

Detecting Fraudulent Financial Statements Using Deep Learning Algorithms

Javad Sharafkhani¹, Ali Ismailzadeh Moqri², Mohammad Ali Bidari³

¹ PhD., Student, Department of Accounting, Central Tehran Branch, Islamic Azad University, Tehran, Iran.
Drjavadsharafkhani@gmail.com

² Professor, Department of Accounting, Central Tehran Branch, Islamic Azad University, Tehran, Iran
(Corresponding author), afies35091@gmail.com

³ Assistant Professor, Department of Accounting, Central Tehran Branch, Islamic Azad University, Tehran, Iran.
bidari@ut.ac.ir

Abstract

Objective: The purpose of this study is to detect fraudulent financial statements in companies listed on the Tehran Stock Exchange using deep learning algorithms.

Method: The study analyzed 1,800 company-years (150 companies over 12 years) of annual financial reports from companies listed on the Tehran Stock Exchange, covering the period from 2012 to 2023. Three deep learning algorithms were employed in this research: support vector machine (SVM), convolutional neural network (CNN), and recurrent neural network (RNN). Additionally, the "two-sample mean comparison test" method was employed to select the final variables for the study and to develop the model.

Findings: The findings indicate that the overall accuracy of the deep learning algorithms is as follows: Support Vector Machine (SVM) at 88.4%, Convolutional Neural Network (CNN) at 81.3%, and Recurrent Neural Network (RNN) at 94.4%. This suggests that the RNN algorithm demonstrates the best performance, while the CNN algorithm exhibits the lowest performance in detecting companies with fraudulent financial statements. In other words, the results indicate that the recurrent neural network (RNN) algorithm is more efficient than other deep learning algorithms. Therefore, among the three algorithms—Support Vector Machine (SVM), Convolutional Neural Network (CNN), and Recurrent Neural Network (RNN)—used in companies listed on the Tehran Stock Exchange, the RNN algorithm offers the most effective model for detecting fraudulent financial statements.

Conclusion: The findings of this study offer valuable insights for shareholders, creditors, analysts, and other participants in the capital markets. These insights can enhance the prediction of fraudulent financial statements, minimize errors in decision-making based on financial information, improve the evaluation of company performance, facilitate the adoption of optimal trading strategies, and help identify suitable opportunities for buying and selling stocks based on financial statement data.

Keywords: Fraudulent Financial Statements, Fraud Detection, Deep Learning, Recurrent Neural Network Algorithms.



کشف صورت‌های مالی متقلبانه براساس الگوریتم‌های یادگیری عمیق

جواد شرف خانی^۱، علی اسماعیل زاده مقری^۲، محمدعلی بیداری^۳

^۱ دانشجوی دکتری، گروه حسابداری، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. Drjavadsharafkhani@gmail.com

^۲ استاد، گروه حسابداری، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مستوفی)، alies35091@gmail.com

^۳ استادیار، گروه حسابداری، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. bidari@ut.ac.ir

چکیده

هدف: هدف پژوهش حاضر کشف صورت‌های مالی متقلبانه براساس الگوریتم‌های یادگیری عمیق در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌باشد.

روشن: ۱۵۰ سال شرکت (۱۵۰ شرکت برای ۱۲ سال) از گزارش‌های مالی سالیانه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در طی دوره زمانی ۱۳۹۱ تا ۱۴۰۲ مورد آزمون قرار گرفتند. در پژوهش حاضر از سه الگوریتم یادگیری عمیق (شامل الگوریتم‌های ماشین بردار پشتیبان (SVM)، شبکه عصبی پیچشی (CNN) و شبکه عصبی بازگشتی (RNN)) استفاده شد. همچنین جهت انتخاب متغیرهای نهایی پژوهش از روش «آزمون مقایسه میانگین دو نمونه» جهت ایجاد مدل استفاده شده است.

یافته‌ها: نتایج حاصل از الگوریتم‌های یادگیری عمیق نشان می‌دهد که صحبت کلی الگوریتم‌های SVM و CNN به ترتیب ۸۸.۴٪ و ۹۴.۴٪ می‌باشد که نشان‌دهنده این است که الگوریتم RNN بهترین عملکرد و الگوریتم CNN بدترین عملکرد را در کشف شرکت‌های دارای صورت‌های مالی متقلبانه دارد. به عبارت دیگر، نتایج نشان‌دهنده کارآ بودن الگوریتم شبکه عصبی بازگشتی (RNN) نسبت به سایر الگوریتم‌های یادگیری عمیق است. بنابراین، در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران از بین سه الگوریتم SVM، CNN و RNN، الگوریتم RNN کارترین مدل را برای کشف صورت‌های مالی متقلبانه فراهم می‌کند.

نتیجه‌گیری: یافته‌های پژوهش حاضر می‌تواند برای سهامداران، اعتباردهندگان، تحلیلگران و سایر مشارکت‌کنندگان در بازار سرمایه، اطلاعات سودمندی را در بهبود پیش‌بینی صورت‌های مالی متقلبانه و کاهش خطا در اتخاذ تصمیمات مبنی بر اطلاعات صورت‌های مالی، ارزیابی بهتر عملکرد شرکت بر مبنای اطلاعات، اتخاذ استراتژی‌های معاملاتی بهینه و شناسایی فرصت‌های مناسب خرید و فروش سهام بر مبنای اطلاعات صورت‌های مالی فراهم کند.

کلیدواژه‌ها: صورت‌های مالی متقلبانه، کشف نقل، یادگیری عمیق، الگوریتم شبکه عصبی بازگشتی.



۱. مقدمه

تقلب در گزارشگری مالی در سال‌های اخیر رشد قابل توجهی داشته است، در این راستا، صورت‌های مالی هرچه بیشتر مورد تحریف قرار گرفته‌اند. در مواقعي که صورت‌های مالی حاوی تحریفی با اهمیت باشد، به گونه‌ای که عناصر تشکیل‌دهنده آن صورت مالی بیانگر واقعیت نباشد، گفته می‌شود که تقلب صورت گرفته است (اسپاتیس^۱، ۲۰۰۲). لذا، توجه به اهمیت کشف تقلب در صورت‌های مالی در جهت حمایت از منافع سرمایه‌گذاران، امری بسیار مهم است. متأسفانه تقلب از هر نوع آن و با هر قصدی، تأثیر نامطلوبی بر شرکت خواهد داشت. از این‌رو شناخت و پیشگیری از آن امری ضروری برای شرکت‌ها است. اعمال متقلبانه به زیان‌های مالی بزرگی برای اقتصادها و واحدهای تجاری در سطح جهان منجر شده است. بنابراین، در زمان کنونی، کشف و مبارزه با تقلب، جهت جبران زیان‌های واردہ بسیار با اهمیت است. صورت‌های مالی متقلبانه به عنوان حذفیات عمدی یا ارائه نادرست در صورت‌های مالی که به دلیل عدم گزارش عمدی داده‌های مالی مطابق با استانداردهای حسابداری پذیرفته شده است، مشخص می‌شود. صورت‌های مالی متقلبانه می‌تواند تأثیرات قابل توجهی بر ذینفعان شرکت‌های متقلب و شرکت‌های غیرمتقلب در صورت عدم شناسایی و پیشگیری به موقع ایجاد کند (ال-بانانی و همکاران^۲، ۲۰۲۰). متأسفانه تشخیص صورت‌های مالی متقلبانه آسان نیست. علاوه‌بر این، حتی در صورت کشف، آسیب قابل توجهی به طور کلی قبل از خبره تقلب^۳ بیان می‌کند که تقلب در صورت‌های مالی عبارت است از ارائه نادرست عمدی وضعیت مالی یک شرکت از طریق تحریف یا حذف عمدی مبالغ یا افشاء در صورت‌های مالی برای گمراه کردن استفاده‌کنندگان از صورت‌های مالی. براساس گزارش مرکز کیفیت حسابرسی^۴، افراد یا شرکت‌ها به دلایل مختلفی از جمله مزایای پولی، نیاز به تحقق اهداف مالی کوتاه‌مدت یا سرپوش گذاشتن بر اخبار بد، به دنبال دستکاری صورت‌های مالی هستند. استفاده‌کنندگان خارجی و داخلی صورت‌های مالی، دائمًاً صورت‌های مالی را زیر سؤال می‌برند و نهادهای نظارتی نمی‌توانند با اطمینان بگویند که صورت‌های مالی معتبر هستند و مطابق با دستورات

-
- 1. Spathis
 - 2. El-Bannany
 - 3. The Association of Certified Fraud Examiners (ACFE)
 - 4. The Center for Audit Quality (CAQ)

قانونی و اخلاقی رویه‌های حسابداران و حسابرسان تهیه شده‌اند (کولیکووا و ساتداروا^۱، ۲۰۱۶؛ دیباک و همکاران^۲، ۲۰۲۲). در نتیجه، کشف تقلب یا فریب به منظور اطمینان از صحّت صورت‌های مالی مهم است. در این زمینه، مطالعه حاضر از اهمیت عملی برای مشاغل و حسابرسان برخوردار است؛ زیرا بازار جهانی شاهد افزایش تقلب در حسابداری مالی است که میلیاردها دلار در سال برای کسب‌وکارها هزینه دارد. آشنازگی مالی تأثیر قابل توجهی بر کسب‌وکارها و اعتباردهندگان یک کشور و در نتیجه بر اقتصاد آن دارد (ال-بانانی و همکاران، ۲۰۲۰؛ اسریدهاران و همکاران^۳، ۲۰۲۰؛ کومار و تریپاتی^۴، ۲۰۲۰). در نتیجه، کشف و پیش‌بینی تقلب حسابداری مالی به موضوعی نوظهور برای مطالعات دانشگاهی و متخصصان صنعت تبدیل می‌شود.

در محیط تجاری مدرن امروزی با پیچیده‌تر شدن سیستم‌ها و فعالیت‌ها و افزایش اطلاعات فریبکارانه، فناوری‌های مورد استفاده برای جلوگیری و کشف تقلب نیز به روز شده است، بنابراین، توسعه و رشد روش‌های مربوط به داده‌های متنوع از جمله داده‌کاوی، برای تشخیص تقلب‌های مالی در اولویت قرار دارد. در ایران به موضوع کشف تقلب صورت‌های مالی توجه زیادی نشده است. مسئله گزارشگری مالی متنقلانه در ایران از اهمیتی ویژه برخوردار است. افزایش تعداد شرکت‌های پذیرفته شده در بورس که به منظور جذب منابع مالی به انتشار اوراق بهادار اقدام می‌کنند، تلاش به منظور کاهش مالیات بر درآمد و... از جمله دلایل اهمیت این موضوع است. بنابراین، در حوزه کشف تقلب، هرچقدر حسابرسان و ذینفعان شرکت به تکنیک‌ها و رویکردهای کارآمدتری از جمله الگوریتم‌های یادگیری عمیق و رویکردهای کارآمدی چون تکنیک یادگیری عمیق شبکه عصبی بازگشتی دسترسی داشته باشند، قاعده‌تاً، توانایی و کارایی آنها در حوزه تائیدپذیری اطلاعات صورت‌های مالی را می‌تواند بهبود بخشد.

کشف تقلب در صورت‌های مالی به چند دلیل دشوار است؛ نخست، اعضای گروه مدیریت که عمدتاً مرتكبین اصلی تقلب هستند، به طور معمول تلاش زیادی برای پنهان کردن تقلب در صورت‌های مالی می‌کنند؛ دوم، اعضای گروه مدیریت از اعتماد قابل توجهی برخوردار هستند، به راحتی کنترل‌های داخلی کلیدی را نقض کرده و در نتیجه تقلب در صورت‌های مالی آسان‌تر و کشف آن سخت‌تر می‌شود؛ سوم، مرتكبین تقلب در صورت‌های مالی، اغلب از تبانی و سندسازی برای

1. Kulikova and Satdarova

2. Deebak

3. Sreedharan

4. Kumar

ارتكاب و پنهان کردن تقلب استفاده می‌کنند و بیشتر رویه‌های حسابرسی مستقل برای کشف چنین طرح‌هایی از تقلب طراحی نشده‌اند؛ چهارم، داده‌های صورت‌های مالی تا حد زیادی خلاصه و تجمعی شده‌اند که پنهان کردن تقلب را ساده‌تر و کشف آن را با استفاده از روش‌های مدل‌سازی آماری و تحلیلی سخت‌تر می‌کند (وایتنگ و همکاران^۱، ۲۰۱۲). دو جریان متفاوت در متون پژوهشی، پیشینه و مبنای برای این پژوهش فراهم می‌کند؛ یکی پژوهش‌های انجام شده در رابطه با گزارشگری مالی متقلبانه؛ و دیگری متون مربوط به الگوریتم‌های یادگیری عمیق است. این دو جریان قلمروهای پژوهشی گسترده‌ای هستند که پژوهش‌های متقابل بسیار اندرکی در ایران، در این زمینه انجام شده است. پژوهش‌های صورت گرفته نیز با توجه به محدودیت در زمینه دسترسی به داده‌های تقلب، با یکدیگر متفاوت هستند؛ از این‌رو، پژوهش حاضر در تلاش است تا با استفاده از تکنیک یادگیری عمیق (ماشین بردار پشتیبان، شبکه عصبی پیچشی و شبکه عصبی بازگشتش) و با بکارگیری جامع ترین متغیرهای اثربار بر تقلب در صورت‌های مالی (با بررسی جامع پژوهش داخلی و خارجی انجام شده در حوزه تقلب)، مدلی برای کشف صورت‌های مالی متقلبانه با دقت و صحّت بالا ارائه دهد، که این موضوع در نوع خود منحصر به‌فرد می‌باشد.

۲. مبانی نظری و پیشینه پژوهش

۱-۱. مبانی نظری پژوهش

در سطح جهانی، هزینه صورت‌های مالی متقلبانه، طی سال‌ها به افزایش خود ادامه داده است. مستقیم‌ترین قربانیان، سرمایه‌گذاران و سرمایه‌دارانی هستند که به بهانه‌های واهمی به شرکت‌ها وجود می‌دهند. هزینه‌های بیشتری برای جامعه در سطح کلان وجود دارد، مانند از دست دادن اعتماد به سیستم‌های مالی، حتی اگر تأثیر اقتصادی در سطح شرکت می‌تواند بسیار متغیر باشد. صورت‌های مالی متقلبانه آسیب مالی قابل توجهی به سرمایه‌گذاران، سهامداران و جامعه وارد می‌کند. اکثر تحقیقات موجود در ادبیات صورت‌های مالی متقلبانه از تحلیل رگرسیون سنتی (اندرو و رایین^۲، ۲۰۲۲؛ پاولو سرگئو گومس ماسدا و ویئرا^۳، ۲۰۲۲؛ وادوا و کومار^۴، ۲۰۲۰؛ آمر و جربوئی^۵، ۲۰۱۳؛ آلسینقلاؤی و آلماری^۶، ۲۰۲۱) استفاده کرده‌اند. یادگیری ماشین که زیرمجموعه هوش مصنوعی است، به علت

-
1. Whiting
 2. Andrew & Robin
 3. Paulo Sérgio Gomes Macedo & Vieira
 4. Wadhwa & Kumar
 5. Ama and Jarboui
 6. Alsinglaw & Almari

خاصیت اکتشافی خود، بدون هیچ فرض اولیه‌ای شروع به الگوسازی رفتار داده‌ها کرده و به مرور زمان و با جلو رفتن الگوریتم، الگو پرنگتر خواهد شد؛ ساختار غیرخطی و مقاوم این روش، توانایی شبیه‌سازی رفتار محیط واقعی را فراهم کرده است. در یادگیری ماشینی از طریق به‌کارگیری یک‌سری الگوریتم‌های خاص، سعی می‌شود الگوهای پنهان بین داده‌ها کشف شود؛ در صورتی که تعداد متغیرهای مستقل ووابسته زیاد باشد و بین آنها ارتباط خطی برقرار نباشد، این روش از جمله بهترین گزینه‌ها برای پیش‌بینی است. یادگیری عمیق، زیرشاخه‌ای از یادگیری ماشینی و از حوزه‌های نوین این بخش است. یادگیری عمیق معرف سلسله‌ای از الگوریتم‌هاست که در آن از چندین لایه پردازش اطلاعات به ویژه اطلاعات غیرخطی استفاده می‌شود، تا بهترین ویژگی‌های مناسب، از ورودی خام استخراج شود. از میان تکنیک‌های مختلف یادگیری عمیق که در علوم مختلف کاربردهای فراوانی دارد، پژوهشگران حوزه مالی برای پیش‌بینی تقلب، اغلب از الگوریتم‌های به‌خصوصی نظری شبکه عصبی بازگشتی^۱ و شبکه عصبی پیچشی استفاده کرده‌اند (الغفیلی و همکاران،^۲ ۲۰۲۰).

شبکه‌های عصبی مصنوعی به دلیل ماهیت همه‌کاره آن، به طور گسترده برای حل بسیاری از مشکلات استفاده شده است. یک رویکرد ترکیبی، یعنی ترکیبی از متغیرهای تحلیل بنیادی و تکنیکی شاخص‌های بازار سهام، برای پیش‌بینی قیمت سهام با هوش مصنوعی در آینده جهت بهبود روش‌های موجود ارائه شده و حرکت شاخص قیمت سهام با استفاده از دو مدل مبتنی بر شبکه عصبی مصنوعی و ماشین بردار پشتیبان مورد بحث قرار گرفته است. پس از مقایسه عملکرد هر دو مدل، نتیجه این شد که میانگین عملکرد مدل ANN به طور قابل توجهی بهتر از مدل SVM است و اینکه شبکه عصبی مصنوعی تناسب بهتری با داده‌ها نسبت به روش‌های مرسوم فراهم می‌کند. این شبکه‌های عصبی به گونه‌ای توسعه یافته‌اند که می‌توانند الگوهایی را از داده‌های نویزدار استخراج کنند. ANN ابتدا یک سیستم را با استفاده از نمونه بزرگ از داده‌ها به نام فاز آموزشی، آموزش می‌دهد، سپس شبکه را با داده‌هایی آشنا می‌کند که در مرحله آموزش گنجانده نشده است، این مرحله به عنوان مرحله اعتبارسنجی یا پیش‌بینی شناخته می‌شود. تنها انگیزه این روش، پیش‌بینی نتایج جدید است. این ایده یادگیری از آموزش و سپس پیش‌بینی نتایج در ANN از مغز انسان می‌آید که می‌تواند یاد بگیرد و پاسخ دهد. بنابراین، ANN در بسیاری از حوزه‌ها مورد استفاده قرار گرفته و در اجرای توابع پیچیده در زمینه‌های مختلف، عملکرد موفقیت‌آمیزی داشته است (جی و همکاران،^۳ ۲۰۲۰).

1. RNN

2. Alghofaili

3. Jay

در حالت کلی، به دلیل پیچیدگی مسئله تقلب و حجم بالای اطلاعات مورد پردازش، اغلب استفاده از یک سیستم ساده برای پیش‌بینی نتایج خوبی به همراه ندارد. به همین دلیل محققان با ارائه مدلی ترکیبی، سعی در ارائه سیستمی با پیچیدگی کمتر و کارایی و دقت بیشتر کرده‌اند. امروزه از الگوهای مختلفی مانند: تکنیک‌های آماری (تحلیل تشخیصی، لوجیت و آنالیز فاکتوری^۱) و تکنیک‌های هوش مصنوعی (شبکه‌های عصبی، درخت تصمیم‌گیری، استدلال مبتنی بر موضوع، الگوریتم ژنتیک، مجموعه‌های سخت، ماشین بردار پشتیبان و منطق فازی) و یا ترکیبی از این دو تکنیک، برای پیش‌بینی تقلب استفاده می‌شود. در اکثر مدل‌های پیش‌بینی‌کننده، سیستم فقط با استفاده از اطلاعات یک شاخص به پیش‌بینی می‌پردازد. در سال‌های اخیر، تعدادی از کارشناسان و محققین سعی کرده‌اند از روش‌های یادگیری ماشین و داده‌کاوی برای انجام تحقیقات در این زمینه به عنوان راهی برای کاهش خطاهای تشخیص استفاده کنند. در حالی که بسیاری از استراتژی‌های تجاری، مبتنی بر دقت صورت‌های مالی هستند، و منابع کافی برای تجزیه و تحلیل همه آنها به طور کامل وجود ندارد. از آنجایی که حسابرسان در چندین نمونه از صورت‌های مالی متقابلانه مقصص شناخته شده‌اند، مدل‌های کشف تقلب مالی معتبر باید به روشی آسان برای حسابرسان، سرمایه‌گذاران، سیاست‌گذاران و سایر ذینفعان ارائه شوند. به دلیل اتکای ذاتی به مفروضات توزیعی محدود، تکنیک‌های پارامتریک مانند رگرسیون لجستیک^۲ قادر کاربرد کلی است که ممکن است رویکردهای غیرپارامتری ارائه کنند (اسچریبر-گریگوری و بادر^۳). از سوی دیگر، تحقیقات موجود در مورد روش‌های کمی کشف تقلب مالی، عمدهاً بر صنعت بانکداری و خدمات مالی متتمرکز شده است، که مبتنی بر روی کشف تقلب ییمه و کارت اعتباری است. الگوریتم‌های کمی برای کشف و پیش‌بینی صورت‌های مالی متقابلانه، باید در پژوهش‌های دانشگاهی مورد توجه قرار گیرد. ادبیات علمی و آکادمیک فعلی در حال حاضر به دنبال قوانین یا طبقه‌بندی‌های بیشتر از داده‌های قبلی، برای دستیابی به هدف پیش‌بینی یا تشخیص است. یادگیری ماشینی با مقدار مناسب داده می‌تواند نتایج دقیق‌تری را در مقایسه با رویکرد سنتی، پیش‌بینی و طبقه‌بندی کند.

کشف تقلب در صورت‌های مالی در چند دهه گذشته با تاکید بر ناهنجاری‌های حسابداری به طور کلی و به طور خاص بر تقلب در صورت‌های مالی، مورد توجه قرار گرفته است. در حالی که تحقیقات اولیه از تکنیک‌های آماری یا سنتی استفاده می‌کرد که هم زمان‌بر و هم پرهزینه هستند.

1. Diagnostic analysis, logit and factor analysis

2. LR

3. Schreiber-Gregory and Bader

اخيراً با ظهور کلان داده و یادگيري ماشين، تمرکز بر کشف تقلب با الگوريتم های یادگيري عميق بيشتر شده است (محمدی و همکاران^۱، ۲۰۲۰). رویکردهای آماری بر روش های رياضي سنتی متتمرکز می باشند، اما روش های مربوط به یادگيري ماشين بر یادگيري و هوش متتمرکز هستند. در حالی که هر دو دسته شباهت های زيادي دارند، تفاوت اصلی آنها اين است که روش های آماری سخت تر و غير منعطف هستند، در حالی که روش های یادگيري ماشين قادر به یادگيري و انعطاف پذير می باشند (هامفريس و همکاران^۲، ۲۰۱۱).

مطالعات قبلی کارايی برتر رویکردهای یادگيري عميق را نسبت به رویکردهای آماری مرسوم نشان داده اند (وست و همکاران^۳، ۲۰۱۴). با توجه به ادبیات موجود، هیچ استراتژی واحدی برای شناسایي تقلب در صورت های مالی وجود ندارد (همال و سنوار^۴، ۲۰۲۱). یافته های پيشين (کراجا و همکاران^۵، ۲۰۲۰) نشان می دهد که مدل هایی که با استفاده از رویکردهای یادگيري ماشين ساخته شده اند، می توانند به طور مؤثر تقلب در صورت های مالی را شناسایي کنند، با تکامل مستمر رفتار متقلبانه گزارشگری مالی همگام باشند و با به روز ترين فناوري پاسخ دهند. در پژوهشی گوپتا و مهتا^۶ (۲۰۲۱)، نشان دادند که مدل های تشخيص توسعه يافته با استفاده از رویکردهای یادگيري ماشين، دقيق تر از روش های سنتی هستند. بسياري از تحقیقات تشخيص صورت های مالی متقلبانه را به عنوان يك مسئله طبقه بندی باينري، گاهی به عنوان يك مسئله چند کلاسه و گاهی اوقات به عنوان يك مشكل خوش بندی، فرموله کرده اند. محققان هر دو تجزие و تحليل کمی و كيفی صورت های مالی متقلبانه را انجام داده اند. متن کاوي به طور گسترده برای تحقیقات كيفی استفاده شده است. در پژوهش حاضر روی مقالاتی تمرکز شده که تجزيء و تحليل کمی را با استفاده از الگوريتم های یادگيري ماشين انجام می دهند. در مراحل اوليه، تحقیقات عمدتاً شامل رویکردهای شبکه عصبی^۷ (سچيني و همکاران^۸، ۲۰۱۰؛ پاي و همکاران^۹، ۲۰۱۱؛ الفيض و فاتي^{۱۰}، ۲۰۲۲؛ استرلسنيا و پراكونويت^{۱۱}، ۲۰۲۳؛ کومار

1. Mohammadi
2. Humpherys
3. West
4. Hamaland Senvar
5. Craja
6. Gupta & Mehta
7. NN
8. Cecchini
9. Pai
10. Alfaiz & Fati
11. Strelcenia & Prakoonwit

و همکاران^۱، ۲۰۲۲)، رگرسیون لجستیک^۲، درخت تصمیم^۳، ماشین بردار پیشتیبان^۴، تحلیل متمايز^۵ و شبکه باور بیزی^۶ بود. مطالعاتی که در حوزه یادگیری ماشین در ایالات متحده آمریکا، چین، تایوان و اسپانیا انجام شده است، نشان می‌دهد که ۶۵ درصد از این مطالعات از تکنیک‌های یادگیری نظارت شده برای تجزیه و تحلیل داده‌ها استفاده کرده‌اند (البашراوی^۷، ۲۰۱۶). تعداد قابل توجهی از مطالعات، عملکرد طبقه‌بندی‌کننده‌ها را در تشخیص صورت‌های مالی متقلبانه تجزیه و تحلیل کرده و نشان می‌دهند که ماشین بردار پیشتیبان (سچینی و همکاران، ۲۰۱۰؛ پای و همکاران، ۲۰۱۱؛ پرولس^۸، ۲۰۱۱؛ آسیمیت و همکاران^۹، ۲۰۲۲؛ موئیپا و همکاران^{۱۰}، ۲۰۱۴؛ یائو و همکاران^{۱۱}، ۲۰۱۹)، شبکه عصبی (هان^{۱۲}، ۲۰۱۷؛ لین و همکاران^{۱۳}، ۲۰۱۵؛ راویسانکار و همکاران^{۱۴}، ۲۰۱۱؛ ریزکی و همکاران^{۱۵}، ۲۰۱۷؛ مورورونخر و همکاران^{۱۶}، ۲۰۲۲؛ پیرز لوپز و همکاران^{۱۷}، ۲۰۱۹) و درخت تصمیم (گوپتا و گیل^{۱۸}، ۲۰۱۲؛ چن^{۱۹}، ۲۰۱۶) در کشف/پیش‌بینی صورت‌های مالی متقلبانه، عملکرد خوبی دارند.

۲-۲. پیشینه تجربی پژوهش

تانگ و کریم^{۲۰} (۲۰۱۸) در پژوهشی با عنوان «کشف تقلب مالی و تجزیه و تحلیل داده‌های بزرگ: پیامدهای مورد استفاده حسابرسان از نشستهای ایده‌پردازی»، نشان دادند که روش‌های

1. Kumar
2. LR
3. DT
4. SVM
5. DA
6. Bayesian Belief Network
7. Albasrahi
8. Perols
9. Asimit
10. Moepya
11. Yao
12. Han
13. Lin
14. Ravisankar
15. Rizki
16. Murorunkwere
17. Pérez López
18. Gupta & Gill
19. Chen
20. Tang & Karim

حسابرسی موجود با هدف کشف تقلب، نیاز به بهبود و اصلاح دارند؛ چراکه توجه به خرد جمعی باعث ایجاد نگرانی و گمراهی خواهد شد. بنابراین، باید از داده‌های بزرگ‌تر در هر مرحله از جمع‌آوری داده‌ها و شناسایی شاخص‌های تقلب و مستندات بیشتر و جلسات متعدد استفاده شود.

الغفیلی و همکاران (۲۰۲۰) در پژوهشی با عنوان «مدل کشف تقلب مالی براساس تکنیک یادگیری عمیق LSTM»، برای ارزیابی مدل پیشنهادی، از یک مجموعه داده واقعی از تقلب‌های Auto-encoder کارت اعتباری استفاده کردند و نتایج را با یک مدل یادگیری عمیق موجود به نام مدل LSTM و برخی تکنیک‌های یادگیری ماشین دیگر مقایسه کردند. نتایج تجربی، یک عملکرد عالی LSTM را نشان می‌دهد که در آن ۹۹٪ دقت را در کمتر از یک دقیقه به دست می‌آورد.

شیوگو و شنگ یونگ^۱ (۲۰۲۲) در پژوهشی با عنوان «تحلیلی در مورد کشف تقلب در صورت‌های مالی برای شرکت‌های پذیرفته شده چینی با استفاده از یادگیری عمیق»، ابتدا سیستم شاخص مالی را شامل شاخص‌های مالی و غیرمالی تدوین کردند که تحقیقات قبلی معمولاً آنها را حذف می‌کردند. سپس ویژگی‌های متئی در بخش بحث و تحلیل مدیریت گزارش‌های سالانه شرکت‌های پذیرفته شده چینی با استفاده از بردار کلمه استخراج شدند. پس از آن، از مدل‌های یادگیری عمیق قدرتمند استفاده شده و عملکرد آنها به ترتیب با داده‌های عددی، متئی و ترکیبی از آنها مقایسه گردید. نتایج تجربی، بهبود عملکرد عالی روش‌های یادگیری عمیق را در برابر روش‌های یادگیری ماشین سنتی نشان می‌دهد که بیانگر این است که میزان دقت الگوریتم‌های LSTM و GRU در کشف تقلب مالی به ترتیب ۹۸٪ و ۶۲٪ می‌باشد.

علی و همکاران^۲ (۲۰۲۳) در پژوهشی از تکنیک‌های مختلف یادگیری ماشین در محیط پایتون برای پیش‌بینی صورت‌های مالی متقابلانه استفاده کردند و یافته‌های تجربی آنها نشان می‌دهد که الگوریتم XGBoost از دیگر الگوریتم‌های این مطالعه، یعنی رگرسیون لجستیک،^۳ درخت تصمیمی،^۴ ماشین بردار پشتیبانی،^۵ جتگل تصادفی^۶ و آدابوست بهتر عمل کرده است. همچنین الگوریتم XGBoost را برای بدست آوردن بهترین نتیجه با دقت نهایی ۹۶٪ درصد در تشخیص صورت‌های مالی متقابلانه، بهینه کردند.

1. Xiuguo & Shengyong

2. Ali

3. LR

4. DT

5. SVM

6. RF

زهیر و همکاران^۱ (۲۰۲۳) در پژوهشی با استفاده از داده‌های شاخص ترکیبی شانگهایی و روش‌های CNN، RNN، LSTM، CNN-RNN و CNN-LSTM نشان دادند که CNN بدترین عملکرد را دارد، LSTM بهتر از CNN-RNN، CNN-LSTM و CNN-RNN بهتر از CNN بود. نتایج تجربی، اثربخشی مدل پیشنهادی را تایید می‌کند که به سرمایه‌گذاران در افزایش سود خود با تصمیم‌گیری خوب کمک می‌نماید.

یولیاتی و همکاران (۲۰۲۴) در پژوهشی با عنوان «کشف تقلب صورت‌های مالی: رویکرد مدل تقلب شش ضلعی» نشان دادند که ثبات مالی بر تقلب صورت‌های مالی تأثیر مثبت دارد. با این حال، نظارت ناکارآمد، تغییر حسابرس، تغییر مدیران، دوره تصدی مدیر عامل و ارتباط با پروژه‌های دولتی، تأثیری بر تقلب در صورت‌های مالی ندارد.

احمدی و همکاران (۱۳۹۹) در پژوهشی با عنوان «ارائه مدلی برای پیش‌بینی صورت‌های مالی متقلبانه و مقایسه صورت‌ها و نسبت‌های مالی با قانون بنفورود»، با استفاده از روش رگرسیون لجستیک نشان دادند که با توجه به نرخ دقت ۶۴٪ درصدی، این مدل نقش اثربخشی در کشف تقلب صورت‌های مالی دارد. همچنین نتایج آزمون T و آزمون لون در ۳۵٪ متغیر مستقل بررسی شده نشان داد که در ۲۰٪ متغیر، تفاوت معناداری در دو گروه متقلب و غیرمتقلب وجود دارد. به علاوه، تطابق‌پذیری و انحراف از قانون بنفورود در چهار حالت مختلف بررسی شد. توجه به ارقام صورت سود و زیان و ترازنامه در شرکت‌های غیرمتقلب نشان داد توزیع بنفورود شرکت‌های غیرمتقلب را به درستی تشخیص داده، ولی شرکت‌های متقلب را به صورت نادرست غیرمتقلب تشخیص داده است. توجه به نسبت مالی کل دارایی‌ها به فروش، و دوره پرداخت حساب‌های پرداختی در شرکت‌های متقلب نشان داد که توزیع بنفورود، این شرکت‌ها را متقلب ارزیابی و به درستی دسته‌بندی کرده، ولی شرکت‌های غیرمتقلب را به صورت نادرست متقلب ارزیابی کرده است.

ملکی کاکلر و همکاران (۱۴۰۰) در پژوهشی با عنوان «کارایی مدل‌های آماری و الگوهای یادگیری ماشین در پیش‌بینی گزارشگری مالی متقلبانه» با استفاده از ۲۰٪ متغیر در قالب الگوی پنج ضلعی تقلب با تأکید بر ساختار کنترل‌های داخلی در ۱۶۶ شرکت فعال در بورس اوراق بهادار تهران طی سال‌های ۱۳۸۸ الی ۱۳۹۷ و مقایسه بین مدل‌های مورد بررسی، با کمک آزمون مقایسه نسبت‌ها، نشان دادند که به لحاظ آماری، مدل‌های یادگیری ماشین در پیش‌بینی گزارشگری مالی متقلبانه،

نسبت به مدل‌های آماری، کارایی و دقت بیشتری دارند. ترکیب الگوریتم درخت تصمیم‌گیری CHAID، C5 و C&R بالاترین دقت در پیش‌بینی گزارشگری مالی متقلبانه را با دقت بالای ۹۲/۶۱ درصد در پیش‌بینی تقلب نشان می‌دهد.

رضائی و همکاران (۱۴۰۰) در پژوهشی با عنوان «پیش‌بینی تقلب صورت‌های مالی با استفاده از رویکرد کریسپ^۱» نشان دادند که همه تکنیک‌ها قابلیت کشف تقلب صورت‌های مالی را در سطح نسبتاً بالایی دارند و تکنیک پیشنهادی آدابوست ماشین بردار پشتیبان در مرحله آموزش با نرخ دقت ۶۹/۸۱٪ دارای دقت و توان ارزیابی بالاتری نسبت به سایر تکنیک‌ها بوده و این تکنیک در مرحله آزمایش، ۸۲٪ صورت‌های مالی متقلبانه و غیرمتقلبانه سال ۱۳۹۶ را بدرستی تشخیص داد.

کاظمی و پیری (۱۴۰۱) در پژوهشی با عنوان «پیش‌بینی طرح تقلب در گزارشگری مالی با استفاده از رویکرد یادگیری ماشین در فضای چند کلاسه»، نشان دادند که تفاوت معناداری در عملکرد الگوهای یادگیری ماشین در فضای چند کلاسه وجود دارد، و روش ماشین بردار پشتیبان نسبت به سایر روش‌ها عملکرد بهتری دارد. با تقلیل فضای مسیله به دسته‌بندی دو کلاسه، تفاوت معناداری در عملکرد الگوهای یادگیری ماشین در تشخیص گزارش‌های مالی مشکوک به بیش نمایی دارایی، کم نمایی بدھی و هزینه، بیش نمایی دارایی و کم نمایی هزینه و بدھی، تایید نشد. با این حال، عملکرد ماشین بردار پشتیبان بر عملکرد روش رگرسیون لجستیک و درخت تصمیم در پیش‌بینی گزارش‌های مالی مشکوک به بیش نمایی دارایی و درآمد ارجح است.

احمدی و همکاران (۱۴۰۳) در پژوهشی با عنوان «تکنیک‌های داده‌کاوی و پیش‌بینی تقلب صورت‌های مالی» نشان دادند که روش‌های داده‌کاوی در تمایز صورت‌های مالی متقلبانه از غیر متقلبانه موثر هستند. بدین ترتیب که روش شبکه عصبی ۶۹/۴ درصد، درخت تصمیم ۶۵/۴ درصد، نزدیکترین همسایگی ۶۴/۴ درصد و ماشین بردار پشتیبان ۷۸ درصد پیش‌بینی صحیح داشته‌اند. امیرمعزی و همکاران (۱۴۰۳) در پژوهشی با عنوان «کشف تقلب صورت‌های مالی: قیاس توانایی مدل‌های مبتنی بر متغیرهای حسابداری» نشان دادند که دقت معیار F-SCORE ۷۳٪ در تشخیص شرکت‌های دارای احتمال دستکاری و غیر آن، بیش از ۷۰ است که بیانگر توانایی متوسط مدل مذکور در تشخیص تقلب است. همچنین توانایی معیار فوق الذکر با ۱۷٪ درصد در تشخیص تقلب از مدل بنیش با ۵۱/۶۹ درصد بالاتر است. از حیث خطای تشخیص نیز، خطای نوع I و II که به ترتیب بیانگر خطای کارایی و اثربخشی مدل است، در مدل دچو و همکاران (۲۰۱۱)

به مراتب کمتر از مدل بنیش است. بنابراین، می‌توان نتیجه گرفت که معیار F-SCORE دچو در موارد تشخیص احتمال دستکاری در صورت‌های مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در فاصله سال‌های ۱۳۹۸ تا ۱۴۰۴ بهتر عمل کرده است.

زارعی و همکاران (۱۴۰۳) در پژوهشی با عنوان «ارائه الگوی پیش‌بینی تقلب مبتنی بر هوش مصنوعی (بیز ساده)» نشان دادند که روش مورد بررسی در این پژوهش با ضریب صحّت ۸۴ درصد، ضریب دقت ۸۴ درصد و ضریب بازخوانی ۹۸ درصد، از توانایی بالایی برای پیش‌بینی تقلب براساس متغیرهای موجود در صورت مالی شرکت‌های پذیرفته شده در بازار بورس برخوردار است.

۳. روش پژوهش

۱-۱. جمع‌آوری داده‌ها

این پژوهش از لحاظ هدف کاربردی بوده و از نوع پژوهش‌های شبه‌تجربی و پس‌رویدادی است و با استفاده از اطلاعات تاریخی انجام شده است. داده‌های مورد نیاز از نرم‌افزار «رهاورد نوین» و سایت‌های اینترنتی «مدیریت پژوهش، توسعه و مطالعات اسلامی سازمان بورس اوراق بهادار»، «کدال»، بانک مرکزی و مرکز آمار ایران گردآوری شده است.

۲-۱. جامعه آماری، نمونه آماری و بازه زمانی پژوهش

جامعه آماری پژوهش حاضر، شامل کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. بازه زمانی نیز یک دوره زمانی ۱۲ ساله براساس صورت‌های مالی سال‌های ۱۴۰۲-۱۳۹۱ 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 بودند، به عنوان نمونه آماری انتخاب و مابقی حذف شدند:

- (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 مورد بررسی جزء شرکت‌های سرمایه‌گذاری، هلدینگ، واسطه‌گری مالی و ییمه 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 شدند.

۳-۳. روش اندازه‌گیری متغیرهای پژوهش

متغیر وابسته (پاسخ): متغیر وابسته در پژوهش حاضر صورت‌های مالی متقلباته می‌باشد که با استفاده از شاخص F_SCORE تدوین شده توسط دیچو و همکاران^۱ (۲۰۱۱) اندازه‌گیری می‌شود که به صورت زیر است:

رابطه (۱):

$$\text{Predicted Value} = -7.893 + 0.790 \times (\text{rsst_acc}) + 2.518 \times (\text{ch_rec}) + 1.191 \times (\text{ch_inv}) + 1.979 \times (\text{soft_assets}) + 0.171 \times (\text{ch_cs}) - 0.932 \times (\text{ch_roa}) + 1.029 \times (\text{issue})$$

که در آن:

rsst_acc: برابر است با $(\Delta\text{fin} + \Delta\text{wc} + \Delta\text{nco})$ تقسیم بر میانگین کل دارایی‌ها.
wc: برابر دارایی‌های جاری منهای وجه نقد و سرمایه‌گذارهای کوتاه مدت، منهای بدھی‌های جاری است.

Nco: برابر مجموع دارایی‌ها، منهای دارایی جاری، منهای سرمایه‌گذاری‌ها، منهای مجموع بدھی‌ها، به کسر بدھی‌های جاری و بلندمدت است.

Fin: برابر سرمایه‌گذاری کوتاه مدت، به علاوه سرمایه‌گذاری بلندمدت، منهای مجموع بدھی‌های بلندمدت، بدھی‌های جاری و سهام ممتاز است.

ch_rec: برابر با تغییر در حساب‌های دریافتی در طول دوره‌ی جاری تقسیم بر میانگین دارایی‌ها است.

ch_inv: برابر با تغییر در موجودی‌ها در طول دوره‌ی جاری تقسیم بر میانگین دارایی‌ها است.

soft_assets: برابر با مجموع دارایی‌ها به کسر اموال، ماشین‌آلات و تجهیزات و وجه نقد و معادل آن تقسیم بر مجموع دارایی‌ها است.

ch_cs: برابر با درصد تغییر در فروش نقدی است، که از طریق فروش دوره‌ی جاری، منهای تغییر در حساب‌های دریافتی محاسبه می‌شود.

ch_roa: برابر با تغییر در بازده دارایی‌ها است، که از طریق تقسیم سود خالص بر میانگین دارایی‌ها بدست می‌آید.

Issue: متغیری ساختگی است؛ به این ترتیب که برای شرکتی که اوراق بدھی یا اوراق مالکیت منتشر کرده باشد، عدد (۱) و در غیر این صورت (۰) می‌باشد.

برای محاسبه F_SCORE، احتمال پیش‌بینی از طریق تقسیم $\frac{e^{PV}}{1+e^{PV}}$ بر احتمال غیرشرطی

ارائه نادرست صورت‌های مالی (۰۰۳۷) بدست می‌آید. که در آن PV ارزش پیش‌بینی بدست آمده از رابطه (۱) است. براساس پژوهش دیچو و همکاران (۲۰۱۱)، در این پژوهش مشاهدات دارای بالاتر از F_SCORE ۸۵/۱ به عنوان شرکت‌های با ریسک بالای صورت‌های مالی متقلبانه شناسایی می‌شوند.

۴-۳. متغیرهای مستقل (پیش‌بین)

به پیروی از پژوهش‌های پیشین (علی و همکاران، ۲۰۲۳؛ جان، ۲۰۲۱؛ کات سیس و همکاران، ۲۰۱۲؛ پرلوس، ۲۰۱۱؛ رضائی و همکاران، ۱۴۰۰؛ خواجهی و ابراهیمی، ۱۳۹۶؛ اعتمادی و زلقی، ۱۳۹۲؛ صفرزاده، ۱۳۸۹) متغیرهای مستقل پژوهش حاضر به شرح جدول زیر ارائه می‌گردد:

جدول ۱- نحوه اندازه‌گیری متغیرهای مستقل پژوهش

ردیف	متغیر مستقل	نام	نحوه اندازه‌گیری
۱	حاشیه سود ناخالص	GPM	سود ناخالص تقسیم بر فروش
۲	حاشیه سود ناخالص	NPM	سود خالص تقسیم بر فروش
۳	حاشیه سود عملیاتی	OPM	سود عملیاتی تقسیم بر فروش
۴	بازده دارایی‌ها	ROA	سود خالص تقسیم بر کل دارایی
۵	بازده حقوق صاحبان سهام	ROE	سود خالص تقسیم بر ارزش دفتری حقوق صاحبان سهام
۶	نسبت سود قبل از بهره و مالیات	EBIT/A	سود قبل از بهره و مالیاتی تقسیم بر کل دارایی
۷	گردش کل دارایی‌ها	ASTRN	فروش خالص تقسیم بر کل دارایی
۸	گردش دارایی‌های ثابت	FXASTRN	فروش خالص تقسیم بر دارایی‌های ثابت
۹	گردش موجودی کالا	INVTRN	بهای تمام شده کالای فروش رفته تقسیم بر متوسط موجودی کالا
۱۰	گردش حساب‌های دریافتی	ACRECTRN	فروش خالص تقسیم بر متوسط حساب‌های دریافتی
۱۱	نسبت کل بدهی‌ها به کل دارایی‌ها	LIB/ASST	کل بدهی‌ها تقسیم بر کل دارایی‌ها
۱۲	نسبت کل بدهی‌ها به حقوق صاحبان سهام	LIB/EQT	کل بدهی‌ها تقسیم بر ارزش دفتری حقوق صاحبان سهام
۱۳	نسبت سود ابیاشته به کل دارایی‌ها	ACUM/ASST	سود (زیان) ابیاشته تقسیم بر کل دارایی
۱۴	نسبت سود ابیاشته به سرمایه	ACUM/EQT	سود (زیان) ابیاشته تقسیم بر سرمایه سهام عادی

1. Jan
2. Katsis
3. Perlos

ردیف	متغیر مستقل	ناماد	نحوه اندازه‌گیری
۱۵	نسبت پوشش هزینه بهره	INTCOV	هزینه بهره تقسیم بر سود قبل از بهره و مالیات
۱۶	نسبت جاری	CURRAT	دارایی‌های جاری تقسیم بر بدھی‌های جاری
۱۷	نسبت آنی	QUICRAT	(وجه نقد + حساب‌های دریافتی + سرمایه‌گذاری کوتاه مدت) تقسیم بر بدھی‌های جاری
۱۸	نسبت وجه نقد آزاد به درآمد	FCF/REV	{سود خالص+هزینه استهلاک+هزینه مالی}×(۱-مالیات) - سرمایه‌گذاری در دارایی ثابت - سرمایه‌گذاری در سرمایه در گردش } تقسیم بر فروش
۱۹	نسبت مخارج سرمایه‌ای به درآمد	CE/REV	مخارج سرمایه‌ای (تفاوت خالص ارزش دفتری دارایی‌های ثابت در ابتدا و پایان دوره به علاوه هزینه استهلاک) تقسیم بر فروش
۲۰	نسبت مخارج سرمایه‌ای به سود خالص	CE/NP	مخارج سرمایه‌ای، تقسیم بر سود خالص
۲۱	نسبت وجه نقد عملیاتی به درآمد	OCF/REV	خالص جریان وجه نقد عملیاتی حاصل از فعالیت‌های عملیاتی تقسیم بر فروش خالص
۲۲	نسبت وجه نقد عملیاتی به بدھی	OCF/LIB	خالص جریان وجه نقد عملیاتی حاصل از فعالیت‌های عملیاتی، تقسیم بر کل بدھی‌ها
۲۳	ارزش شرکت	EV	لگاریتم طبیعی (ارزش بازار سهام+ارزش دفتری بدھی‌ها- نقد و معادل نقد)
۲۴	ارزش دفتری شرکت	BV	لگاریتم طبیعی ارزش دفتری حقوق صاحبان سهام

۳-۵. الگوریتم‌های یادگیری عمیق مورد استفاده در پژوهش

ماشین بردار پشتیبان (^۱SVM): ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است از آن برای طبقه‌بندی و رگرسیون استفاده می‌شود. این روش از روش‌های نسبتاً جدیدی بوده که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی نشان داده است. مبنای کاری دسته‌بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌شود خطی انتخاب گردد که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های QP که روش‌های شناخته‌شده‌ای در حل مسائل محدودیت دار هستند، صورت می‌گیرد.

قبل از تقسیم خطی، برای اینکه ماشین بتواند داده‌هایی با پیچیدگی بالا را دسته‌بندی کند، داده‌ها با استفاده از تابع phi به فضایی با ابعاد خیلی بالاتر برده می‌شوند. برای اینکه بتوان مسئله ابعاد خیلی

بالا را با استفاده از این روش‌ها حل کرد، از قضیه دوگانی لاگرانژ^۱ برای تبدیل مستله مینیمم‌سازی مورد نظر به فرم دوگانی آن که در آن به جای تابع پیچیده phi که ما را به فضای با ابعاد بالا می‌برد، تابع ساده‌تری به نام تابع هسته که ضرب برداری تابع phi است، استفاده می‌گردد. از توابع هسته مختلفی از جمله هسته‌های نمایی، چندجمله‌ای و سیگموید^۲ می‌توان استفاده نمود.

شبکه عصبی پیچشی (CNN): شبکه عصبی پیچشی یا به اختصار CNN که به آن شبکه عصبی کانولوشنی نیز گفته می‌شود، نوعی از شبکه‌های عصبی است که عموماً برای یادگیری بر روی مجموعه داده‌های بصری (مانند تصاویر و عکس‌ها) استفاده می‌شود. از لحاظ مفهوم، این شبکه‌ها مانند شبکه‌های عصبی ساده هستند؛ یعنی از فازهای پیش‌خور^۳ و پس‌انتشار خطأ^۴ استفاده می‌کنند، ولی از لحاظ معماری تفاوت‌هایی با شبکه‌های عصبی ساده دارند. این شبکه‌ها در دسته یادگیری عمیق قرار می‌گیرند؛ زیرا لایه‌های موجود در این شبکه‌ها، زیاد است.

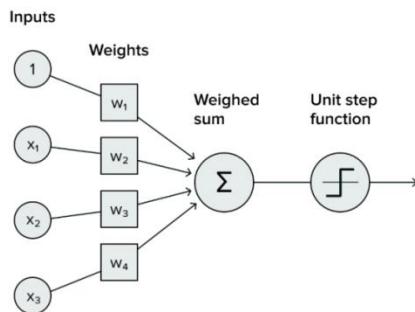
شبکه عصبی پیچشی همانند سایر شبکه‌های عصبی از لایه‌های نورونی با وزن و بایاس با قابلیت یادگیری تشکیل شده است. در هر نورون اتفاقات زیر رخ می‌دهد:

۱. نورون مجموعه‌ای ورودی دریافت می‌کند.

۲. ضرب داخلی بین وزن‌های نورون و ورودی‌ها انجام می‌شود.

۳. حاصل با بایاس جمع می‌شود.

۴. درنهایت، از یک تابع غیرخطی^۵ عبور داده می‌شود.

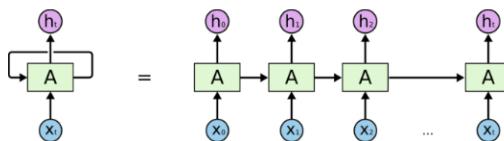


شکل ۱- یک بلوک شبکه عصبی پیچشی (علی و همکاران، ۲۰۲۳)

-
1. Lagrange's duality theorem
 2. Sigmoid
 3. Convolutional Neural Networks
 4. Feed forward
 5. Back propagation of error
 6. Activation function

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

شبکه عصبی بازگشتی (RNN): شبکه عصبی بازگشتی که به آن شبکه عصبی مکرر نیز گفته می‌شود، نوعی از شبکه عصبی مصنوعی است که در تشخیص گفتار، پردازش زبان طبیعی^۲ و همچنین در پردازش داده‌های ترتیبی^۳ استفاده می‌شود. بسیاری از شبکه‌های عمیق مانند CNN شبکه‌های پیش‌خور^۴ هستند؛ یعنی سیگنال در این شبکه‌ها فقط در یک جهت از لایه ورودی، به لایه‌های مخفی و سپس به لایه خروجی حرکت می‌کند و داده‌های قبلی به حافظه سپرده نمی‌شوند. اما شبکه‌های عصبی بازگشتی، یک لایه بازخورد دارند که در آن خروجی شبکه به همراه ورودی بعدی، به شبکه بازگردانده می‌شود. RNN می‌تواند به علت داشتن حافظه داخلی، ورودی قبلی خود را به خاطر بسپارد و از این حافظه برای پردازش دنباله‌ای از ورودی‌ها استفاده کند. به بیان ساده، شبکه‌های عصبی بازگشتی شامل یک حلقة بازگشتی هستند که موجب می‌شود اطلاعاتی را که از لحظات قبلی بدست آمده، از بین نرون‌های در شبکه باقی بمانند.



An unrolled recurrent neural network.

شکل ۲- یک بلوک شبکه عصبی بازگشتی (علی و همکاران، ۲۰۲۳)

همانطور که در شکل (۲) مشاهده می‌شود، X_0 را از دنباله ورودی می‌گیرد، خروجی h_0 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 آموختش، قادر به یادآوری ورودی‌های قبلی خواهد بود.

شبکه عصبی بازگشتی می‌تواند کاربردهایی به شرح زیر داشته باشد:

۱. **شرح‌نویسی عکس:**^۵ شبکه عصبی بازگشتی با تحلیل حالت کنونی عکس، برای شرح‌نویسی عکس به کار می‌رود.

-
1. Recurrent Neural Networks
 2. NLP
 3. Sequential data
 4. Feed Forward
 5. Image Captioning

۲. پیش‌بینی سری‌های زمانی:^۱ هر مسئله سری زمانی مانند پیش‌بینی قیمت یک سهام در یک ماه خاص، با RNN قابل انجام است.
۳. پردازش زبان طبیعی:^۲ کاوش متن و تحلیل احساسات می‌تواند با استفاده از RNN انجام شود.
۴. ترجمه ماشینی:^۳ شبکه RNN می‌تواند ورودی خود را از یک زبان دریافت و آن را به عنوان خروجی به زبان دیگری ترجمه کند.

۴. یافته‌های پژوهش

۴-۱. آمار توصیفی متغیرهای پژوهش

جدول ۲- آمار توصیفی متغیرهای پژوهش

متغیرها	نماد	تعداد مشاهدات	پنل الف: متغیرهای پیوسته				
			میانگین	میانه	حداکثر	حداقل	انحراف معیار
حاشیه سود ناچالص	GPM	1800	0.136	0.179	0.616	-0.151	0.196
حاشیه سود خالص	NPM	1800	0.128	0.164	0.566	-0.154	0.183
حاشیه سود عملیاتی	OPM	1800	0.157	0.191	0.528	-0.107	0.172
بازده دارایی‌ها	ROA	1800	0.108	0.131	0.414	-0.089	0.134
بازده حقوق صاحبان سهام	ROE	1800	0.291	0.294	0.749	-0.236	0.260
نسبت سود قبل از بهره و مالیات	EBIT/A	1800	0.161	0.187	0.466	-0.029	0.139
گردش کل دارایی‌ها	ASTRN	1800	0.919	0.795	2.067	0.297	0.478
گردش دارایی‌های ثابت	FXASTRN	1800	6.396	4.479	21.330	0.703	5.679
گردش موجودی کالا	INVTRN	1800	4.008	2.851	12.172	1.007	2.988
گردش حساب‌های دریافتی	ACRECTRN	1800	5.416	3.545	20.900	0.925	5.168
نسبت کل بدھی‌ها به کل دارایی‌ها	LIB/ASST	1800	0.572	0.579	0.923	0.208	0.200
نسبت کل بدھی‌ها به حقوق صاحبان سهام	LIB/EQT	1800	1.849	1.268	6.786	0.172	1.701
نسبت سود انباشته به کل دارایی‌ها	ACUM/ASST	1800	0.148	0.152	0.495	-0.249	0.193
نسبت سود انباشته به سرمایه	ACUM/EQT	1800	0.332	0.401	0.880	-0.723	0.413
نسبت پوشش هزینه بهره	INTCOV	1800	19.244	4.459	153.122	-0.401	37.205
نسبت جاری	CURRAT	1800	1.526	1.348	3.440	0.599	0.717

1. Time Series Prediction
2. Natural Language Processing
3. Machine Translation

پنل الف: متغیرهای پیوسته								
متغیرها	نماد	تعداد مشاهدات	میانگین	میانه	حداکثر	حداقل	انحراف معیار	
نسبت آنی	QUICRAT	1800	0.816	0.728	2.067	0.193	0.484	
نسبت وجه نقد آزاد به درآمد	FCF/REV	1800	0.054	0.043	0.323	-0.261	0.139	
نسبت مخارج سرمایه‌ای به درآمد	CE/REV	1800	0.045	0.012	0.224	-0.019	0.075	
نسبت مخارج سرمایه‌ای به سود خالص	CE/NP	1800	0.248	0.070	1.652	-0.519	0.600	
نسبت وجه نقد عملیاتی به درآمد	OCF/REV	1800	0.136	0.112	0.473	-0.117	0.153	
نسبت وجه نقد عملیاتی به بدھی	OCF/LIB	1800	0.247	0.162	1.145	-0.144	0.316	
ارزش شرکت	EV	1800					1.669	12.944 18.757 15.598 15.635
ارزش دفتری شرکت	BV	1800					1.516	12.255 17.970 14.505 14.695

پنل ب: متغیرهای دو ارزشی					
متغیرها	نماد	طبقه	فرابونی	درصد فرابونی	
صورت‌های مالی متقلبانه	FSF	1	536	29.8%	
صورت‌های مالی متقلبانه	FSF	0	1264	70.2%	

در جدول (۲)، برخی از مفاهیم آمار توصیفی متغیرها، شامل میانگین، میانه، حداقل مشاهدات، حداکثر مشاهدات و انحراف معیار ارائه شده است. با توجه به پنل «الف»، میانگین متغیر حاشیه سود ناخالص ۱۷۹٪ می‌باشد که با توجه به انحراف معیار (۱۹۶٪)، از نوسان پذیری بالایی برخوردار است. میانگین متغیر بازده دارایی‌ها ۱۳۱٪ می‌باشد که با توجه به انحراف معیار (۱۳۴٪)، از نوسان پذیری بالایی برخوردار است. میانگین نسبت کل بدھی‌ها به کل دارایی‌ها ۵۷۲٪ می‌باشد که نشان‌دهنده این است که به طور متوسط ۵۷٪ منابع مالی شرکت‌ها از طریق بدھی، تأمین مالی شده است. با توجه به پنل «ب» نیز نتایج نشان می‌دهد که درصد فرابونی صورت‌های مالی متقلبانه ۲۹٪ می‌باشد که نشان‌دهنده این است که صورت‌های مالی ۸٪ شرکت‌های موجود در نمونه آماری پژوهش، متقلبانه است.

جدول ۳- آزمون t در شرکت‌های دارای صورت‌های مالی متقلبانه و بدون صورت‌های مالی متقلبانه

متغیرها	نماد	صورت‌های مالی متقلبانه (تعداد مشاهدات = ۵۳۶)	بدون صورت‌های مالی متقلبانه (تعداد مشاهدات = ۱۲۶۴)	t آماره
حاشیه سود ناخالص	GPM	0.0592	0.2292	-18.315***
حاشیه سود خالص	NPM	0.0534	0.2114	-17.911***
حاشیه سود عملیاتی	OPM	0.0739	0.2403	-22.228***

متغیرها	نماد	صورت‌های مالی متقلبانه (تعداد مشاهدات = ۵۳۶)	صورت‌های مالی بدون صورت‌های مالی متقلبانه (تعداد مشاهدات = ۱۲۶۴)	t آماره
بازده دارایی‌ها	ROA	0.0199	0.1779	-31.566****
بازده حقوق صاحبان سهام	ROE	0.1082	0.3729	-22.301****
نسبت سود قبل از بهره و مالیات	EBIT/A	0.0701	0.2366	-32.817***
گردش کل دارایی‌ها	ASTRN	0.5773	1.0637	-27.466***
گردش دارایی‌های ثابت	FXASTRN	3.5672	7.5956	-16.780****
گردش موجودی کالا	INVTRN	3.622	4.1721	-3.644***
گردش حساب‌های دریافتی	ACRECTRNN	3.5139	6.2228	-11.929***
نسبت کل بدھی‌ها به کل دارایی‌ها	LIB/ASST	0.6622	0.535	12.732***
نسبت کل بدھی‌ها به حقوق صاحبان سهام	LIB/EQT	2.312	1.653	6.873***
نسبت سود انباسته به کل دارایی‌ها	ACUM/ASST	-0.0111	0.2168	-27.260***
نسبت سود انباسته به سرمایه	ACUM/EQT	0.0941	0.433	-15.039***
نسبت پوشش هزینه بهره	INTCOV	5.4553	25.0905	-14.125***
نسبت جاری	CURRAT	1.1201	1.6985	-19.202***
نسبت آنی	QUICRAT	0.6192	0.8993	-13.255***
نسبت وجه نقد آزاد به درآمد	FCF/REV	-0.056	0.1007	-23.443***
نسبت مخارج سرمایه‌ای به درآمد	CE/REV	0.06	0.0381	4.967***
نسبت مخارج سرمایه‌ای به سود خالص	CE/NP	0.3256	0.2151	3.028***
نسبت وجه نقد عملیاتی به درآمد	OCF/REV	0.1137	0.1461	-3.929***
نسبت وجه نقد عملیاتی به بدھی	OCF/LIB	0.0893	0.3146	-19.555***
ارزش شرکت	EV	15.3186	15.7694	-5.280***
ارزش دفتری شرکت	BV	14.5811	14.744	-1.996**

* معناداری در سطح اطمینان ۹۰٪، ** معناداری در سطح اطمینان ۹۵٪ و *** معناداری در سطح اطمینان ۹۹٪

با توجه به جدول (۳)، نتایج حاصل از آزمون t نشان می‌دهد که در سطح اطمینان ۹۵٪، همه متغیرهای مستقل (پیش‌بین) در شرکت‌های دارای صورت‌های مالی متقلبانه و بدون صورت‌های مالی متقلبانه، تفاوت معناداری با هم دارند و میانگین متغیرهای حاشیه سود ناخالص، حاشیه سود خالص، حاشیه سود عملیاتی، بازده دارایی‌ها، بازده حقوق صاحبان سهام، نسبت سود قبل از بهره و مالیات، گردش کل دارایی‌ها، گردش دارایی‌های ثابت، گردش موجودی کالا، گردش حساب‌های دریافتی، نسبت سود انباسته به کل دارایی‌ها، نسبت سود انباسته به سرمایه، نسبت پوشش هزینه بهره، نسبت جاری، نسبت آنی، نسبت وجه نقد آزاد به درآمد، نسبت وجه نقد عملیاتی به درآمد، نسبت وجه نقد عملیاتی به بدھی، ارزش شرکت و ارزش دفتری شرکت، در شرکت‌های دارای صورت‌های

مالی متقلبانه در مقایسه با شرکت‌های دارای بدون صورت‌های مالی متقلبانه کمتر است؛ در حالی که، میانگین متغیرهای نسبت کل بدھی‌ها به کل دارایی‌ها، نسبت کل بدھی‌ها به حقوق صاحبان سهام، نسبت مخارج سرمایه‌ای به درآمد و نسبت مخارج سرمایه‌ای به سود خالص، در شرکت‌های دارای صورت‌های مالی متقلبانه، در مقایسه با شرکت‌های دارای بدون صورت‌های مالی متقلبانه، بیشتر است.

۲-۴. فرآیند ایجاد مدل‌های پژوهش

به منظور پاسخگویی به سوالات و همچنین دستیابی به اهداف پژوهش، ابتدا مدل‌های مورد نظر شامل مدل‌های ایجادی با ماشین بردار پشتیبان، شبکه عصبی پیچشی و شبکه عصبی بازگشته، با استفاده از متغیرهای انتخاب شده براساس «آزمون مقایسه میانگین دو نمونه» ایجاد شده و مقایسه نتایج انجام شد.

۱-۲-۴. متغیرهای نهایی پژوهش

به منظور تعیین متغیرهای نهایی (با اهمیت) پژوهش از میان متغیرهای اولیه پژوهش (۲۴ متغیر انتخاب شده براساس مبانی نظری و مطالعات تجربی)، از آزمون مقایسه میانگین دو نمونه مستقل استفاده شد. 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 شد. 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 (۲) برای محاسبه آماره t استفاده می‌شود که در این حالت درجه آزادی برابر $df=n_1+n_2-2$ است.

رابطه (۲):

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

رابطه (۳):

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

در حالت عدم تساوی واریانس‌ها، آماره t از رابطه (۴) و درجه آزادی از رابطه (۵) محاسبه می‌شود.

رابطه (۴):

$$t = \frac{(\bar{x}_1 - \bar{x}_2) - (u_1 - u_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

رابطه (۵):

$$t = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^2}{\frac{\left(\frac{s_1^2}{n_1} \right)^2}{n_1 - 1} + \frac{\left(\frac{s_2^2}{n_2} \right)^2}{n_2 - 1}}$$

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 درصد، تفسیر نتایج انجام می‌شود. اگر عدد t محاسبه شده از عدد t طبق جدول کوچکتر باشد ($p-value < 0.05$)، معنادار بودن تفاوت میانگین‌های دو گروه، پذیرفته شده و در غیر این صورت رد خواهد شد. با توجه به جدول (۴)، نتایج حاصل از آزمون t نشان می‌دهد که در سطح اطمینان ۹۵٪، همه متغیرهای مستقل (پیش‌بین) در شرکت‌های دارای صورت‌های مالی متقلبانه و بدون صورت‌های مالی متقلبانه، تفاوت معناداری با هم دارند. بنابراین، در ادامه به منظور پیاده‌سازی الگوریتم یادگیری عمیق از ۲۴ متغیر پیش‌بین انتخاب شده براساس آزمون t استفاده می‌گردد.

۲-۲-۴. اجرای مدل‌ها

به منظور پیاده‌سازی و ارزیابی الگوریتم‌ها، داده‌های پژوهش باید به دو دسته داده‌های آموزش و آزمایش تقسیم شوند. از مجموعه داده‌های آموزش برای ساخت و از داده‌های آزمایش نیز برای ارزیابی مدل ایجاد شده در مرحله آموزش استفاده می‌شود. تکنیک‌های دسته‌بندی را می‌توان براساس معیارهایی مانند صحّت، سرعت و پایداری با هم مقایسه نمود. صحّت یک روش دسته‌بندی، بستگی به تعداد پیش‌بینی‌های درستی که آن مدل انجام می‌دهد، دارد. سرعت یک روش دسته‌بندی نیز زمان لازم برای ساخت و استفاده از مدل در دسته‌بندی است و پایداری توانایی برخورد مدل در مواجهه با داده‌های غیرمعمول و یا مقادیر مفقود شده را نشان می‌دهد.

به منظور ارزیابی صحّت و پایداری مدل‌ها، داده‌های پژوهش ۵۰ مرتبه به صورت تصادفی به دو دسته داده‌های آموزش و آزمایش تقسیم شده و ایجاد مدل و ارزیابی نتایج حاصل از آنها انجام شد. به این صورت که در هر مرتبه ۷۵ درصد داده‌ها برای آموزش مدل و ۲۵ درصد آن را برای ارزیابی و آزمایش مدل مورد استفاده قرار گرفته و میانگین نتایج حاصل از ۵۰ مرتبه اجرای هر مدل، به عنوان نتیجه نهایی آن در نظر گرفته شده است.

جدول ۴- پارامترهای شبیه‌سازی

مقدار	پارامتر شبیه‌سازی
۱۸۰۰ سال - شرکت (مشاهده)	تعداد نمونه‌ها کل دیتابست
۲۴ ویژگی	تعداد ویژگی هر نمونه
۱۳۵۰	تعداد نمونه‌های آموزش مدل
۴۵۰	تعداد نمونه‌های تست مدل

۳-۲-۴. پارامترهای ارزیابی مدل

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 (۶):

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

همانگونه که در جدول (۵) 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 ۵- ماتریس اغتشاش

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

با توجه به هدف پژوهش حاضر که کشف صورت‌های مالی متقلبانه است، پارامترهای ماتریس اغتشاش به صورت زیر تعریف می‌شوند:

TP: درصد تشخیص درست شرکت‌های دارای صورت‌های مالی متقلبانه

TN: درصد تشخیص درست شرکت‌های بدون صورت‌های مالی متقلبانه

FP: درصد تشخیص غلط شرکت‌های دارای صورت‌های مالی متقلبانه به عنوان شرکت‌های

بدون صورت‌های مالی متقلبانه

FN: درصد تشخیص غلط شرکت‌های بدون صورت‌های مالی متقلبانه به عنوان شرکت‌های

دارای صورت‌های مالی متقلبانه.

1. Accuracy

2. Confusion Matrix

در ادامه ماتریس اغتشاش هر روش دسته‌بندی در کشف صورت‌های مالی متقلبانه نشان داده شده است.

نتایج حاصل از الگوریتم ماشین بردار پیش‌تیبان که در قالب ماتریس اغتشاش و در جدول (۶) آمده است، نشان می‌دهد که میزان خطای مدل در شناسایی شرکت‌های دارای صورت‌های مالی متقلبانه و شرکت‌های بدون صورت‌های مالی متقلبانه به ترتیب ۱۰.۹٪ و ۱۲.۴٪ می‌باشد. در حالت کلی، نتایج حاصل از الگوریتم SVM نشان می‌دهد که میزان دقت این مدل در کشف صورت‌های مالی متقلبانه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، تقریباً ۸۸.۴٪ است، این موضوع نشان‌دهنده آن است که با توجه به متغیرهای انتخاب شده به روش T-test و الگوریتم ماشین بردار پیش‌تیبان، می‌توان با احتمال ۸۸.۴٪ شرکت‌های دارای صورت‌های مالی متقلبانه را شناسایی کرد.

جدول ۶- نتایج ماتریس اغتشاش در کشف صورت‌های مالی متقلبانه
(الگوریتم ماشین بردار پیش‌تیبان)

SVM & T-test		
	Positive	Negative
Positive	0.891	0.124
Negative	0.109	0.876
Accuracy	0.884	

نتایج حاصل از الگوریتم شبکه عصبی پیچشی که در قالب ماتریس اغتشاش و در جدول (۷) ارائه شده است، نشان می‌دهد که میزان خطای مدل در شناسایی شرکت‌های دارای صورت‌های مالی متقلبانه و شرکت‌های بدون صورت‌های مالی متقلبانه به ترتیب ۳٪/۱۸٪ و ۱٪/۱۹٪ می‌باشد. در حالت کلی، نتایج حاصل از الگوریتم CNN نشان می‌دهد که میزان دقت این مدل در کشف صورت‌های مالی متقلبانه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، تقریباً ۸۱٪ است، این موضوع نشان‌دهنده آن است که با توجه به متغیرهای انتخاب شده به روش T-test و الگوریتم شبکه عصبی پیچشی، می‌توان با احتمال ۸۱٪ شرکت‌های دارای صورت‌های مالی متقلبانه را شناسایی کرد.

جدول ۷- نتایج ماتریس اغتشاش در کشف صورت‌های مالی متقلبانه
(الگوریتم شبکه عصبی پیچشی)

CNN & T-test		
	Positive	Negative
Positive	0.817	0.191
Negative	0.183	0.809
Accuracy	0.813	

نتایج حاصل از الگوریتم شبکه عصبی بازگشتی که در قالب ماتریس اغتشاش و در جدول (۸) ارائه شده است، نشان می‌دهد که میزان خطای مدل در شناسایی شرکت‌های دارای صورت‌های مالی متقلبانه و شرکت‌های بدون صورت‌های مالی متقلبانه به ترتیب ۵۵.۲٪ و ۶۶.۱٪ می‌باشد. در حالت کلی، نتایج حاصل از الگوریتم RNN نشان می‌دهد که میزان دقت این مدل در کشف صورت‌های مالی متقلبانه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، تقریباً ۹۴٪ است. این موضوع نشان‌دهنده آن است که با توجه به متغیرهای انتخاب شده به روش T-test و الگوریتم شبکه عصبی بازگشتی، می‌توان با احتمال ۹۴٪ شرکت‌های دارای صورت‌های مالی متقلبانه را شناسایی کرد.

جدول ۸- نتایج ماتریس اغتشاش در کشف صورت‌های مالی متقلبانه
(الگوریتم شبکه عصبی بازگشتی)

RNN & T-test		
	Positive	Negative
Positive	0.948	0.061
Negative	0.052	0.939
Accuracy	0.944	

جدول ۹- خلاصه نتایج الگوریتم LSTM و سایر الگوریتم‌های یادگیری عمیق در کشف صورت‌های مالی متقلبانه

FN	Accuracy	الگوریتم
0.109	0.884	SVM
0.183	0.813	CNN
0.052	0.944	RNN

با توجه به جدول (۹)، به طور خلاصه نتایج حاصل از الگوریتم‌های یادگیری عمیق نشان می‌دهد که صحّت کلی الگوریتم‌های CNN و RNN به ترتیب ۸۸.۴٪ و ۹۴.۴٪ می‌باشد که نشان‌دهنده این است که الگوریتم RNN بهترین عملکرد و الگوریتم CNN بدترین عملکرد را در کشف شرکت‌های دارای صورت‌های مالی متقلبانه دارد. به عبارت دیگر، نتایج نشان‌دهنده کارآبودن الگوریتم شبکه عصبی بازگشتی نسبت به سایر الگوریتم‌های یادگیری عمیق می‌باشد. بنابراین، در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، از بین سه الگوریتم SVM، CNN و RNN، الگوریتم RNN کارترین مدل را برای کشف صورت‌های مالی متقلبانه فراهم می‌کند.

۵. نتیجه‌گیری

در محیط تجاری مدرن امروزی با پیچیده‌تر شدن سیستم‌ها و فعالیت‌ها و افزایش اطلاعات

فریبکارانه، فناوری‌های مورد استفاده برای جلوگیری و کشف تقلب نیز بهروز شده است. بنابراین، توسعه و رشد روش‌های مربوط به داده‌های متتنوع ازجمله داده‌کاوی، برای تشخیص تقلب‌های مالی در اولویت است. در ایران به موضوع کشف تقلب صورت‌های مالی توجه زیادی نشده است. مسئله گزارشگری مالی متقلبانه در ایران از اهمیت ویژه برخوردار است. افزایش تعداد شرکت‌های پذیرفته شده در بورس که به منظور جذب منابع مالی به انتشار اوراق بهادر اقدام می‌کنند، تلاش به منظور کاهش مالیات بر درآمد و... ازجمله دلایل اهمیت این موضوع است. بنابراین، در حوزه کشف تقلب هرچقدر حسابسان و ذینفعان شرکت به تکنیک‌ها و رویکردهای کارآمدتری ازجمله الگوریتم‌های یادگیری عمیق و رویکردهای کارآمدی چون شبکه عصبی و ماشین بردار پشتیبان دسترسی داشته باشند، قاعdet، توانایی و کارایی آنها در حوزه تاییدپذیری اطلاعات صورت‌های مالی بالاتر خواهد رفت. کشف تقلب در صورت‌های مالی در چند دهه گذشته با تاکید بر ناهنجاری‌های حسابداری به طور کلی و به طور خاص بر تقلب در صورت‌های مالی مورد توجه قرار گرفته است.

در این راستا، پژوهش حاضر با استفاده از سه الگوریتم یادگیری عمیق (شامل الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی پیچشی و شبکه عصبی بازگشتی) و با بکارگیری جامع‌ترین متغیرهای اثرگذار بر تقلب در صورت‌های مالی (با بررسی جامع پژوهش داخلی و خارجی انجام شده در حوزه تقلب)، مدلی برای کشف صورت‌های مالی متقلبانه با دقت و کارائی بالا ارائه کرده است که این موضوع در نوع خود منحصر به فرد می‌باشد. از طریق تحلیل اطلاعات مربوط به ۱۵۰ شرکت پذیرفته شده در بورس اوراق بهادر تهران طی سال‌های ۱۳۹۱ تا ۱۴۰۲، نتایج حاصل از الگوریتم‌های یادگیری عمیق نشان می‌دهد که صحّت کلی الگوریتم‌های CNN، SVM و RNN به CNN به ترتیب ۸۸.۴٪، ۸۱.۳٪ و ۹۴.۴٪ می‌باشد که نشان‌دهنده این است الگوریتم RNN بهترین عملکرد و الگوریتم CNN بدترین عملکرد را در کشف شرکت‌های دارای صورت‌های مالی متقلبانه دارد. به عبارت دیگر، نتایج نشان‌دهنده کارآبودن الگوریتم شبکه عصبی بازگشتی نسبت به سایر الگوریتم‌های یادگیری عمیق می‌باشد. بنابراین، در شرکت‌های پذیرفته شده در بورس اوراق بهادر تهران از بین سه الگوریتم CNN، SVM و RNN، الگوریتم RNN کارترین مدل را برای کشف صورت‌های مالی متقلبانه فراهم می‌کند. این نتایج تا حدودی با یافته‌های پژوهش کاظمی و پیری (۱۴۰۱)، بهشتی مسئله‌گو و همکاران (۱۴۰۱)، سیاهکارزاده (۱۴۰۰)، زهیر و همکاران (۲۰۲۳)، علی و همکاران (۲۰۲۳) همخوانی دارد.

نوآوری و دستاوردهای علمی پژوهش حاضر به شرح زیر است: اول، از دیدگاه نظری، با توجه به بررسی پژوهش‌های تجربی صورت گرفته در ایران، این پژوهش اولین موردی است که با استفاده از

الگوریتم حافظه طولانی کوتاه‌مدت، به کشف صورت‌های مالی متقلبانه در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداخته است. دوم، با توجه به اینکه کیفیت و درستی صورت‌های مالی شرکت یکی از متغیرهای کلیدی در تصمیمات سرمایه‌گذاران است، این پژوهش با کشف صورت‌های مالی متقلبانه، با بکارگیری الگوریتم حافظه طولانی کوتاه مدت و سایر الگوریتم‌های یادگیری عمیق، سهامداران، تحلیلگران و اعتباردهنگان را در اتخاذ تصمیمات اثربخش و کارآمد یاری می‌کند و در نتیجه باعث افزایش سطح کارآیی بازار در بلندمدت می‌گردد. سوم، برای نهادهای نظارتی و تدوین‌کنندگان قوانین و استانداردها، مسئله تقلب به ویژه صورت‌های مالی متقلبانه، همواره در کانون توجه بوده است. یافته‌های این پژوهش می‌تواند به سازمان حسابرسی، سازمان بورس و اوراق بهادار و سایر نهادهای نظارتی، رهنما ودهای لازم را در زمینه تدوین قوانین و استانداردها ارائه دهد. چهارماً، نتایج این پژوهش می‌تواند حسابرسان را در زمینه گردآوری شواهد و ارزیابی شواهد یاری کند. در نهایت، یافته‌های این پژوهش می‌تواند ایده‌های جدیدی در اختیار پژوهشگران و دانشگاهیان قرار دهد.

منابع

- احمدی، سید جلال؛ فغانی ماکرانی، خسرو؛ فاضلی، نقی (۱۳۹۹). ارائه مدلی برای پیش‌بینی صورت‌های مالی متقلبانه و مقایسه صورت‌ها و نسبت‌های مالی با قانون بنفورد. دانش حسابداری و حسابرسی مدیریت، ۲۳(۵)، ص ۲۲۱-۲۳۷.
- احمدی، سید جلال؛ فغانی ماکرانی، خسرو؛ فاضلی، نقی (۱۴۰۳). تکنیک‌های داده‌کاوی و پیش‌بینی تقلب صورت‌های مالی. دانش حسابداری و حسابرسی مدیریت، ۵۲(۱۳)، ص ۱۵-۲۸.
- اعتمادی، حسین؛ زلقی، حسن (۱۳۹۲). کاربرد رگرسیون لجستیک در شناسایی گزارشگری مالی متقلبانه. دانش حسابرسی، ۵۱(۱)، ص ۱-۲۶.
- امیرمعزی، حسین؛ پورآقاجان، عباسعلی؛ جعفری، علی (۱۴۰۳). کشف تقلب صورت‌های مالی: قیاس توانایی مدل‌های مبتنی بر متغیرهای حسابداری. دانش حسابداری و حسابرسی مدیریت، ۱۳(۵۲)، ص ۱۷۳-۱۸۸.
- بهشتی مستله‌گو، سیده مژگان؛ افسار کاظمی، محمدعلی؛ حقیقت منفرد، جلال؛ رضاییان، علی (۱۴۰۱). یادگیری عمیق برای پیش‌بینی بازار سهام با استفاده از اطلاعات عددی و متّنی) رویکرد الگوریتم حافظه کوتاه مدت ماندگار. مهندسی مالی و مدیریت اوراق بهادار (پذیرفته شده برای انتشار).
- خواجه‌ی، شکرالله؛ ابراهیمی، مهرداد (۱۳۹۶). ارائه یک رویکرد محاسباتی نوین برای پیش‌بینی تقلب در صورت‌های مالی، با استفاده از شیوه‌های خوش‌بندی و طبقه‌بندی (شواهدی از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران).
- پیشرفتهای حسابداری، ۹(۲)، ص ۱-۲۴.
- رضانی، مهدی؛ ناظمی اردکانی، مهدی؛ ناصر صدرآبادی، علیرضا (۱۴۰۰). پیش‌بینی تقلب صورت‌های مالی با استفاده از رویکرد کریسپ (CRISP). دانش حسابداری و حسابرسی مدیریت، ۱۰(۴۰)، ص ۱۵۰-۱۳۵.
- رضانی، مهدی؛ ناظمی اردکانی، مهدی؛ ناصر صدرآبادی، علیرضا (۱۴۰۰). پیش‌بینی تقلب صورت‌های مالی با استفاده از رویکرد کریسپ (CRISP). دانش حسابداری و حسابرسی مدیریت، ۱۰(۴۰)، ص ۱۳۵-۱۵۰.
- زارعی، علی؛ رهنما رودپشتی، فریدون؛ خان‌محمدی، محمدحامد؛ کردلویی، حمیدرضا (۱۴۰۳). ارائه الگوی پیش‌بینی تقلب مبتنی بر هوش مصنوعی (بیز ساده). مطالعات اخلاق و رفتار در حسابداری و حسابرسی، ۴(۴)، ص ۷-۲۶.
- سیاهکارزاده، علی‌محمد (۱۴۰۰). پیش‌بینی بازارهای مالی با استفاده از یادگیری عمیق. پیان‌نامه کارشناسی ارشد، مهندسی کامپیوتر. دانشگاه صنعتی شاهrood.
- صفرازاده، محمدحسین (۱۳۸۹). توانایی نسبت‌های مالی در کشف تقلب در گزارشگری مالی: تحلیل لاجیت. دانش حسابداری، ۱۱(۱)، ص ۱۳۷-۱۶۳.
- کاظمی، توحید؛ پیری، پرویز (۱۴۰۱). پیش‌بینی طرح تقلب در گزارشگری مالی با استفاده از رویکرد یادگیری ماشین در فضای چند کلاسه. پژوهش‌های تجربی حسابداری، ۱۲(۴۶)، ص ۲۷۶-۲۵۵.
- ملکی کاکلر، حسن؛ بحری ثالث، جمال؛ جبارزاده کنگرلویی، سعید؛ آشتبا، علی (۱۴۰۰). کارایی مدل‌های آماری و الگوهای یادگیری ماشین در پیش‌بینی گزارشگری مالی متقلبانه. اقتصاد مالی، ۱۵(۵۴)، ص ۲۶۷-۲۹۲.
- Albashrawi, M. (2016). Detecting financial fraud using data mining techniques: *J. Data Sci.* no.14, p. 553-569.
- Alfaiz, N.S. & Fati, S.M. (2022). Enhanced Credit Card Fraud Detection Model Using Machine Learning. *Electronics*, no.11, p. 662.
- Alghofaili, Y., Albattah, A., Rassam, M. & Rassam, M. (2020). A Financial Fraud Detection Model

- Based on LSTM Deep Learning Technique. *Journal of Applied Security Research*, 15(4), p. 498–516. <https://doi.org/10.1080/19361610.2020.1815491>.
- Ali, A.A., Khedr, A.M., El-Bannany, M. & Kanakkayil, S. (2023). A Powerful Predicting Model for Financial Statement Fraud Based on Optimized XGBoost Ensemble Learning Technique. *Appl. Sci.* no. 13, p. 2272. <https://doi.org/10.3390/app13042272>
- Alsinglawi, M.M.A.S.M.A.O. & Almari, M.O.S. (2021). Predicting Fraudulent Financial Statements Using Fraud Detection Models. *Acad. Strateg. Manag.* no. 20, p.1–17.
- Amar, I.A.A.B. & Jarboui, A. (2013). Detection of Fraud in Financial Statements: French Companies as a Case Study. *Int. J. Acad. Res. Bus. Soc. Sci.* no. 3, p. 456–472.
- Andrew, C. & Robin, C (2022). Detecting Fraudulent of Financial Statements Using Fraud S.C.O.R.E Model and Financial Distress. *Int. J. Econ. Bus. Account. Res.* no. 6, p. 211–222.
- Asimit, A.V., Kyriakou, I., Santoni, S., Scognamiglio, S. & Zhu, R. (2022). Robust Classification via Support Vector Machines. *Risks*, no.10, p.154.
- Cecchini, M., Aytug, H., Koehler, G.J. & Pathak, P. (2010). Detecting management fraud in public companies. *Manag. Sci.* no. 56, p.1146–1160.
- Chen, S. (2016). Detection of fraudulent financial statements using the hybrid data mining approach. *SpringerPlus*, no. 5, p. 1–16.
- Craja, P., Kim, A. & Lessmann, S. (2020). Deep learning for detecting financial statement fraud. *Decis. Support Syst.* no.139, p.113421.
- Dechow, P., Ge, W., Larson, C. & Sloan, R. (2011). Predicting Material Misstatements. *Contemporary Accounting Research*, 28(1), p. 17-82.
- Deebak, B., Memon, F.H., Dev, K., Khowaja, S.A., Wang, W. & Qureshi, N.M.F. (2022).TAB-SAPP: A trust-aware blockchain-based seamless authentication for massive IoT-enabled industrial applications. *IEEE Trans. Ind. Inform.* No. 19, p. 243250.
- El-Bannany, M., Sreedharan, M. & Khedr, A.M. (2020). A robust deep learning model for financial distress prediction. *Int. J. Adv. Comput. Sci. Appl.* No. 11, p.170–175.
- Gupta, R. & Gill, N.S. (2012). Prevention and detection of financial statement fraud—An implementation of data mining framework. *Editor. Pref.* no 3, p.150–160
- Gupta, S. & Mehta, S.K. (2021). Data mining-based financial statement fraud detection: Systematic literature review and meta-analysis to estimate data sample mapping of fraudulent companies against non-fraudulent companies. *Glob. Bus. Rev.*, 25(2), p. 1–26.
- Hamal, S. & Senvar, Ö. (2021). Comparing performances and effectiveness of machine learning classifiers in detecting financial accounting fraud for Turkish SMEs. *Int. J. Comput. Intell. Syst.* No. 14, p. 769–782.
- Han, D. (2017). Researches of Detection of Fraudulent Financial Statements Based on Data Mining. *J. Comput. Theor. Nanosci.*, no. 14, p. 32–36.
- Humpherys, S.L., Moffitt, K.C., Burns, M.B., Burgoon, J.K. & Felix, W.F. (2011). Identification of fraudulent financial statements using linguistic credibility analysis. *Decis. Support Syst.* No. 50, p. 585–594.

- Jan, Ch. (2021). Detection of Financial Statement Fraud Using Deep Learning for Sustainable Development of Capital Markets under Information Asymmetry. *Sustainability* 13(17), p. 9879.
- Katsis, D.Ch. & et al. (2012). Using Ants to Detect Fraudulent Financial Statements. *Journal of Applied Finance & Banking*, 2(6), p. 73-81.
- Kulikova, L. & Satdarova, D. (2016). Internal control and compliance-control as effective methods of management, detection and prevention of financial statement fraud. *Acad. Strateg. Manag. J.* no. 15, p. 92.
- Kumar, R. & Tripathi, R. (2020). *Secure healthcare framework using blockchain and public key cryptography*. In: Blockchain Cybersecurity, Trust and Privacy; Springer: Cham, Switzerland, p. 185–202.
- Kumar, S., Ahmed, R., Bharany, S., Shuaib, M., Ahmad, T., Tag Eldin, E., Rehman, A.U. & Shafiq, M. (2022). Exploitation of Machine Learning Algorithms for Detecting Financial Crimes Based on Customers' Behavior. *Sustainability*, no.14, p. 13875.
- Lin, C.C., Chiu, A.A., Huang, S.Y. & Yen, D.C. (2015). Detecting the financial statement fraud: The analysis of the differences between data mining techniques and experts' judgments. *Knowl-Based Syst*, no. 89, p. 459–470.
- Moepya, S.O., Akhoury, S.S. & Nelwamondo, F.V. (2014). *Cost-sensitive classification for financial fraud detection under high classimbalance*. In: Proceedings of the 2014 IEEE international conference on data mining workshop, Shenzhen, China, 14–17 December 2014; IEEE: New York, NY, USA, p. 183–192.
- Mohammadi, M., Yazdani, S., Khanmohammadi, M.H. & Maham, K. (2020). Financial reporting fraud detection: An analysis of data mining algorithms. *Int. J. Financ. Manag. Account*, no. 4, p. 1–12.
- Murorunkwere, B.F., Tuyishimire, O., Haughton, D. & Nzabanita, J. (2022). Fraud Detection Using Neural Networks: A Case Study of Income Tax. *Future Internet*, no.14, p. 168.
- Pai, P.F., Hsu, M.F. & Wang, M.C. (2011). A support vector machine-based model for detecting top management fraud. *Knowl-Based Syst*, no. 24, p. 314–321.
- Paulo Sérgio Gomes Macedo, H.C.I. & Vieira, E.S. (2022). A model to detect financial statement fraud in Portuguese companies by the auditor. *Contaduría Adm*, no. 67, p. 185–209.
- Pérez López, C., Delgado Rodríguez, M. & de Lucas Santos, S. Tax Fraud Detection through Neural Networks: An Application Using a Sample of Personal Income Taxpayers. *Future Internet*, no. 11, p. 86.
- Perols, J. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Audit. J. Pract. Theory*, no. 30, p. 19–50.
- Perols, J. (2011). Financial Statement Fraud Detection: An Analysis of Statistical and Machine Learning Algorithms. *A Journal of Practice & Theory*, 30(2), p. 19-50.
- Ravisankar, P., Ravi, V., Rao, G.R. & Bose, I. (2011). Detection of financial statement fraud and feature selection using data mining techniques. *Decis. Support Syst.* No. 50, p. 491–500.
- Rizki, A.A., Surjandari, I. & Wayasti, R.A. (2017). *Data mining application to detect financial fraud*

- in Indonesia's public companies. In: Proceedings of the 2017 3rd International Conference on Science in Information Technology (ICSITech), Bandung, Indonesia, 25–26 October 2017; IEEE: New York, NY, USA, p. 206–211.
- Schreiber-Gregory, D. & Bader, K. (2018). *Logistic and Linear Regression Assumptions: Violation Recognition and Control*. In: Proceedings of the SESUG Conference, St. Pete Beach, FL, USA, p. 1–6.
- Spathis, C., Doumpos, M. & Zopounidis, C. (2002). Detecting falsified financial statements: A comparative study using multicriteria analysis and multivariate statistical techniques. *European Accounting Review*, 11(3), p. 509-535.
- Sreedharan, M., Khedr, A.M. & El Banany, M. (2020). A Multi-Layer Perceptron Approach to Financial Distress Prediction with Genetic Algorithm. *Autom. Control. Comput. Sci.* no. 54, p. 475–482.
- Zaheer, S., Anjum, N., Hussain, S., Algarni, A.D., Iqbal, J., Bourouis, S. & Ullah, S.S. (2023). A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model. *Mathematics*, no.11, p. 590. <https://doi.org/10.3390/math11030590>