LSTM با مکانیزم گیت‌بندی، توانسته است اطلاعات مهم تاریخی را حفظ کرده و در تصمیم‌گیری‌های جاری از آن استفاده کند، در حالی که مدل‌هایی مانند CNN که بیشتر برای داده‌های تصویری طراحی شده‌اند، در مواجهه با داده‌های زمانی عملکرد ضعیف‌تری از خود نشان داده‌اند. از سوی دیگر، الگوریتم RNN نیز گرچه توانایی نسبی در پردازش داده‌های ترتیبی دارد، اما به دلیل بروز مشکل گرادیان ناپدیدشونده در داده‌های بلندمدت، در برابر LSTM ناکارآمدتر ظاهر شده است (Wu & Wilson, 2016).

علاوه بر الگوریتم‌ها، متغیرهای به‌کاررفته در مدل نیز نقشی کلیدی در دقت پیش‌بینی داشته‌اند. طبق یافته‌ها، متغیرهایی مانند اندازه شرکت، نقدینگی، سودآوری، نسبت بدهی، استقلال حساسی، تخصص کمیته حساسی و نرخ‌های کلان اقتصادی (نرخ تورم، نرخ ارز و بهره) از جمله مهم‌ترین عوامل پیش‌بینی‌کننده ریسک حساسی بوده‌اند. همسویی این یافته‌ها با پژوهش‌های گذشته همچون تحقیقات غلامی و دشتبانی (۲۰۲۱) در خصوص ارتباط بین کیفیت حساسی و ریسک حساسی، و پژوهش فریدی مایوان و همکاران (۲۰۲۲) درباره تأثیر افشای مسئولیت اجتماعی بر کاهش ریسک حساسی، نشان می‌دهد که ترکیب متغیرهای کیفی و کمی در مدل‌های یادگیری عمیق منجر به بهبود دقت پیش‌بینی می‌شود (Faridi Mayvan et al., 2022; Gholami & Dashtbani, 2021).

همچنین، بررسی آزمون t و آزمون کای دو در پژوهش حاضر حاکی از آن است که بسیاری از متغیرها میان شرکت‌های دارای ریسک بالا و پایین تفاوت معناداری دارند. برای مثال، شرکت‌هایی که حساب‌رسان با رتبه پایین‌تری داشته‌اند یا تغییر مکرر در مؤسسه حسابرسی را تجربه کرده‌اند، بیشتر در گروه ریسک بالا قرار گرفته‌اند. این یافته با دیدگاه‌های کوهن و همکاران (۲۰۱۴) و همچنین مطالعات مربوط به اهمیت تخصص صنعتی حسابرسان و تجربه حسابرسی هم‌راستا است (Cohen et al., 2014; Krishnan et al., 2013).

از نظر مفهومی، نتایج این پژوهش با نظریه‌های مربوط به کاهش عدم تقارن اطلاعاتی از طریق حسابرسی نیز هم‌راستا است. مطالعات نشان داده‌اند که حساب‌رسان، به‌ویژه آن‌هایی که دارای نام تجاری و تخصص در صنعت خاص هستند، نقش مهمی در ارتقای شفافیت مالی و اعتماد سرمایه‌گذاران ایفا می‌کنند (Kim et al., 2015; Robin & Wu, 2017). بنابراین، بکارگیری مدل‌های یادگیری عمیق به‌ویژه در محیط‌هایی مانند بازار سرمایه ایران، می‌تواند هم به تصمیم‌گیری بهتر سرمایه‌گذاران و هم به ارتقای کیفیت افشا و حسابرسی کمک کند.

از دیگر نکات برجسته پژوهش، استفاده از آزمون مقایسه میانگین دو نمونه برای انتخاب متغیرهای نهایی بوده است. این روش آماری، ضمن شناسایی متغیرهایی که تفاوت معنی‌داری میان دو گروه (ریسک بالا و پایین) دارند، به پالایش متغیرها و بهبود دقت مدل کمک شایانی کرده است. این شیوه انتخاب متغیرها، مطابق با توصیه‌های پژوهش‌هایی مانند پژوهش زارعیان و حجازی (۲۰۲۳) بوده که از روش‌های ساختاری برای طراحی مدل‌های ریسک حسابرسی بهره گرفته‌اند (Zaraeian & Hejazi, 2023). با این حال، یافته‌های پژوهش در خصوص الگوریتم CNN نیز قابل تأمل است. این الگوریتم با دقتی معادل ۸۵.۸ درصد ضعیف‌ترین عملکرد را در میان چهار الگوریتم مورد بررسی داشته است. دلیل این امر را می‌توان در ذات معماری CNN جست‌وجو کرد که اساساً برای داده‌های تصویری و فضایی طراحی شده و در پردازش داده‌های زمانی و سری‌های مالی، کارایی کمتری دارد. این نتیجه با مطالعات زهیر و همکاران (۲۰۲۳) که CNN را در تحلیل داده‌های مالی ضعیف‌تر از RNN و LSTM ارزیابی کرده‌اند، مطابقت دارد (Robin & Zhang, 2015).

در نهایت، نتایج این پژوهش می‌تواند در چهار سطح مورد استفاده قرار گیرد: الف) به‌کارگیری در فرایندهای برنامه‌ریزی و اجرای حسابرسی توسط حساب‌رسان مستقل، ب) استفاده از نتایج توسط سازمان بورس و نهادهای نظارتی برای طراحی سازوکارهای هشدار ریسک، ج) استفاده توسط سرمایه‌گذاران و تحلیل‌گران برای تصمیم‌گیری بهتر و د) توسعه ابزارهای هوشمند در نظام حسابداری و حسابرسی با تکیه بر الگوریتم‌های یادگیری عمیق.

یکی از محدودیت‌های اصلی پژوهش حاضر، تمرکز صرف بر داده‌های شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران بوده است که ممکن است قابلیت تعمیم نتایج به سایر بازارها یا شرکت‌های غیر بورسی را کاهش دهد. همچنین، استفاده از داده‌های تاریخی با محدودیت‌هایی مانند تغییرات ساختاری، مقررات جدید، یا رخداد‌های خاص اقتصادی روبرو بوده که ممکن است بر پایداری مدل تأثیر بگذارد. علاوه بر آن، انتخاب متغیرها براساس آزمون t در عین دقت آماری، ممکن است برخی متغیرهای غیرقابل مشاهده یا کیفی را که بر ریسک حسابرسی تأثیر دارند نادیده گرفته باشد.

برای تحقیقات آینده پیشنهاد می‌شود که از الگوریتم‌های ترکیبی یا بهینه‌سازی‌شده (مانند LSTM با یادگیری تقویتی یا الگوریتم‌های ژنتیک) استفاده شود تا دقت پیش‌بینی افزایش یابد. همچنین، بررسی تأثیر تعاملات بین متغیرهای محیطی (مانند نرخ تورم یا نرخ بهره) و متغیرهای ساختاری شرکت‌ها می‌تواند به توسعه مدل‌های دقیق‌تر کمک کند. انجام مطالعات تطبیقی در سایر بازارهای سرمایه منطقه‌ای یا بین‌المللی نیز می‌تواند اعتبار خارجی مدل‌های پیش‌بینی ریسک را افزایش دهد.

نهادهای ناظر مالی و حسابرسی می‌توانند از مدل طراحی‌شده در این پژوهش برای توسعه سیستم‌های هشدار سریع ریسک استفاده کنند. سازمان بورس می‌تواند با همکاری حساب‌رسان رسمی، الگوریتم‌های یادگیری عمیق را به‌عنوان ابزارهای کمکی در تحلیل کیفیت گزارش‌های مالی مورد استفاده قرار دهد. حساب‌رسان نیز می‌تواند با تلفیق دانش فنی و الگوریتم‌های هوشمند، دقت تشخیص خود را افزایش دهند. در نهایت، شرکت‌ها با تحلیل ساختارهای داخلی خود در تطابق با عوامل ریسک‌زا، می‌توانند به ارتقاء کیفیت حاکمیت شرکتی و کاهش احتمال بروز ریسک حسابرسی دست یابند.

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

حمایت مالی

این پژوهش حامی مالی نداشته است.

موازین اخلاقی

در انجام این پژوهش تمامی موازین و اصول اخلاقی رعایت گردیده است.

References

- Al-Din, S., Al-Hayik, Y., & Abu-Naser, S. S. (2023). Neural Network-Based Audit Risk Prediction: A Comprehensive Study. *International Journal of Academic Engineering Research (IJAER)*, 7(10), 43-51.
- Bagheri, M., & Lotfallian, M. (2024). Examining the Impact of Financial and Operational Risks on Audit Quality in Companies Listed on the Tehran Stock Exchange. 7th International Conference on Innovative Ideas in Management, Economics, Accounting, and Banking, <https://civilica.com/doc/2023922/>
- Cohen, J., Krishnamoorthy, G., & Wright, A. (2010). Corporate governance in the post-Sarbanes- Oxley era: Auditors' experiences. *Contemporary Accounting Research*VL - 27(3), 751-786. <https://doi.org/10.1111/j.1911-3846.2010.01026.x>
- Cohen, J. R., Hoitash, U., Krishnamoorthy, G., & Wright, A. M. (2014). The effect of audit committee industry expertise on monitoring the financial reporting process. *The Accounting Review*, 89(1), 243-273. <https://doi.org/10.2308/accr-50585>
- Darabi, R., Alizadeh Pirali, F., & Dabestani, M. (2020). A Review of Theoretical and Empirical Literature on the Impact of Macroeconomic Conditions on Audit Risk. *Accounting and Management Perspectives*, 3(37), 12-18.
- DeFond, M., & Zhang, J. (2014). A review of archival auditing research. *Journal of Accounting and Economics*, 58(2), 275-326. <https://doi.org/10.1016/j.jacceco.2014.09.002>
- Deng, M., Lu, T., & Wen, X. (2023). Does Audit Risk Disclosure Improve or Impair Audit Quality and Investment Efficiency? <https://doi.org/10.2139/ssrn.4540951>
- Engel, E., Hayes, R. M., & Wang, X. (2010). Audit committee compensation and the demand for monitoring of the financial reporting process. *Journal of Accounting and Economics*, 49(1-2), 136-154. <https://doi.org/10.1016/j.jacceco.2009.08.001>
- Faridi Mayvan, M., Momeni, A., & Moghadam, A. (2022). Testing Audit Risk Assessment Under the Influence of Corporate Social Responsibility Disclosure. *Accounting and Management Auditing Knowledge*, 11(43), 309-321.
- Gholami, H., & Dashtbani, G. (2021). Examining the Relationship Between Audit Quality and Audit Risk in Companies Listed on the Tehran Stock Exchange. *Accounting and Management Perspectives*VL - 4(49), 122-135.
- Hammersley, J. S., Johnstone, K., & Kadous, K. (2011). How do audit seniors respond to heightened fraud risk? *Auditing: A Journal of Practice & Theory*, 30IS - 3, 81-101. <https://doi.org/10.2308/ajpt-10110>
- Hamti, D., Arab-Salehi, M., & Tolouei Ashlaghi, A. (2020). Audit Risk Assessment Using a Data Mining Approach (Case Study: Bank Loans). *Accounting and Management Auditing Knowledge*, 9(34), 157-167.
- Hamti, D., & Tolouei Ashlaghi, A. (2022). Audit Risk Assessment Using a Data Mining Approach Based on Neural Networks in Companies Listed on the Tehran Stock Exchange. *Auditing Knowledge*, 5(89), 216-245.
- Heydinejad, G., Jamshidi Navid, B., & Ghanbari, M. (2021). The Relationship Between Audit Committee Effectiveness and Audit Risk. *Accounting and Auditing Research*, 13(52), 185-206.
- International, A., & Assurance Standards, B. (2011). Audit quality. An IAASB perspective. <http://www.ifac.org/sites/default/files/publications/files/audit-quality-an-iaasb-per.pdf>

- International Organization of Securities, C. (2009). Consultation report on transparency of firms that audit public companies. <http://www.iosco.org/library/pubdocs/pdf/IOSCOPD302.pdf>
- Kim, J. B., Lee, J. J., & Park, J. C. (2015). Audit quality and the market value of cash holdings: The case of office-level auditor industry specialization. *Auditing: A Journal of Practice & Theory*, 34(2), 27-57. <https://doi.org/10.2308/ajpt-50903>
- Krishnan, G. V., & Visvanathan, G. (2009). Do auditors price audit committee's expertise? The case of accounting versus nonaccounting financial experts. *Journal of Accounting, Auditing & Finance*, 24(1), 115-144. <https://doi.org/10.1177/0148558X0902400107>
- Krishnan, J., Li, C., & Wang, Q. (2013). Auditor industry expertise and cost of equity. *Accounting Horizons*, 27(4), 667-691 DOI - 610.2308/acch-50513.
- Kurt, A. C. (2022). Audit Risk and the Benefits of Employing Specialist Auditors: Evidence from Firms with Major Government Customers. <https://doi.org/10.2139/ssrn.4199751>
- Nurmawanti, S., Lenggogeni, L., & Yanti, H. B. (2024). The Effect of Competence, Time Budget Pressure and Professional Attitudes of Auditors on Internal Audit Quality With Role Conflict As a Moderating Variable. *Dinasti International Journal of Economics, Finance & Accounting (DIJEFA)*, 4(6).
- O. Abu-Mehsen, D., Abu Nasser, M. S., Hasaballah, M. A., & Abu-Naser, S. S. (2023). Predicting Audit Risk Using Neural Networks: An In-depth Analysis. *International Journal of Academic Information Systems Research (IJAIRS)*, 7(10), 48-56.
- Porcuna-Enguix, L., Bustos-Contell, E., Serrano-Madrid, J., Labatut-Serer, G., & Public Company Accounting Oversight, B. (2021). Constructing the Audit Risk Assessment by the Audit Team Leader When Planning: Using Fuzzy Theory The process for Board determinations regarding firms' efforts to address quality control criticisms in inspection reports. *Mathematics*, 9(23), 3065. <https://doi.org/10.3390/math9233065>
- Public Company Accounting Oversight, B. (2010). Consideration of registration applications from public accounting firms in Non-U.S. jurisdictions where there are unresolved obstacles to PCAOB inspections.
- Robin, A., & Wu, Q. A. U. Z. H. (2017). Auditor quality and debt covenants. *Contemporary Accounting Research*, 34(1), 154-185. <https://doi.org/10.1111/1911-3846.12243>
- Robin, A. J., & Zhang, H. (2015). Do industry-specialist auditors influence stock price crash risk? *Auditing: A Journal of Practice & Theory*, 34(3), 47-79. <https://doi.org/10.2308/ajpt-50950>
- Sujana, E., & Dharmawan, N. A. S. (2023). Audit Quality Improvement and the Role of Risk: Audit as a Moderator. *AABFJ*, 17(4), 223-238. <https://doi.org/10.14453/aabfj.v17i4.14>
- Wu, Y., & Wilson, M. P. (2016). Audit quality and analyst forecast accuracy: The impact of forecast horizon and other modeling choices. *Auditing: A Journal of Practice & Theory*, 35(2), 167-185. <https://doi.org/10.2308/ajpt-51216>
- Yarifard, R., & Hashemi, N. (2024). The Impact of Corporate Social Responsibility Reporting on Firm Value Considering the Role of Audit Quality, Corporate Governance, and Earnings Management in Companies Listed on the Tehran Stock Exchange. *Accounting and Management Outlook*, 7IS - 94, 1-27.
- Zaraeian, H., & Hejazi, M. (2023). Presenting a Tax Audit Risk Model in the Comprehensive Tax Plan Using a Combined ISM-ANP Approach. *Empirical Accounting Research*, 13(1), 61-80.