



Using convolutional neural networks to model the relationship between institutional investors' horizons and bank risk-taking

Javad Beigy *

Dariusz Fareed **

Gholamreza Askarzadeh ***

Hamid khajehmahmoodabadi ****

Abstract

Introduction: Bank risk-taking is a fundamental component of financial system stability and is shaped by a variety of factors, including ownership structure, shareholder composition, and investor behavior. Among these, the investment horizon of institutional investors—whether short-term or long-term—plays a critical role in determining how banks respond to different types of market risk. Institutional investors with varying horizons adopt distinct approaches to oversight, resource allocation, and responsiveness to market fluctuations, which in turn can have direct implications for banks' risk exposure. Due to the multidimensional and nonlinear nature of the relationship between investment horizon and risk-taking, traditional financial modeling techniques such as linear regression or feedforward neural networks face significant limitations. These models often fail to capture hidden patterns, nonlinear dependencies, and localized features within financial data. Therefore, the primary objective of this study is to utilize Convolutional Neural Networks (CNNs) to more accurately model the relationship between institutional investment horizon and bank risk-taking, using structured financial data from banks listed on the Tehran Stock Exchange.

Method: This research is applied in nature and follows a descriptive-correlational methodology. The statistical population consists of all active banks listed on the

Received: 28 June 2025

Accepted: 17 September 2025

* PhD student, Department of Finance, Yazd Branch, Islamic Azad University, Yazd, Iran.

** Prof, Faculty of Economics, Management and Accounting, Department of Accounting and Finance, University of Yazd, Yazd, Iran. (**Corresponding Author**) E-mail: fareed@yazd.ac.ir

*** Associate Prof, Department of Finance, Yazd Branch, Islamic Azad University, Yazd, Iran.

**** Assistant Prof, Department of Finance, Yazd Branch, Islamic Azad University, Yazd, Iran.

Tehran Stock Exchange between 2014 and 2020. Financial data related to institutional investment horizons (short-term and long-term) and key indicators of bank risk-taking were extracted and transformed into 4×4 matrices to enable convolutional processing. Three CNN architectures were designed and trained, each with a different number of filters: 64, 128, and 256. These models were developed to identify complex patterns and improve predictive accuracy in modeling the target relationship. Model performance was evaluated using standard classification metrics, including Accuracy, F1 Score, and Area Under the Receiver Operating Characteristic Curve (AUC).

Results and Discussion: The results revealed that the correlation between short-term institutional investment horizon and bank risk-taking was 0.86, significantly stronger than the correlation observed for long-term horizons, which was 0.72. This indicates that institutional investors with shorter horizons, due to their heightened responsiveness to market dynamics, play a more effective role in mitigating bank risk. Among the three CNN models, the 64-filter architecture (CNN64) demonstrated the highest predictive performance, achieving an accuracy of 0.829, an F1 score of 0.815, and an AUC of 0.842. This model successfully extracted localized features and identified complex patterns within the financial data, outperforming traditional approaches in both precision and generalizability.

Conclusion: The findings of this study confirm that Convolutional Neural Networks—particularly lightweight configurations such as CNN64—are powerful tools for analyzing complex and nonlinear relationships in financial datasets. Applying CNNs to assess the impact of institutional investment horizons on bank risk-taking not only enhances predictive accuracy but also enables deeper interpretation of market behavior and more informed investment decision-making. The emphasis on short-term horizons as a key factor in reducing bank risk offers practical implications for regulatory policy, risk governance, and strategic asset allocation in the banking sector. Future research is encouraged to explore a broader range of machine learning models, such as decision trees, ensemble methods, and deeper neural networks, and to incorporate macroeconomic variables including interest rates, inflation, and monetary policy into the analytical framework. Moreover, extending the scope of analysis to include international financial markets and longer time horizons will enhance the external validity of the findings and contribute to theoretical advancement in bank risk management.

Keywords: Institutional investor horizon, Bank risk taking, Deep learning network, Convolutional neural networks.

How to Cite: Beigy, J., Fareed, D., Askarzadeh, Gh. and Khajehmahmoodabadi, H. (2025). *Using convolutional neural networks to model the relationship between institutional investors' horizons and bank risk-taking. Financial Management Perspective*, 15(2), 54-80. doi: 10.48308/jfmp.2025.240484.1512 (In Persian).





نوع مقاله: پژوهشی

استفاده از شبکه‌های عصبی کانولوشنالی جهت مدل‌سازی رابطه افق سرمایه گذار نهادی با ریسک‌پذیری بانکی

جواد بیگی *

داریوش فرید **

غلامرضا عسکرزاده ***

حمید خواجه محمود آبادی ****

چکیده

هدف: ریسک‌پذیری بانکی یکی از مؤلفه‌های بنیادین در سنجش پایداری مالی نظام‌های اقتصادی به‌شمار می‌رود و تحت تأثیر عوامل متعددی از جمله ساختار مالکیت، نوع سهامداران و رفتار سرمایه‌گذاران قرار دارد. در این میان، افق سرمایه‌گذاری نهادی—اعم از کوتاه‌مدت یا بلندمدت—می‌تواند نقش تعیین‌کننده‌ای در نحوه مواجهه بانک‌ها با انواع ریسک‌های بازار ایفا کند. سرمایه‌گذاران نهادی با افق‌های متفاوت، رویکردهای گوناگونی در نظارت، تخصیص منابع و واکنش به نوسانات بازار اتخاذ می‌کنند که این تفاوت‌ها می‌تواند پیامدهای مستقیم بر سطح ریسک‌پذیری بانک‌ها داشته باشد. با توجه به پیچیدگی، چندبعدی بودن و غیرخطی بودن رابطه میان افق سرمایه‌گذاری و ریسک‌پذیری، استفاده از مدل‌های سنتی تحلیل مالی نظیر رگرسیون خطی یا شبکه‌های عصبی پیش‌خور با محدودیت‌هایی مواجه است. این مدل‌ها غالباً در شناسایی الگوهای پنهان، روابط غیرخطی و ویژگی‌های محلی داده‌های مالی ناکارآمد هستند. از این‌رو، هدف اصلی پژوهش حاضر، بهره‌گیری از شبکه‌های عصبی کانولوشنالی (CNN) برای مدل‌سازی دقیق‌تر رابطه افق سرمایه‌گذار نهادی با ریسک‌پذیری بانکی در داده‌های ساختاریافته بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران است.

روش: این مطالعه از نوع کاربردی بوده و با رویکرد توصیفی-همبستگی انجام شده است. جامعه آماری شامل کلیه بانک‌های فعال در بورس تهران طی سال‌های ۱۳۹۳ تا ۱۳۹۹ بود. داده‌های مربوط به افق سرمایه‌گذاری نهادی (کوتاه‌مدت و بلندمدت) و شاخص‌های ریسک‌پذیری بانکی استخراج گردید و به‌منظور پردازش توسط شبکه‌های کانولوشنالی، به ماتریس‌های ۴×۴ تبدیل شدند. سه مدل CNN با تعداد فیلترهای ۶۴، ۱۲۸ و ۲۵۶ طراحی و آموزش داده شدند تا عملکرد آن‌ها در شناسایی

تاریخ پذیرش: ۱۴۰۴/۰۶/۲۶

تاریخ دریافت: ۱۴۰۴/۰۴/۰۷

* دانشجوی دکتری، گروه مالی، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران

** استاد، دانشکده اقتصاد، مدیریت و حسابداری، گروه حسابداری و مالی، دانشگاه یزد، یزد، ایران. (نویسنده مسئول). E-Mail: fareed@yazd.ac.ir

*** دانشیار، گروه مالی، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران.

**** استادیار، گروه مالی، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران.

الگوهای پیچیده و پیش‌بینی دقیق‌تر رابطه مورد نظر ارزیابی شود. برای سنجش کیفیت مدل‌ها از معیارهای دقت (Accuracy)، امتیاز F1 و سطح زیر منحنی ROC (AUC) استفاده شد.

یافته‌ها: نتایج حاصل از مدل‌سازی نشان داد که همبستگی میان افق سرمایه‌گذاری کوتاه‌مدت و ریسک‌پذیری بانکی برابر با ۰/۸۶ بوده که به‌مراتب قوی‌تر از همبستگی افق بلندمدت با ریسک‌پذیری (۰/۷۲) است. این یافته حاکی از آن است که سرمایه‌گذاران نهادی با افق کوتاه‌مدت، به دلیل واکنش‌پذیری سریع‌تر نسبت به تغییرات بازار، نقش مؤثرتری در کاهش ریسک‌های بانکی ایفا می‌کنند. از میان سه مدل طراحی‌شده، شبکه ۶۴ فیلتری (CNN64) با دقت ۰/۸۲۹ امتیاز F1 برابر با ۰/۸۱۵ و AUC برابر با ۰/۸۴۲، بالاترین عملکرد را در مدل‌سازی رابطه مورد نظر داشت. این مدل توانست با استخراج ویژگی‌های محلی و شناسایی الگوهای پیچیده در داده‌های مالی، عملکردی به‌مراتب بهتر از مدل‌های سنتی ارائه دهد و اثربخشی شبکه‌های کانولوشنالی در تحلیل‌های مالی را به اثبات رساند.

نتیجه‌گیری: پژوهش حاضر نشان داد که شبکه‌های عصبی کانولوشنالی، به‌ویژه در ساختارهای سبک‌تر مانند CNN64، ابزار قدرتمندی برای تحلیل روابط پیچیده و غیرخطی در داده‌های مالی هستند. استفاده از این مدل‌ها در تحلیل افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی، نه تنها دقت پیش‌بینی را افزایش می‌دهد، بلکه امکان تفسیر بهتر رفتار بازار، شناسایی الگوهای پنهان و اتخاذ تصمیمات سرمایه‌گذاری آگاهانه‌تر را فراهم می‌سازد. تمرکز بر افق کوتاه‌مدت به‌عنوان عامل مؤثر در کاهش ریسک‌های بانکی، می‌تواند راهگشای تدوین سیاست‌های نظارتی، طراحی ابزارهای کنترلی و توسعه راهبردهای سرمایه‌گذاری هوشمندانه‌تر در صنعت بانکداری باشد. پیشنهاد می‌شود در مطالعات آتی، از مدل‌های یادگیری ماشین متنوع‌تری مانند درخت‌های تصمیم‌گیری، مدل‌های تصادفی و شبکه‌های عمیق‌تر استفاده شود و تأثیر عوامل کلان اقتصادی نظیر نرخ بهره، تورم و سیاست‌های پولی نیز در تحلیل‌ها لحاظ گردد. همچنین، گسترش دامنه تحقیق به سایر بازارهای مالی، نمونه‌های بین‌المللی و بازه‌های زمانی بلندمدت می‌تواند به تعمیم‌پذیری نتایج، افزایش اعتبار بیرونی و توسعه نظری در حوزه مدیریت ریسک بانکی کمک شایانی نماید.

کلیدواژه‌ها: افق سرمایه‌گذار نهادی؛ ریسک‌پذیری بانکی؛ شبکه یادگیری عمیق؛ شبکه‌های عصبی کانولوشنی.

استناد دهی: بیگی، جواد، فرید، داریوش، عسکرزاده، غلامرضا و خوابه محمود آبادی، حمید. (۱۴۰۴). استفاده از شبکه‌های عصبی کانولوشنالی جهت مدل‌سازی رابطه افق سرمایه‌گذار نهادی با ریسک‌پذیری بانکی. چشم‌انداز مدیریت مالی، ۱۵(۳)، ۵۴-۸۰.



۱. مقدمه

همسو با رشد اقتصادی و بزرگ شدن واحدهای تجاری از قدرت کنترل سهامداران در عمل کاسته شده است، چرا که پراکندگی ساختار مالکیت بیشتر شده و اکثر مالکان را سهامداران جزء تشکیل می‌دهند در چنین حالتی تنها تعداد اندکی از سهامداران این امکان را می‌یابند تا در انتخاب اعضای هیأت مدیره و همچنین مدیر عامل نقشی را ایفا نمایند [۲]. این مشکل زمانی حادتر خواهد شد که انگیزه بیشتر سهامداران سرمایه‌گذاری در شرکت‌ها برای کسب سود دیدگاه کوتاه مدت) باشد تا اینکه کنترل شرکت دیدگاه بلندمدت را بدست گیرند. آنگاه تنها سد دفاعی سهامداران در مقابل مشکلات نمایندگی ایجاد تنوع در پرتفوی های سرمایه‌گذاری خواهد بود و یا اینکه در نهایت پس از زیان‌های غیر قابل جبران، سرمایه‌گذاری در آن شرکت را به فروش رسانند. در چنین نظامی بدون حضور سهامداران نهادی حاکمیت شرکت‌ها بصورت کنترل نشده در اختیار مدیریت است [۵]. در واقع همه مسئولیت‌ها بر دوش مدیران شرکت نهاده می‌شود که در این میان، نقش بالاترین مقام اجرایی (مدیرعامل) برجسته‌تر است. به تدریج و با توجه به بحران‌های مالی شرکت‌های سرمایه‌پذیر لزوم ایجاد نظام جدیدی از حاکمیت شرکت‌ها احساس شد. از مهم‌ترین معیارهای کنترلی حاکمیت شرکتی حضور سهامداران نهادی در شرکت است. در بیشتر نظام نامه‌های حاکمیت شرکتی بر حضور آنها در جهت افزایش منافع سهامداران تاکید شده است. گزارش‌های حاکمیت شرکتی حاکی از آن است که سهامداران نهادی به علت درصد بالای مالکیت خود توانایی اعمال کنترل بر اقدامات شرکت را دارند پتانسیلی که به ندرت برای سهامداران کوچک وجود دارد [۲۶].

سرمایه‌گذاران نهادی موسسه‌هایی هستند که به خرید و فروش حجم بالایی از اوراق بهادار می‌پردازند. طبق تعریف سرمایه‌گذاران نهادی سرمایه‌گذاران بزرگ نظیر بانک‌ها، شرکت‌های بیمه، شرکت‌های سرمایه‌گذاری و موسسه‌های بازنشستگی هستند. سرمایه‌گذاران نهادی معمولاً به دلیل در اختیار داشتن درصد قابل توجهی از سهام شرکت‌ها و همچنین حرفه‌ای بودن در امر سرمایه‌گذاری، توان و انگیزه لازم برای نظارت بر شرکت‌ها را دارا می‌باشند [۱۳]. عموماً این گونه تصور می‌شود که حضور سرمایه‌گذاران نهادی ممکن است به تغییر رفتار و عملکرد شرکت منجر شود. این امر از فعالیت‌های نظارتی که این سرمایه‌گذاران انجام می‌دهند نشأت می‌گیرد [۴۴]. سرمایه‌گذاران نهادی به واسطه دسترسی به منابع عظیم مالی، نقش مهمی در توسعه اقتصادی بازار سرمایه ایفا می‌کنند به علاوه هر روز بر اهمیت نقش نظارتی سرمایه‌گذاران نهادی افزوده می‌شود زیرا آنها بسیار بزرگ و با نفوذ شده‌اند و در عین حال تمرکز مالکیت قابل ملاحظه‌ای را به دست آورده‌اند. این سرمایه‌گذاران یکی از گروه‌های اصلی فعال در بازار هستند که می‌توانند از طریق انجام معاملات عمده تأثیر شگرفی بر سمت و سوی حرکت بازار داشته باشند [۱۸]. به علاوه ساختار منسجم سازمانی و شبکه پیچیده مالکانه آنها، تمایز این گروه را بیشتر نمایان می‌کند. آنان به نیابت از گستره وسیعی از مالکان و با اتکا به توان تحلیل بالای خود، تصمیمات آگاهانه‌تر و منطقی‌تری در مقایسه با سرمایه‌گذاران ناآگاه اتخاذ کرده روند بهبود کارایی بازار را تسریع کرده و عملکرد تخصیص منابع توسط بازار را بهبود می‌بخشند [۱۵]. با توجه به اهمیتی که سرمایه‌گذاران نهادی در توسعه بازارهای سرمایه دارند، توجه به افق سرمایه‌گذار نهادی در ارزیابی ریسک‌پذیری بانک‌ها از ضرورت‌های سنجش بازار سرمایه است. بررسی تأثیر افق سرمایه‌گذاری نهادی بر ریسک‌پذیری در صنعت بانکداری به چند دلیل حائز اهمیت است. اول، اصلاحات نظارتی انجام شده در پاسخ به بحران بانکی ۲۰۰۷-۲۰۰۹ با هدف بهبود حاکمیت بانک از طریق توانمندسازی سهامداران برای نظارت دقیق‌تر بر مدیران بانک‌ها می‌باشد [۱۹]. بخش بانکداری یک موقعیت جذاب برای مطالعه ریسک‌پذیری شرکت‌ها و پیامدهای آن ارائه می‌دهد و فشار سهامداران بر بانک‌ها برای افزایش سود کوتاه‌مدت خود از طریق تمرکز بر ریسک‌پذیری به این موضوع کمک می‌کند. سوم، در مقایسه با شرکت‌های غیرمالی، بانک‌ها به دلیل ماهیت پیچیده کسب‌وکار، در اختیار داشتن اطلاعات خصوصی مشتریان و دارایی‌های بانکی که عمدتاً مالی هستند، غیرشفاف‌تر هستند. این عدم

شفافیت در بانک‌ها فرصت‌هایی را برای رفتار مخدوش فراهم می‌کند. بنابراین، شناسایی نوع سهامدارانی که به طور بالقوه می‌توانند در چنین محیط غیرشفاف بانکی به عنوان ناظر واگذار شوند، ضروری است [۳۳].

حضور سرمایه‌گذاران نهادی در بازارهای مالی، به‌ویژه در بخش بانکی، نقش کلیدی در کاهش ریسک‌پذیری و بهبود حاکمیت شرکتی ایفا می‌کند. با این حال، تأثیر افق سرمایه‌گذاری نهادی (کوتاه‌مدت در مقابل بلندمدت) بر ریسک‌پذیری بانکی کمتر مورد توجه قرار گرفته است، به‌ویژه در بازارهای نوظهور مانند بورس اوراق بهادار تهران. پژوهش‌های پیشین عمدتاً بر تأثیر کلی مالکیت نهادی بر ریسک یا ارزش شرکت تمرکز داشته‌اند، اما استفاده از روش‌های پیشرفته یادگیری عمیق، مانند شبکه‌های عصبی کانولوشنی، برای مدل‌سازی رابطه بین افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی به‌ندرت بررسی شده است. نوآوری این پژوهش در بهره‌گیری از شبکه‌های عصبی کانولوشنی برای تحلیل داده‌های مالی با ساختار جدولی و شناسایی الگوهای غیرخطی در رابطه بین افق سرمایه‌گذاری و ریسک‌پذیری بانکی است. این رویکرد امکان استخراج ویژگی‌های پیچیده و محلی از داده‌ها را فراهم می‌کند که در روش‌های سنتی، مانند رگرسیون خطی، قابل دستیابی نیست. علاوه بر این، تمرکز بر داده‌های بانک‌های پذیرفته‌شده در بورس تهران در بازه زمانی ۱۳۹۳ تا ۱۳۹۹، این پژوهش را به اولین مطالعه‌ای تبدیل می‌کند که این رابطه را در بستر بازار ایران با استفاده از شبکه‌های عصبی کانولوشنی بررسی می‌کند. این مطالعه با پر کردن شکاف موجود در کاربرد روش‌های یادگیری عمیق در تحلیل مالی و ارائه شواهد تجربی از تأثیر افق کوتاه‌مدت بر کاهش ریسک‌پذیری بانکی، به ادبیات این حوزه کمک می‌کند. لذا با توجه به اهمیت موضوع این پژوهش به دنبال استفاده از شبکه‌های عصبی کانولوشنی جهت مدل‌سازی رابطه افق سرمایه‌گذار نهادی با ریسک‌پذیری بانکی می‌باشد.

۲. مبانی نظری و پیشینه پژوهش

سرمایه‌گذاری نهادی: سرمایه‌گذاری نهادی به معنای سرمایه‌گذاری از سوی نهادها و سازمان‌های دولتی و غیردولتی می‌باشد. این نهادها و سازمان‌ها با هدف ایجاد تعادل در بازار سرمایه و همچنین بهره‌مندی از امکانات سرمایه‌گذاری برای دستیابی به اهداف خود، به سرمایه‌گذاری در بازار سرمایه می‌پردازند. بسیاری از نهادها و سازمان‌های دولتی و غیردولتی در سراسر جهان سرمایه‌گذاری نهادی انجام می‌دهند، از جمله بانک‌های مرکزی، صندوق‌های سرمایه‌گذاری، صندوق‌های بازنشستگی، صندوق‌های خیریه، بیمارستان‌ها، موسسات آموزشی و پژوهشی و سازمان‌های دولتی مانند صندوق تأمین اجتماعی. سرمایه‌گذاری نهادی معمولاً به دلیل داشتن منابع مالی بالا، می‌تواند به رقابت با سرمایه‌گذاران حرفه‌ای در بازار سرمایه کمک کند و با توجه به اندازه و تنوع سرمایه‌گذاری‌هایش، به طور موثری بر روی بازار سرمایه تأثیر بگذارد. سرمایه‌گذاری نهادی به عنوان یکی از روش‌های سرمایه‌گذاری، به دو صورت مستقیم و غیرمستقیم انجام می‌شود. سرمایه‌گذاری مستقیم به معنای خرید سهام یا اوراق بهادار مستقیماً توسط نهادها و سازمان‌های دولتی و غیردولتی است. به عنوان مثال، بانک مرکزی می‌تواند به صورت مستقیم سهام شرکت‌های دارایی را خریداری کند. در سرمایه‌گذاری غیرمستقیم، نهادها و سازمان‌ها به صورت سرمایه‌گذاری در صندوق‌های سرمایه‌گذاری، صندوق‌های بازنشستگی و سایر صندوق‌های سرمایه‌گذاری شرکت می‌کنند. این صندوق‌ها به عنوان یک واسطه، سرمایه‌گذاری را در معاملات بازار سرمایه و بخش سرمایه‌گذاری به کار می‌برند. این نوع سرمایه‌گذاری غالباً به عنوان یک راه ساده‌تر و کم‌هزینه‌تر برای دسترسی به بازار سرمایه استفاده می‌شود. سرمایه‌گذاری نهادی می‌تواند به عنوان یک ابزار موثر برای رشد اقتصاد و ایجاد شغل در یک کشور مورد استفاده قرار گیرد. سرمایه‌گذاری نهادی معمولاً به دلیل داشتن منابع مالی بالا، می‌تواند به رقابت با سرمایه‌گذاران حرفه‌ای در بازار سرمایه کمک کند و با توجه به اندازه و تنوع سرمایه‌گذاری‌هایش، به طور موثری بر روی بازار سرمایه تأثیر بگذارد. به طور کلی، سرمایه‌گذاری نهادی یکی از

روش‌های مهم سرمایه‌گذاری است که می‌تواند به بهبود شرایط اقتصادی و مالی جامعه کمک کند و در بسیاری از کشورها، جزء سیاست‌های دولتی برای توسعه اقتصادی و بهبود شرایط زندگی مردم محسوب می‌شود [۲].

سرمایه‌گذاری نهادی و خصوصی: تفاوت اصلی بین سرمایه‌گذاری نهادی و سرمایه‌گذاری خصوصی در منشأ سرمایه‌گذاری است. در سرمایه‌گذاری خصوصی، سرمایه‌گذاری توسط افراد حقیقی یا حقوقی در بازار سرمایه انجام می‌شود، در حالی که در سرمایه‌گذاری نهادی، سرمایه‌گذاری توسط نهادها و سازمان‌های دولتی و غیردولتی انجام می‌شود. یکی دیگر از تفاوت‌های بین سرمایه‌گذاری نهادی و سرمایه‌گذاری خصوصی، در اهداف سرمایه‌گذاری آنها است. در حالی که سرمایه‌گذاران خصوصی به دنبال کسب سود و بازدهی بالاتر هستند، سرمایه‌گذاری نهادی معمولاً به دلیل هدف‌های اجتماعی و اقتصادی انجام می‌شود، مانند ایجاد شغل، توسعه صنایع، نوآوری، توسعه فناوری، ارتقای سطح زندگی و بهبود شرایط اقتصادی و اجتماعی جامعه. در نتیجه، سرمایه‌گذاری نهادی معمولاً به دلیل داشتن منابع مالی بالا، می‌تواند به رقابت با سرمایه‌گذاران حرفه‌ای در بازار سرمایه کمک کند و با توجه به اندازه و تنوع سرمایه‌گذاری‌هایش، به طور موثری بر روی بازار سرمایه تأثیر بگذارد. از سوی دیگر، سرمایه‌گذاری خصوصی معمولاً به دلیل اهداف تجاری و سودآوری انجام می‌شود و می‌تواند به رشد اقتصادی و کسب و کارهای خصوصی کمک کند. تفاوت‌های دیگر بین سرمایه‌گذاری نهادی و سرمایه‌گذاری خصوصی عبارتند از: الف) ریسک: سرمایه‌گذاری نهادی معمولاً دارای ریسک کمتری نسبت به سرمایه‌گذاری خصوصی است، زیرا نهادها و سازمان‌های دولتی و غیردولتی برای سرمایه‌گذاری خود از منابع مالی پایدار و بلند مدت برخوردارند. در عین حال، سرمایه‌گذاری خصوصی ممکن است با ریسک‌های بیشتری همراه باشد، زیرا سرمایه‌گذاران خصوصی معمولاً از منابع مالی کوتاه مدت استفاده می‌کنند و با شرایط بازار سرمایه روبرو می‌شوند.

ب) هدف: همانطور که قبلاً گفته شد، هدف سرمایه‌گذاری نهادی معمولاً به بهبود شرایط اجتماعی و اقتصادی جامعه، ایجاد شغل و توسعه صنایع مرتبط با آن مربوط است. از طرف دیگر، هدف سرمایه‌گذاری خصوصی بیشتر به تولید سود و بازدهی بالا مرتبط است.

ج) تأثیر: سرمایه‌گذاری نهادی معمولاً تأثیرات بلند مدت و عمیقی بر جامعه دارد، زیرا هدف آن به بهبود شرایط اجتماعی و اقتصادی جامعه مربوط است. از طرف دیگر، سرمایه‌گذاری خصوصی عمدتاً به تولید سود برای سرمایه‌گذاران خود ارتباط دارد و تأثیر آن بر جامعه به طور مستقیم کمتر است.

د) کنترل: سرمایه‌گذاران خصوصی معمولاً بر کنترل کامل سرمایه‌گذاری خود تمرکز دارند و تصمیم‌گیری‌های آنها برای سودآوری به عنوان اولویت اصلی آنها محسوب می‌شود. در مقابل، در سرمایه‌گذاری نهادی، تصمیم‌گیری‌ها ممکن است تحت تأثیر حسابداری اجتماعی و مسئولیت اجتماعی قرار گیرند و اهداف اجتماعی و فرهنگی نیز در تصمیم‌گیری‌ها مدنظر قرار می‌گیرند [۲۱]. سرمایه‌گذاری نهادی می‌تواند در چندین سبک صورت بگیرد. در زیر به برخی از این سبک‌ها اشاره شده است:

الف) سرمایه‌گذاری در بنیادهای خیریه و انجمن‌های مردم نهاد: این سبک از سرمایه‌گذاری نهادی معمولاً در اهداف انسان دوستانه و خیریه مشغول است. بنیادهای خیریه و انجمن‌های مردم نهاد معمولاً از منابع مالی حاصل از سرمایه‌گذاری‌های نهادی برای حمایت از اهداف خیریه و اجتماعی استفاده می‌کنند.

ب) سرمایه‌گذاری در شرکت‌های دارای هدف اجتماعی: این سبک از سرمایه‌گذاری نهادی در شرکت‌هایی که هدف اجتماعی را در کنار هدف سودآوری دارند، انجام می‌شود. این شرکت‌ها معمولاً به دنبال بهبود شرایط اجتماعی و اقتصادی جامعه هستند و برای این منظور، به کارگیری مدیریت مسئولیت اجتماعی، استفاده از منابع مالی برای اهداف اجتماعی و زیست‌محیطی و توسعه فناوری‌های نوین را در دستور کار خود قرار می‌دهند.

ج) سرمایه‌گذاری در شرکت‌های شراکتی: این سبک از سرمایه‌گذاری نهادی در شرکت‌هایی صورت می‌گیرد که به صورت شراکتی توسط چندین نهاد و سازمان دولتی و غیردولتی تأسیس شده‌اند. این شرکت‌ها معمولاً به دنبال ارائه خدمات و محصولاتی با کیفیت بالا هستند که می‌توانند به بهبود شرایط اقتصادی و اجتماعی جامعه کمک کنند.

د) سرمایه‌گذاری در پروژه‌های عمومی: این سبک از سرمایه‌گذاری نهادی در پروژه‌های عمومی مانند احداث مدارس، بیمارستان‌ها، جاده‌ها و پل‌ها صورت می‌گیرد. این پروژه‌ها معمولاً توسط دولت و سازمان‌های عمومی انجام می‌شوند و سرمایه‌گذاری نهادی می‌تواند به آنها کمک کند تا به صورت بهتر و سریع‌تری اجرا شوند.

ه) سرمایه‌گذاری در شرکت‌های دارای هدف اجتماعی-مالی: در این سبک از سرمایه‌گذاری نهادی، شرکت‌هایی توسط نهادها و سازمان‌های دولتی و غیردولتی تأسیس می‌شوند که به همان اندازه که به تولید سود برای سهامداران خود اهمیت می‌دهند، به بهبود شرایط اجتماعی و محیطی نیز توجه دارند.

و) سرمایه‌گذاری در بنیادهای اقتصادی: در این سبک از سرمایه‌گذاری نهادی، نهادها و سازمان‌های دولتی و غیردولتی سعی می‌کنند با تأسیس بنیادهای اقتصادی، افراد و کسب‌وکارهای کوچک و متوسط را به کسب و کار و توسعه فعالیت‌های اقتصادی تشویق کنند.

ز) سرمایه‌گذاری در پروژه‌های فناوری: در این سبک از سرمایه‌گذاری نهادی، نهادها و سازمان‌های دولتی و غیردولتی به پروژه‌های فناوری و نوآوری سرمایه‌گذاری می‌کنند. این پروژه‌ها معمولاً به توسعه فناوری‌های نوین، تحقیق و توسعه در زمینه‌های بحران آب، برق و انرژی، سلامت و بهداشت، تولید پایدار و محیط زیست و... مربوط هستند.

ح) سرمایه‌گذاری در پروژه‌های حمایت از کشاورزی و بوم‌شناسی: در این سبک از سرمایه‌گذاری نهادی، نهادها و سازمان‌های دولتی و غیردولتی به پروژه‌های حمایت از کشاورزی و بوم‌شناسی سرمایه‌گذاری می‌کنند. این پروژه‌ها می‌توانند شامل توسعه کشاورزی پایدار، مدیریت منابع آب و خاک، توسعه صنایع دستی و توریسم بومی و... باشند.

از طرف دیگر، سرمایه‌گذاری نهادی می‌تواند در انواع دیگری از پروژه‌های اقتصادی و اجتماعی نیز انجام شود که به دلایل مختلفی مانند نیاز به سرمایه‌گذاری بلندمدت، حمایت از صنایع کوچک و متوسط، توسعه پایدار و محیط زیست و... صورت می‌گیرد. به طور کلی، سرمایه‌گذاری نهادی به عنوان یکی از راه‌های مهم تأمین منابع مالی برای توسعه اقتصادی و اجتماعی در کشورهای مختلف، به کار گرفته می‌شود [۴].

میزان سرمایه‌گذاری نهادی در هر کشور و منطقه متفاوت است و به عوامل مختلفی مانند سیاست‌های دولتی، شرایط اقتصادی، نیازهای اجتماعی و فرهنگی، وجود زیرساخت‌های لازم و... بستگی دارد. با این حال، از طریق آمارها و داده‌های موجود می‌توان به برخی اطلاعات درباره میزان سرمایه‌گذاری نهادی در جهان دست یافت. برای مثال، گزارش سال ۲۰۲۱ سازمان ملل متحد نشان می‌دهد که میزان سرمایه‌گذاری نهادی در سال ۲۰۲۰ به حدود ۱۷۰ میلیارد دلار رسیده است. همچنین، در برخی کشورها مثل کانادا، سرمایه‌گذاری نهادی به عنوان یکی از راه‌های تأمین منابع مالی برای توسعه اقتصادی و اجتماعی، به طور فزاینده‌ای در حال افزایش است. بنابراین، میزان سرمایه‌گذاری نهادی بستگی به شرایط مختلفی دارد و نمی‌توان به طور کلی به آن پاسخ دقیقی داد. در چندین کشور سرمایه‌گذاری نهادی به طور فزاینده‌ای در حال افزایش است. برخی از کشورهایی که میزان سرمایه‌گذاری نهادی در آن‌ها افزایش یافته عبارتند از: الف) کانادا: در سال ۲۰۲۰، سرمایه‌گذاری نهادی در کانادا به میزان ۱۰ میلیارد دلار رسیده بود که نسبت به سال ۲۰۱۸ با افزایش ۱۷ درصدی همراه بود.

ب) ایالات متحده آمریکا: در سال ۲۰۲۰، سرمایه‌گذاری نهادی در ایالات متحده آمریکا به میزان ۴۳۸ میلیارد دلار رسیده بود که نسبت به سال ۲۰۱۸ با افزایش ۲۹ درصدی همراه بود.

ج) انگلستان: در سال ۲۰۲۰، سرمایه‌گذاری نهادی در انگلستان به میزان ۱۱۴ میلیارد دلار رسیده بود که نسبت به سال ۲۰۱۸ با افزایش ۲۵ درصدی همراه بود.

د) آلمان: در سال ۲۰۲۰، سرمایه‌گذاری نهادی در آلمان به میزان ۶۵ میلیارد دلار رسیده بود که نسبت به سال ۲۰۱۸ با افزایش ۲۴ درصدی همراه بود.

ه) فرانسه: در سال ۲۰۲۰، سرمایه‌گذاری نهادی در فرانسه به میزان ۳۳ میلیارد دلار رسیده بود که نسبت به سال ۲۰۱۸ با افزایش ۱۰ درصدی همراه بود [۴].

توسعه سرمایه‌گذاری نهادی در این کشورها و همچنین در کشورهای دیگر، بهبود شرایط اقتصادی و اجتماعی و توسعه پایدار کمک می‌کند. نکته‌ای که باید به آن توجه داشت این است که سرمایه‌گذاری نهادی در هر کشور به عوامل مختلفی مانند سیاست‌های دولتی، شرایط اقتصادی، نیازهای اجتماعی و فرهنگی، وجود زیرساخت‌های لازم و... بستگی دارد. با این حال، برخی از عواملی که می‌تواند به افزایش سرمایه‌گذاری نهادی در کشورهایی که اشاره کردید، منجر شده باشد، عبارتند از:

الف) نیازهای اجتماعی و محیطی: در کشورهایی مانند کانادا، ایالات متحده، انگلستان و فرانسه، نیازهای اجتماعی و محیطی افراد و جوامع رو به افزایش است. سرمایه‌گذاری نهادی در این زمینه‌ها می‌تواند به بهبود شرایط اجتماعی و محیطی کمک کند.

ب) تمرکز بر توسعه پایدار: توسعه پایدار برای بسیاری از کشورها به یکی از اولویت‌های اصلی توسعه اقتصادی تبدیل شده است. سرمایه‌گذاری نهادی در پروژه‌هایی که به توسعه پایدار کمک می‌کنند، می‌تواند به افزایش سرمایه‌گذاری نهادی در کشورهایی که اشاره کردید، منجر شود.

ج) افزایش توانایی‌های فنی و فناوری: توسعه تکنولوژی و فناوری، بهبود شرایط زندگی و توسعه اقتصادی را در کشورهای مختلف به همراه دارد. بنابراین سرمایه‌گذاری نهادی در پروژه‌های فناوری و نوآوری، می‌تواند به افزایش سرمایه‌گذاری نهادی در کشورهایی که اشاره کردید، کمک کند.

د) حمایت از کسب و کارهای کوچک و متوسط: سرمایه‌گذاری نهادی در بنیادهای اقتصادی و پروژه‌های حمایت از کسب و کارهای کوچک و متوسط، می‌تواند به افزایش سرمایه‌گذاری نهادی در کشورهایی که اشاره کردید، منجر شود. بنابراین، افزایش سرمایه‌گذاری نهادی در کشورهایی که اشاره کردید، به عوامل مختلفی بستگی دارد و به بهبود شرایط اقتصادی و اجتماعی و توسعه پایدار کمک می‌کند [۴].

افق سرمایه‌گذاری نهادی به مدت زمانی اشاره دارد که یک سرمایه‌گذار نهادی برای سرمایه‌گذاری در یک شرکت یا پروژه مشخص می‌کند. هر سرمایه‌گذار نهادی، برای سرمایه‌گذاری خود در نظر دارد که مدت زمانی که سرمایه‌گذاری خود را در یک شرکت یا پروژه نگه می‌دارد، چه طولی باشد. افق سرمایه‌گذاری نهادی معمولاً برای سرمایه‌گذاری در شرکت‌ها و پروژه‌های بلندمدت تعیین می‌شود و معمولاً بیشتر از یک سال است. در برخی شرکت‌ها و پروژه‌هایی که نیاز به سرمایه‌گذاری بلندمدت دارند، افق سرمایه‌گذاری نهادی ممکن است چند سال یا حتی چند دهه باشد. افق سرمایه‌گذاری نهادی برای سرمایه‌گذاران نهادی بسیار مهم است زیرا آن‌ها به دنبال بازدهی بلندمدت هستند و نمی‌توانند به دنبال بازدهی کوتاه‌مدت بروند. برای مثال، صندوق‌های بازنشستگی و بنیادها معمولاً برای سرمایه‌گذاری خود افق سرمایه‌گذاری نهادی بلندمدتی را در نظر می‌گیرند. در کل، افق سرمایه‌گذاری نهادی به مدت زمانی اشاره دارد که یک سرمایه‌گذار نهادی برای سرمایه‌گذاری در یک شرکت یا پروژه مشخص می‌کند. افق سرمایه‌گذاری نهادی برای سرمایه‌گذاران نهادی بسیار مهم است زیرا آن‌ها به دنبال بازدهی بلندمدت هستند و نمی‌توانند به دنبال بازدهی کوتاه‌مدت بروند [۳۲]. افق سرمایه‌گذاری نهادی می‌تواند به دو دسته بلندمدت و کوتاه‌مدت تقسیم شود:

الف) افق سرمایه‌گذاری نهادی بلندمدت: در این حالت، سرمایه‌گذار نهادی برای سرمایه‌گذاری خود در یک شرکت یا پروژه، مدت زمان طولانی‌تری را در نظر می‌گیرد و معمولاً بیشتر از یک سال است. سرمایه‌گذاران نهادی بلندمدت به

دنبال بازدهی بلندمدت هستند و در نتیجه، به دنبال پروژه‌ها و شرکت‌هایی هستند که قابلیت رشد و سودآوری بلندمدت را دارند.

ب) افق سرمایه‌گذاری نهادی کوتاه‌مدت: در این حالت، سرمایه‌گذار نهادی برای سرمایه‌گذاری خود در یک شرکت یا پروژه، مدت زمان کوتاه‌تری را در نظر می‌گیرد و معمولاً کمتر از یک سال است. سرمایه‌گذاران نهادی کوتاه‌مدت به دنبال بازدهی سریع و سودآوری در کوتاه‌مدت هستند و بیشتر به پروژه‌ها و شرکت‌هایی که در کوتاه‌مدت سودآوری بالایی دارند، علاقه دارند.

در کل، افق سرمایه‌گذاری نهادی بلندمدت برای سرمایه‌گذارانی که به دنبال بازدهی بلندمدت هستند، مناسب است و به دلیل طولانی بودن مدت سرمایه‌گذاری، این نوع سرمایه‌گذاری معمولاً با بازدهی بلندمدت و پایدار همراه است. اما سرمایه‌گذاران کوتاه‌مدت به دنبال بازدهی سریع و کوتاه‌مدت هستند و بیشتر به پروژه‌ها و شرکت‌هایی که در کوتاه‌مدت بازدهی بالایی دارند، علاقه دارند. در نهایت، افق سرمایه‌گذاری نهادی باید با استراتژی و هدف سرمایه‌گذاری سازگار باشد [۲۳].

ریسک‌پذیری بانک‌ها به میزان توانایی بانک در مقابله با ریسک‌های مالی و عدم قطعیت‌های بازار اشاره دارد. به عبارت دیگر، ریسک‌پذیری بانک‌ها به توانایی آن‌ها در مقابله با ریسک‌های مالی و عدم قطعیت‌های بازار، از جمله ریسک‌های اعتباری، ریسک نقدینگی، ریسک بازار، ریسک عملیاتی و ریسک حقوقی، اشاره دارد. با توجه به اینکه بانک‌ها با توجه به نوع فعالیت‌هایشان، در معرض ریسک‌های مختلفی قرار دارند؛ بنابراین توانایی مدیریت ریسک‌های مالی و عدم قطعیت‌های بازار برای آن‌ها بسیار حیاتی است. ریسک‌پذیری بانک‌ها در واقع نشان‌دهنده این است که بانک‌ها توانایی مدیریت ریسک‌های مختلف را دارند و در صورت بروز ریسک، می‌توانند به طور موثری مدیریت و کنترل آن را بر عهده بگیرند. برای افزایش ریسک‌پذیری بانک‌ها، می‌توان از روش‌های متنوعی استفاده کرد. از جمله این روش‌ها می‌توان به تقویت سرمایه، بهره‌گیری از فناوری‌های پیشرفته، بهبود فرآیندها و ساماندهی منابع، تحلیل ریسک‌های مختلف، پایش و کنترل ریسک‌ها، مدیریت ریسک بازار، مدیریت ریسک نقدینگی و مدیریت ریسک عملیاتی اشاره کرد. به طور کلی، ریسک‌پذیری بانک‌ها به عنوان یکی از مهم‌ترین مؤلفه‌های موفقیت در عملکرد بانک‌ها، برای اطمینان از پایداری و اطمینان مشتریان، حائز اهمیت است. برای افزایش ریسک‌پذیری بانک، باید از روش‌های مدیریت ریسک‌های مختلف استفاده کرد و بانک باید به طور مداوم برای بهبود روش‌های مدیریت ریسک خود تلاش کند [۱۴].

پیشینه پژوهش: تاکنون پژوهش‌ها مختلفی با هدف بررسی رابطه‌ی افق سرمایه‌گذاری نهادی با ریسک‌پذیری بانکی انجام شده است. صراف و همکاران (۱۴۰۱) در پژوهشی تاثیر افق مالکیت نهادی بر مسئولیت اجتماعی و ارزش سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران را مورد بررسی قرار دادند. نتایج نشان داد که افق مالکیت نهادی بلندمدت بر مسئولیت اجتماعی و ارزش سهام شرکت‌ها تاثیر مثبت و معنادار دارد [۳۸]. در پژوهشی دیگر، بنایی‌قدیم و رحمانی فرد (۱۴۰۰) به بررسی تاثیر مشکلات نمایندگی بر رابطه بین افق زمانی کوتاه مدت سرمایه‌گذار نهادی و ریسک سقوط قیمت سهام پرداختند. نتایج این پژوهش نشان داد که، افق زمانی کوتاه‌مدت سرمایه‌گذار نهادی بر ریسک سقوط قیمت سهام تاثیر مثبت و معنی‌داری دارد [۶]. نوابی‌ف و همکاران (۱۴۰۰) در پژوهشی به ارتباط بین ریسک سقوط قیمت سهام و سرمایه‌گذاری نهادی با بازده سهام با تاکید بر نقش تعدیلی نسبت نقدینگی در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداختند. نتایج پژوهش نشان داد بین ریسک سقوط قیمت سهام و بازده سهام ارتباط معکوس و معناداری وجود دارد [۲۹]. عنایت‌پور شیباده و همکاران (۱۳۹۹) در پژوهشی به سنجش تاثیر مالکیت نهادی بر ارزش و ریسک شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران اقدام کردند. نتایج حاصله حاکی از آن است که، مالکیت نهادی تاثیر معناداری بر ارزش و ریسک شرکت دارد [۱۲]. همچنین صادقی گورچی و

همکاران (۱۳۹۵) در پژوهشی به سنجش تاثیر سرمایه گذار نهادی مختلف بر ریسک سقوط قیمت سهام در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداختند. نتایج این تحقیق نشان داد که بین انواع سرمایه گذار نهادی و ریسک سقوط قیمت سهام ارتباط معناداری وجود دارد [۳۷].

پیلی و پوشپا لاتا^۱ (۲۰۲۵) با هدف شناسایی تقلب‌های درون‌سازمانی در نظام‌های بانکی، یک مدل ترکیبی مبتنی بر یادگیری ژرف طراحی کردند که از شبکه عصبی پیچشی و حافظه بلندمدت بهره می‌برد. در این پژوهش، داده‌های مربوط به تراکنش‌های بانکی شامل الگوهای رفتاری غیرعادی و نمونه‌های تقلب شبیه‌سازی شده با استفاده از ابزارهای تحلیل داده پیش‌پردازش شدند. شبکه عصبی پیچشی برای استخراج ویژگی‌های مکانی از داده‌های ساختاریافته و حافظه بلندمدت برای مدل‌سازی وابستگی‌های زمانی به کار گرفته شد. نتایج نشان داد که مدل ترکیبی یادگیری ژرف در تشخیص الگوهای پنهان و غیرخطی رفتاری عملکرد بسیار بالایی دارد و نسبت به روش‌های سنتی مانند ماشین بردار پشتیبان و جنگل تصادفی، بهبود قابل توجهی ارائه می‌دهد [۳۴]. لی و همکاران^۲ (۲۰۲۴) با هدف توسعه یک مدل یادگیری عمیق برای ارزیابی ریسک بانکی، از شبکه عصبی کانولوشنی (CNN) جهت تحلیل رفتار سرمایه‌گذاران نهادی استفاده کردند. در این پژوهش، داده‌های ساختاری شامل تراکنش‌های بانکی، جریان سرمایه نهادی، و شاخص‌های نوسان‌پذیری مالی به‌عنوان ورودی مدل به کار رفتند. CNN توانست ویژگی‌های غیرخطی و پنهان در داده‌ها را استخراج کرده و الگوهای رفتاری مرتبط با ریسک را شناسایی کند. نتایج نشان داد که سرمایه‌گذاران با افق کوتاه‌مدت، ریسک‌پذیری بانک‌ها را افزایش می‌دهند، در حالی که سرمایه‌گذاران بلندمدت با کاهش نوسان‌پذیری و بهبود ثبات مالی همراه هستند [۲۷].

بینتی احمد و بینتی ازهار^۳ (۲۰۲۲) به بررسی اثرات فعالیت سرمایه‌گذاران نهادی بر فعالیت‌های ریسک‌پذیر شرکتی پرداختند. نتایج نشان داد که سرمایه‌گذاران نهادی فعال می‌توانند نقش خود را با نظارت برای کاهش سرمایه‌گذاری غیرضروری ریسک توسط شرکت‌ها ایفا کنند [۸]. هاجینسون و همکاران^۴ (۲۰۲۱) رابطه سرمایه‌گذاران نهادی، ریسک، عملکرد و حاکمیت شرکتی را مورد مطالعه قرار داد و نتایج نشان داد که بین ریسک خاص شرکت، سیاست مدیریت ریسک و عملکرد برای شرکت‌هایی با افزایش سهام نهادی ارتباط مثبتی وجود دارد [۲۰]. کیم^۵ و همکاران (۲۰۲۱) در پژوهشی به بررسی ناهمگونی سرمایه‌گذار نهادی و پویایی قیمت بازار با شواهدی از افق سرمایه‌گذاری و تمرکز پرتفوی پرداختند. محققین بیان داشتند که موسسات ناهمگونی قابل توجهی در رفتار معاملاتی از خود نشان می‌دهند [۲۳]. پاتان و همکاران^۶ (۲۰۲۰) به بررسی افق سرمایه‌گذار نهادی و ریسک‌پذیری بانکی پرداختند و نتایج نشان داد که نتایج ما نشان می‌دهد که تنظیم‌کننده‌های بانکی باید نسبت به اقدامات بانک‌هایی که به شدت به سهامداری کوتاه‌مدت متکی هستند، هوشیارتر باشند [۳۳]. نی^۷ و همکاران (۲۰۲۰) در پژوهش خود اقدام به بررسی رابطه ریسک سرمایه‌گذاران نهادی و سقوط قیمت سهام پرداختند. با استفاده از بازده شدید شرکت‌ها در صنایع غیرمرتبط پرتفوی سهامداران نهادی به عنوان تغییرات برون‌زا در حواس پرتی سرمایه‌گذاران نهادی، محققین یک رابطه مثبت و معنادار بین ریسک سهامداران نهادی و ریسک سقوط قیمت سهام وجود دارد [۳۰].

در پژوهش‌های بررسی شده اقدام به بررسی رابطه‌ی افق سرمایه‌گذاری نهادی با ریسک‌پذیری بانکی شده است و تاکنون پژوهشی اقدام به مدلسازی رابطه میان این دو متغیر نکرده است. مدلسازی افق سرمایه‌گذار نهادی بر ریسک‌پذیری بانکی می‌تواند نقش مهمی در سنجش ریسک به عنوان یکی از مشخصه‌های اصلی بازارهای سرمایه داشته

1 Pillai & Pushpa Latha

2 Li et al.

3 Binti Ahmad and Binti Azhari

4 Hutchinson

5 Kim

6 Pathan

7 Ni

باشد. روندهای اخیر در بازارهای بورس نیاز به تکنیک‌های مدل‌سازی و شبیه‌سازی را که بتوانند ارائه‌دهنده و نمایشگر دقیق، موثر و موثقی برای مسائل پیچیده، غیرخطی و پویا برای سرمایه باشد، را افزایش داده است. در این میان مدل‌های شبکه‌های عصبی مصنوعی سازگاری رضایت بخشی با مسائل مذکور دارند و امتیازات خاص خود را نسبت به روش‌های سنتی دارا هستند. در این پژوهش از شبکه‌های عصبی یادگیری عمیق برای مدل‌سازی افق سرمایه گذار نهادی بر ریسک پذیری بانکی استفاده شده است. یادگیری عمیق عبارت است از ساخت مدل‌های یادگیری ماشین که برای یادگیری نمایشی سلسله مراتبی از داده‌ها به کار می‌روند. شبکه‌های عصبی عمیق، اصطلاحی کلی برای مجموعه‌ای از شبکه‌های عصبی با معماری چند لایه است که نشان می‌دهند چگونه شبکه‌های عصبی با تعداد زیادی از لایه‌ها می‌توانند در ایجاد ساختارهای بازنمایی مورد نیاز در یادگیری عمیق موفق عمل کنند. الگوریتم‌های یادگیری ویژگی به صورت ناظر و بدون ناظر می‌توانند در تنظیم وزن‌های این شبکه‌ها به کار گرفته شوند و در واقع انواع گوناگونی از شبکه‌های عصبی عمیق موجودند از جمله شبکه‌های کد گذار خودکار^۱، شبکه‌های عصبی کانولوشن^۲، شبکه‌های عصبی عود کننده^۳، شبکه‌های عصبی بازگشتی^۴، ماشین‌های یادگیری بولتزمن و شبکه‌های باور عمیق. از همین رو، با توجه اهمیت به کارگیری روش‌های دقیق در این مدل‌سازی و بررسی‌ها، در این پژوهش‌ها از شبکه‌های عصبی یادگیری عمیق از نوع شبکه‌های عصبی کانولوشن (CNN) استفاده شد.

۳. روش‌شناسی پژوهش

روش پژوهش حاضر برحسب زمان وقوع پدیده، آینده‌نگر؛ برحسب نتیجه، تصمیم‌گرا؛ برحسب هدف، کاربردی؛ برحسب زمان اجرای پژوهش، مقطعی؛ برحسب نوع داده، کمی؛ برحسب روش گردآوری داده‌های پژوهش، توصیفی-همبستگی است. روش پژوهش حاضر از نوع ماهیت، یک روش نظری است. جامعه آماری این پژوهش کلیه بانک‌های پذیرفته شده در بورس اوراق بهادار تهران می‌باشند که از ابتدای سال ۱۳۹۳ لغایت تا پایان سال ۱۳۹۹ در بورس فعال بوده‌اند. برای انتخاب نمونه آماری مناسب که یک نماینده مناسبی برای جامعه آماری موردنظر باشد از روش حذفی سیستماتیک استفاده شده است. برای این منظور ۴ معیار در نظر گرفته شد. معیارهای مذکور عبارت‌اند از: الف) سال مالی بانک‌های موردبررسی منتهی به پایان اسفندماه باشد (به دلیل یکسان بودن شرایط سال مالی شرکت‌ها و عملیات آن‌ها)؛ ب) جزء بانک‌های سرمایه‌گذاری و واسطه‌گری مالی و مؤسسات مالی و اعتباری نباشد (به دلیل یکسان بودن ماهیت عملیات شرکت‌ها)؛ ج) شرکت موردنظر طی دوره پژوهش فعالیت مستمر داشته و سهام آن مورد معامله قرار گرفته باشد (به دلیل اصل تداوم فعالیت و معامله شدن سهام آن‌ها)؛ د) در دوره تحقیق تغییر سال مالی نداشته باشد. متغیر وابسته در این پژوهش، متغیر ریسک‌پذیری (Z-score) است. مطابق با پژوهش منظور حسن و همکاران (۲۰۲۰) جهت ریسک‌پذیری بانک‌ها از رابطه زیر استفاده شده است:

(۱)

$$(Z - score)_{i,t} = \ln \left(\frac{\mu ROA_{i,t} + CAR_{i,t}}{\sigma(ROA)_{i,t}} \right)$$

که در رابطه فوق؛ μROA میانگین بازده دارایی‌ها در سه سال اخیر، CAR نسبت کفایت سرمایه و نیز سیگما سه‌ساله بازده دارایی‌های بانک است. شاخص Z میزان ثبات بانک را نشان می‌دهد و معکوس آن احتمال ورشکستگی را بیان می‌کند (لیون و لون، ۲۰۰۸). مقادیر بالای شاخص Z نشان‌دهنده ریسک پایین و ثبات بالا برای بانک بوده و مقادیر پایین آن نیز حاکی از ثبات پایین و ریسک‌پذیری بالا است. متغیر مستقل در این پژوهش، افق سرمایه گذار

¹ Auto-Encoder

² Convolutional Neural Networks

³ Recurrent Neural Networks

⁴ Recursive Neural Networks

نهادی است. مالکیت سهامداران نهادی با دو بعد سرمایه‌گذاران با افق دید کوتاه مدت و بلند مدت به عنوان متغیر مستقل پژوهش حاضر در نظر گرفته شد. بدین منظور ابتدا مجموع مالکیت نهادی براساس پژوهش‌های گومپرز^۱ و همکاران (۲۰۰۳) به صورت نسبت تعداد سهام نزد سهامداران نهادی به کل سهام منتشر شده تعریف می‌گردد. از طرفی مالکیت سرمایه‌گذاران در دو طبقه کوتاه مدت و بلند مدت طبقه‌بندی شده‌اند که این دسته بندی به علت نگرش سهامداران در موقعیت‌های مختلف تصمیم‌گیری صورت می‌پذیرد. بنابراین مجموع خرید و فروش هر سرمایه گذار به صورت رابطه ۲ و ۳ تعریف می‌گردد:

$$CR_{buy_{j,t}} = \sum_{i \in Q, N_{j,i,t} > N_{j,i,t-1}} |N_{j,i,t} p_{i,t} - N_{j,i,t-1} p_{t-1} - N_{j,i,t} \Delta p_{i,t}| \quad (2)$$

$$CR_{sell_{j,t}} = \sum_{i \in Q, N_{j,i,t} \leq N_{j,i,t-1}} |N_{j,i,t} p_{i,t} - N_{j,i,t-1} p_{t-1} - N_{j,i,t} \Delta p_{i,t}| \quad (3)$$

که در آن:

$CR_{buy_{j,t}}$: مجموع خرید سرمایه گذار j ام در سه ماهه ام t ام (فصل t ام). $CR_{sell_{j,t}}$: مجموع تعداد سهام موجودی دسته i که توسط سرمایه گذار j ام در پایان سه ماهه t ام منتشر شده یا به عبارتی مجموع فروش‌های سرمایه گذار j ام برای فصل t ام می باشد. $p_{i,t}$: قیمت سهام و $N_{i,t}$: تعداد سهام می باشد. اگر تعداد سهام فصل جاری بیش تر از فصل قبل باشد، خرید سرمایه گذار و اگر تعداد سهام فصل جاری کمتر از فصل قبل باشد فروش سرمایه گذار محاسبه می گردد. حال برای سنجش افق سرمایه‌گذاران نهادی لازم است نرخ ریزش هر سرمایه گذار محاسبه شود به شرح رابطه ۴ محاسبه می‌گردد.

$$CR_{j,t} = \frac{\min(CR_{buy_{j,t}}, CR_{sell_{j,t}})}{\frac{N_{j,i,t} p_{i,t} + N_{j,i,t-1} p_{t-1}}{2}} \quad (4)$$

در محاسبه نرخ ریزش برای کاهش اثر جریان‌های نقدی سرمایه گذار در کل پرتفوی دبايد کمترین مقدار (خرید یا فروش) در نظر گرفته شود. بنابراین نرخ ریزش عبارت است از نسبت دکمترین مقدار مجموع سهام خریداری شده یا فروخته شده بر میانگین حاصل ضرب تعداد سهام در قیمت سهام دو فصل اخیر سرمایه گذار (لازم به ذکر است که در هر سال برای هر سرمایه گذار در طی چهار فصل نرخ ریزش به همین ترتیب محاسبه می گردد). پس از محاسبه نرخ ریزش، برای تعیین افق سرمایه‌گذاران نهادی در دو گروه کوتاه‌مدت و بلندمدت، میانگین نرخ ریزش با استفاده از رابطه زیر محاسبه می‌شود:

$$AVG - CR_{j,t} = \frac{1}{4} \sum_{r=1}^4 CR_{j,t-r+1} \quad (5)$$

بعد از محاسبه میانگین نرخ ریزش ($AVG - CR_{j,t}$) سرمایه‌گذاران بر اساس مقدار مذکور در سه پرتفوی طبقه‌بندی می شوند. در صورتی که در پرتفوی بالایی قرار بگیرند یعنی بالاترین میانگین نرخ ریزش را دارا باشند (بیشتر از ۸۰٪) درصد سهامداران نهادی به عنوان شاخص افق سهامداران نهادی کوتاه مدت $SHINST - INV_{i,t}$ در نظر گرفته می شود و برای سرمایه‌گذارانی که در پرتفوی پایینی قرار می گیرند. در این رابطه، سرمایه‌گذاران بر اساس میانگین نرخ ریزش در سه پرتفوی طبقه‌بندی می‌شوند. سرمایه‌گذارانی که در پرتفوی بالایی (نرخ ریزش بیش از ۸۰ درصد) قرار گیرند، به عنوان سهامداران نهادی کوتاه‌مدت و سرمایه‌گذارانی که در پرتفوی پایینی (نرخ ریزش کمتر از ۲۰ درصد) قرار گیرند، به عنوان سهامداران نهادی بلندمدت در نظر گرفته می‌شوند. این طبقه‌بندی امکان تحلیل دقیق‌تر

¹ Gompers

تأثیر افق سرمایه‌گذاری بر ریسک‌پذیری بانکی را فراهم می‌کند. در مطالعه حاضر چهار متغیر اندازه شرکت، اهرم مالی و نرخ بازده دارایی‌ها به عنوان متغیر کنترلی پژوهش در نظر گرفته شد که به شرح زیر محاسبه می‌گردند [۳۳]:

$SIZE_{i,t}$: اندازه شرکت با استفاده از لگاریتم طبیعی فروش شرکت i در سال t محاسبه می‌گردد.

$LEV_{i,t}$: از حاصل نسبت جمع کل بدهی‌های شرکت به کل دارایی‌های شرکت برآورد می‌شود.

$ROA_{i,t}$: با استفاده از حاصل نسبت سود خالص به ارزش دفتری کل دارایی‌های شرکت بدست می‌آید.

شبکه‌های یادگیری عمیق: مدل‌های یادگیری عمیق با تجزیه و تحلیل مداوم داده‌ها و با کشف ساختارهای پیچیده در داده‌ها یادگیری را فرامی‌گیرند. فرآیند یادگیری با ساخت مدل‌های محاسباتی به نام شبکه‌های عصبی که از ساختار مغز الهام گرفته شده، حاصل می‌شود. ساختار این شبکه از چندین لایه پردازشی تشکیل شده است. یادگیری عمیق، به دنبال بهره‌وری از ساختار ناشناخته در توزیع ورودی، به منظور کشف بازنمایی خوب توسط ساختاری سلسله مراتبی از مفاهیم که همان لایه‌های پردازشی هستند، می‌باشد. در این ساختار با رفتن به لایه‌های سطح بعدی، قادر به حل مفاهیم پیچیده‌تری از مسئله می‌شود. لایه‌های اولیه داده‌های خام را پردازش و لایه‌های بعدی قادر به استفاده از اطلاعات نرون‌های موجود در لایه‌های قبلی جهت به دست آوردن اطلاعات پیچیده‌تر از داده‌ها را فراهم می‌سازند. به عنوان مثال، در پردازش یک تصویر، لایه‌ی ورودی هر یک پیکسل از تصویر را پردازش می‌کند. لایه‌های بعدی گروهی از پیکسل‌ها را پردازش و اطلاعاتی از داده‌ها را به دست می‌آورند. لایه‌های اولیه ممکن است متوجه شوند که برخی پیکسل‌ها تاریک‌تر از بقیه هستند، حال آنکه لایه‌های بعدی ممکن است متوجه شوند که از گروهی پیکسل‌ها ساختار چشم به نظر را نشان می‌دهد، و لایه‌ای خیلی عمیق متوجه شود که کل یک تصویر مربوط به یک انسان است. یادگیری عمیق این امکان را می‌دهد، تا داده‌های خام را به بردار تبدیل کرده و به شبکه تغذیه کرد بدون اینکه استخراج ویژگی را به صورت دستی روی این داده‌ها انجام داد. یادگیری عمیق این استخراج ویژگی‌ها را حتی بهتر از یک متخصص توسط تعداد لایه‌های مختلفی که در ساختارش وجود دارد، در جهت حل مسئله موردنظر بر مبنای داده‌های آموزشی مربوط به مسئله انجام می‌دهد. این لایه‌ها می‌توانند به صورت مستقیم و به تنهایی نمایشی انتزاعی از داده‌های خام را بیاموزند. مزیت بزرگ یادگیری عمیق، این است که با حجم زیادی از داده‌ها تأمین می‌شود. مدل‌های یادگیری عمیق با افزایش مقدار داده‌های آموزشی میل به افزایش دقت دارند. در مقابل، مدل‌های سنتی یادگیری ماشین، پس از یک نقطه اشباع، مدل دیگر بهبودی را به همراه ندارد. یکی از مهم‌ترین تفاوت‌های که یادگیری عمیق را در تقابل با یادگیری ماشین قرار می‌دهد، عملکرد سیستم بر اساس افزایش تعداد نمونه‌های آموزشی است. یادگیری عمیق در صورت عدم وجود نمونه‌های آموزشی کافی نتایج مطلوبی را به همراه نخواهند داشت. در مقابل یادگیری ماشین می‌تواند با تعداد نمونه‌های کم هم نتایج خوبی را از خود نشان دهد. همچنین استفاده از یادگیری عمیق نیاز به سخت‌افزارهای پیشرفته داشته، حال آنکه یادگیری ماشین می‌تواند با سخت‌افزار و رایانه‌هایی با قدرت پایین هم قابل استفاده باشد [۴۲].

شبکه عصبی یادگیری عمیق کانولوشنی: شبکه عصبی یادگیری عمیق کانولوشنی یا شبکه‌های عصبی کانولوشنی یکی از پرکاربردترین شبکه‌های عصبی یادگیری عمیق هستند. برای برخی از انواع داده‌ها به ویژه تصاویر، شبکه‌های پیش‌خور کارکرد خوبی ندارند. همان‌طور که پیش‌تر بیان شد، در شبکه‌های پیش‌خور هر نرون به‌طور کامل به هر یک از نرون‌های موجود در لایه بعدی متصل است. به‌طور دقیق‌تر، هر نرون در لایه پنهان تابعی را محاسبه می‌کند که به مقادیر هر گره در لایه ورودی وابسته می‌باشد. به‌طور کلی، یک شبکه عصبی کانولوشنی از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از: (الف) لایه کانولوشن؛ (ب) لایه پولینگ؛ (ج) لایه تماماً متصل [۲۸].

¹ Pooling

² Fully Connected

در هر شبکه عصبی کانولوشنی، دو مرحله برای آموزش وجود دارد. مرحله تغذیه روبه‌جلو و مرحله پس انتشار. در مرحله اول تصویر ورودی به شبکه تغذیه می‌شود و این عمل چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه نیست. سپس خروجی شبکه محاسبه می‌شود. در اینجا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. برای این کار، خروجی شبکه را با استفاده از یک تابع خطا با پاسخ صحیح مقایسه کرده و از این طریق میزان خطا محاسبه می‌شود. در مرحله بعدی بر اساس میزان خطای محاسبه‌شده، مرحله پس انتشار آغاز می‌شود. در این مرحله گرادیانت هر پارامتر با توجه به قانون زنجیره‌ای محاسبه می‌شود و تمامی پارامترها با توجه به تأثیری که بر خطای ایجادشده در شبکه دارند تغییر پیدا می‌کنند. بعد از به هنگام شدن پارامترها، مرحله بعدی (تغذیه روبه‌جلو) شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد [۱۱]. در شبکه‌های عصبی کانولوشنی یک کاستی پولینگ ماکزیمم این است که نسبت به $Overfitting$ مجموعه آموزشی حساس بوده و تعمیم را سخت می‌کند. باهدف حل این مشکل، ذیلر^۱ و همکاران (۲۰۱۳) روش پولینگ تصادفی را پیشنهاد داد که در آن عملیات قطعی پولینگ با یک رویه اتفاقی جایگزین می‌شود. این رویه اتفاقی، انتخاب تصادفی مقادیر در داخل هر ناحیه پولینگ، بر اساس یک توزیع چندجمله‌ای است. این عملیات شبیه پولینگ ماکزیمم استاندارد با تعداد زیادی کپی از تصویر ورودی است که هرکدام تغییر شکل محلی کوچکی دارند. طبیعت تصادفی بودن برای جلوگیری از مشکل $Overfitting$ مفید بوده و به همین دلیل از آن در این روش استفاده شده است [۳ و ۲۵]. یکی از فواید یادگیری عمیق با شبکه‌های عصبی کانولوشنی این است که می‌توان معماری‌های عمیق را جهت یادگیری اطلاعات انتزاعی در ایجاد نمود. اما تعداد بسیار زیاد پارامترهای معرفی شده ممکن است سبب مشکل $Overfitting$ شود. اخیر روش‌های تنظیم زیادی در مقابله با $Overfitting$ ارائه شده است، مثل روش پولینگ تصادفی که در قبل به آن اشاره کردیم. در این بخش ما چند فن و روش تنظیم را که سبب بهبود کارایی شبکه می‌شود را معرفی می‌کنیم. دقت کنید که الزاماً تمامی تکنیک‌های معرفی شده در این بخش، خاص شبکه‌های عصبی کانولوشنی نیستند. یعنی این تکنیک‌ها قابل اعمال در شبکه‌های عصبی مصنوعی سنتی نیز هستند (مثل شیوه (Dropout) [۲۲]).

فن Dropout توسط هینتن^۲ و همکاران (۲۰۱۲) ارائه شد و توسط بالدی^۳ و همکاران (۲۰۱۳) نیز به صورت کامل توضیح داده شد. روش Dropout به منظور جلوگیری از $Overfitting$ معرفی شد و نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون یا با احتمال $P(-1)$ از شبکه بیرون انداخته شده و یا با احتمال P نگه‌داشته می‌شود، به طوری که نهایتاً یک شبکه کاهش داده شده باقی بماند. یال‌های ورودی و خروجی به یک گره بیرون انداخته شده نیز حذف می‌شوند. این گونه تنها شبکه کاهش یافته بر روی داده‌ها، در آن مرحله آموزش خواهد دید. بعد از این کار، گره‌های حذف شده به همراه وزن‌های سابق آن‌ها (قبل از حذف شدن) دوباره به درون شبکه وارد می‌شوند. وارد فارلی^۴ و همکاران (۲۰۱۲) در تحقیقات خود بهینگی Dropout ها را مورد تحلیل قرارداد و نهایتاً عنوان کرد که Dropout یک شیوه یادگیری گروهی بسیار مؤثر است. یک نمونه معروف مشتق شده از Dropout به DropConnect معروف است که به صورت تصادفی وزن‌ها را بجای مقادیر فعال سازی حذف می‌کند. آزمایش‌ها نشان دادند که این روش می‌تواند پایاپای و حتی بهتر از روش Dropout در انواع گوناگونی از ارزیابی‌های مقایسه‌ای استاندارد عمل کند، هرچند با سرعت کمتر [۷]. اگرچه شبکه‌های عصبی کانولوشنی (CNN) به طور سنتی برای

¹ Zeiler² Hinton³ Baldi⁴ Warde-Farley

داده‌های با ساختار شبکه‌ای مانند تصاویر طراحی شده‌اند، کاربرد آن‌ها در تحلیل داده‌های مالی، به‌ویژه داده‌های جدولی و سری زمانی، در مطالعات اخیر رو به افزایش بوده است [۲۳].

در این پژوهش، داده‌های مالی شامل متغیرهای افق سرمایه‌گذاری نهادی (نرخ ریزش، نسبت مالکیت) و شاخص ریسک‌پذیری بانکی (Z-score) به‌صورت ماتریس‌های 4×4 بازسازی شدند تا امکان استفاده از عملیات کانولوشن فراهم شود. این تبدیل با هدف شناسایی الگوهای محلی و روابط غیرخطی بین متغیرها انجام شد، زیرا CNNها در استخراج ویژگی‌های محلی از داده‌های با ساختار منظم (مانند ماتریس‌های بازنمایی‌شده) عملکرد بهتری نسبت به شبکه‌های پیشخور سنتی دارند. به‌طور خاص، هر ماتریس 4×4 شامل مقادیر نرمال‌شده متغیرهای مالی (مانند نرخ ریزش، نسبت کفایت سرمایه، و بازده دارایی‌ها) برای یک بازه زمانی سه‌ماهه بود که به‌صورت یک ساختار شبکه‌ای سازمان‌دهی شد. لایه‌های کانولوشن با فیلترهای 3×3 برای شناسایی الگوهای محلی در این ماتریس‌ها و لایه‌های MaxPooling با اندازه 4×4 برای کاهش ابعاد و حفظ ویژگی‌های کلیدی استفاده شدند. این رویکرد با الهام از مطالعات اخیر در تحلیل داده‌های مالی با CNN انتخاب شد، زیرا امکان مدل‌سازی روابط پیچیده بین متغیرهای مالی را با دقت بالا فراهم می‌کند.

شاخص‌های ارزیابی مدل: از آنجا که خروجی مدل‌های شبکه عصبی کانولوشنی در این پژوهش به‌صورت دو نورون تعریف شده است (افق سهامداری کوتاه‌مدت و بلندمدت)، این مسئله به‌عنوان یک طبقه‌بندی دودویی در نظر گرفته می‌شود. بنابراین، معیارهای ارزیابی شامل دقت (Accuracy)، امتیاز F1 (F1-score)، و سطح زیر منحنی راک (AUC-ROC) برای سنجش عملکرد مدل‌ها استفاده شدند [۴۳].

۴. تحلیل داده‌ها و یافته‌ها

در مرحله اول از مدل‌سازی رابطه بین افق سرمایه‌گذار نهادی و ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران، اطلاعات پس از دسته‌بندی، هموار شدند. هدف از هموارسازی اطلاعات مرتبط با داده‌های پژوهش این است که داده‌هایی که در یک دسته موجود هستند و از میانگین هر دسته فاصله (انحراف) زیادی دارند، به‌عنوان داده نامناسب حذف می‌گردند و یا با یک ضریب وزنی (w_{ij}^h) مورد استفاده قرار می‌گیرند. در رابطه ۹، که برای هموارسازی داده‌ها استفاده شده است، بازه‌های مربوط به ضریب وزنی (w) به‌صورت کامل تعریف نشده بود. برای رفع این ابهام، رابطه ۹ به‌صورت زیر اصلاح شده و بازه بین $0/2$ و $0/4$ نیز به‌صراحت تعریف می‌شود:

$$\text{If } |x_{i,d,j}-x_{id}| > 0.4 \text{ then } w=0; \quad \text{if } 0.2 \leq |x_{i,d,j}-x_{id}| \leq 0.4 \text{ then } w=0.5; \quad \text{If } |x_{i,d,j}-x_{id}| < 0.2 \text{ then } w=1 \quad (9)$$

در این رابطه، $x_{i,d,j}$ نشان‌دهنده j امین داده از متغیرهای دسته i ام در سال d ام، x_{id} میانگین متغیرهای دسته i ام در سال d ام است. برای بازه $0.2 \leq |x_{i,d,j}-x_{id}| \leq 0.4$ ، ضریب وزنی $0/5$ انتخاب شده است تا داده‌هایی با انحراف متوسط همچنان با وزن کاهش‌یافته در تحلیل حفظ شوند [۴۵]. نتایج هموارسازی داده‌ها نشان داد که $90/7\%$ داده‌ها از سطوح همواری مناسبی برخوردار بودند و به عنوان داده‌های مورد استفاده برای انجام فرآیند تحلیل استفاده شدند. در حالی که $9/3\%$ داده‌ها از سطوح همواری مناسب برخوردار نبودند و از ادامه فرآیند مدل‌سازی حذف گردیدند. به‌طور کلی نتایج هموارسازی داده‌ها نشان داد که داده‌های مورد استفاده از میزان همواری بسیار مناسبی برخوردار بودند. **مدل‌سازی رابطه افق سرمایه‌گذار نهادی با ریسک‌پذیری بانکی از طریق شبکه‌های عصبی کانولوشنی (CNN):** روند داده‌های مورد استفاده در CNN مشابه با شبکه‌های عصبی پیشخور انجام شد. به‌طور مشابه، یادگیری پارامترهای شبکه توسط الگوریتم پس انتشار و بهینه‌سازی گردایان کاهشی تصادفی صورت گرفت. فاز اول انجام شده در فرایند مدل‌سازی با شبکه CNN برای داده‌های رابطه بین افق سرمایه‌گذار نهادی کوتاه مدت و بلند

مدت با ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران، انتشار جلورو می باشد، جایی که سیگنال ها از ورودی شبکه به خروجی انتشار یافتند. در آخرین لایه، خروجی توسط تابع هزینه با مقدار دلخواه مقایسه و برآورد خطا صورت می گیرد. در فاز دوم، مجدداً از الگوریتم پس انتشار برای جبران این خطا استفاده شد [۴۱]. شبکه عصبی کانولوشنی از انواع مختلفی لایه ها تشکیل شده و فاز انتشار جلورو و پس انتشار خطا از قوانین ویژه ای در هر لایه پیروی می کنند. نرون ها در شبکه عصبی کانولوشنی بر خلاف شبکه عصبی پیشخور که هر نرون دارای یک بردار وزن جداگانه هستند، وزنی مشترک دارند. این اشتراک وزن ها منجر به کاهش تعداد کلی وزن های قابل آموزش می شود [۹].

انتشار جلورو در لایه کانولوشنی: اولین مرحله در فرآیند مدلسازی با شبکه عصبی کانولوشنی، انجام فرآیند انتشار جلورو در لایه کانولوشنی بود. هر لایه کانولوشنی، بر روی ورودی های خود در حال انجام عملگر کانولوشنی است [۳۹]. در این پژوهش ورودی های به شبکه یک لایه 4×4 و هسته آن 3×3 باشد. انتشار جلورو در لایه کانولوشنی پژوهش حاضر بدون استفاده از دنباله گذاری صفر و با اندازه $(4-3+1) \times (4-3+1)$ و محاسبه کانولوشنی خروجی x_{ij}^l به صورت رابطه زیر به دست آمد:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y^{l-1}(i+a)(j+b) \quad (۱۱)$$

جایی که $l, i, j \in (0, n-m+1)$ شاخص لایه فعلی، ω_{ab} وزن هسته و $y^{l-1}(i+a)(j+b)$ خروجی لایه قبلی می باشد. سپس، خروجی لایه کانولوشنی y_{ij}^l با اعمال یک تابع فعالسازی غیرخطی بر روی خروجی کانولوشنی x_{ij}^l محاسبه شد که نتیجه این محاسبه در رابطه زیر گزارش شده است:

$$y_{ij}^l = \sigma(x_{ij}^l) \quad (۱۲)$$

جایی که σ یک تابع فعالسازی غیر خطی است [۱].

پس انتشار خطا در لایه کانولوشنی: در این پژوهش، از کتابخانه TensorFlow (نسخه ۲.۸) در محیط Python (نسخه ۳.۹) برای پیاده سازی شبکه های عصبی کانولوشنی استفاده شد. مدل های کانولوشنی با تعداد فیلترهای ۶۴، ۱۲۸ و ۲۵۶ با استفاده از معماری های تعریف شده در بخش ۴ پیاده سازی شدند. تنظیمات پارامترهای کلیدی شامل نرخ یادگیری ۰/۰۰۱، بهینه ساز آدام، تابع هزینه Categorical Cross-Entropy، اندازه دسته (Batch Size) برابر با ۳۲، و تعداد دوره های آموزشی (Epochs) برابر با ۱۰۰ بود. برای جلوگیری از بیش برآزش، از تکنیک Dropout با نرخ ۰/۲ در لایه های تماماً متصل استفاده شد. این تنظیمات بر اساس آزمایش های اولیه و استانداردهای رایج در مدل سازی داده های مالی انتخاب شدند تا تعادل مناسبی بین دقت و پایداری مدل ایجاد شود [۱۷]. پس انتشار خطا در لایه کانولوشنی مرحله دوم از فرآیند مدلسازی مرتبط با داده های پژوهش است. این مرحله هم از همان اصول الگوریتم پس انتشار پیروی می کند. تنها تفاوت در این است که هسته کانولوشنی وزن کل لایه را به اشتراک می گذارد و هسته دارای بایاس نیست. مقدار تابع خطا در این پژوهش برابر با E در نظر گرفته شد [۲۴]. با توجه به مقدار خطا در لایه کانولوشنی و مشتق جزئی خطای لایه قبلی با توجه به هر خروجی نرون $\frac{\partial E}{\partial y_{ij}^l}$ باشد، تاثیر وزن هسته بر تابع هزینه محاسبه شد که نتایج آن در رابطه زیر نشان داده شده است:

$$\frac{\partial E}{\partial \omega_{ab}} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{ij}^l} \frac{\partial x_{ij}^l}{\partial \omega_{ab}} \quad (۱۳)$$

از آنجایی که در مرحله انتشار جلورو در لایه کانولوشنی رابطه زیر به دست آمد:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y^{l-1}(i+a)(j+b) \quad (۱۴)$$

این نتیجه حاصل شد که:

$$\frac{\partial x_{ij}^l}{\partial w_{ab}} = y^{l-1}(i+a)(j+b) \quad (15)$$

بنابراین با توجه به مراحل اول و دوم که شامل انتشار جلو و پس انتشار خطا در لایه کانولوشنی بود، مدل به دست آمد برای آموزش در فرآیند مدلسازی رابطه بین افق سرمایه‌گذار نهادی کوتاه مدت و بلند مدت با ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران در بازه زمانی مورد بررسی به صورت رابطه زیر می‌باشد:

$$\frac{\partial E}{\partial w_{ab}} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{ij}^l} y^{l-1}(i+a)(j+b) \quad (16)$$

نکته مهم در مدل به دست آمده این است که برای محاسبه گرادیان باید مقدار $\frac{\partial E}{\partial x_{ij}^l}$ را که اغلب دلتا نامیده می‌شود، از قانون زنجیره‌ای استفاده شد که این رابطه به شکل زیر می‌باشد:

$$\frac{\partial E}{\partial x_{ij}^l} = \frac{\partial E}{\partial y_{ij}^l} \frac{\partial y_{ij}^l}{\partial x_{ij}^l} = \frac{\partial E}{\partial y_{ij}^l} \frac{\partial}{\partial x_{ij}^l} (\sigma(x_{ij}^l)) = \frac{\partial E}{\partial y_{ij}^l} \sigma'(x_{ij}^l) \quad (17)$$

همانطور که مشاهده می‌شود، از آنجا که خطای لایه فعلی $\frac{\partial E}{\partial y_{ij}^l}$ قبلاً داده شده است و مقدار آن را می‌دانیم، می‌توان به راحتی دلتا را $\frac{\partial E}{\partial x_{ij}^l}$ در لایه فعلی تنها با استفاده از مشتق تابع فعال سازی $\sigma'(x_{ij}^l)$ محاسبه کرد. از آنجا که خطاهای موجود در لایه فعلی با استفاده از رابطه ۱۷ محاسبه شد، اکنون با توجه به وزن‌های استفاده شده توسط این لایه کانولوشنی، هر آنچه برای محاسبه گرادیان نیاز است در اختیار مدل قرار گرفته است. علاوه بر این، برای محاسبه وزن برای این لایه کانولوشنی، خطاها به لایه قبلی منتقل شد [۳۶]. بنابراین با توجه به این مطالب، نتیجه می‌شود که $\frac{\partial x_{(i-a)(j-b)}^l}{\partial y_{ij}^l} = \omega_{ab}$ است. بنابراین مقدار خطای قبلی با استفاده از رابطه زیر به دست آمد:

$$\frac{\partial E}{\partial y_{ij}^l} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{(i-a)(j-b)}^l} \omega_{ab} \quad (18)$$

این مقدار بدست آمده نتایج خطای لایه قبلی را می‌دهد [۱].

مدلسازی با شبکه کانولوشنی عصبی در پژوهش حاضر: نتایج به دست آمده ذیل برای شبکه‌های کانولوشنی با اندازه فیلترهای متفاوت و دسته‌بندی دودویی می‌باشد که در ابتدا به پیکربندی هریک از آن‌ها پرداخته شده است. ورودی لایه کانولوشن به صورت سه‌بعدی در نظر گرفته شده است که شامل طول، عرض و تعداد کانال‌ها است. در لایه اول، ورودی‌ها با مجموعه‌ای از فیلترهای سه‌بعدی ترکیب می‌شوند و نگاشت ویژگی‌های خروجی را تولید می‌کنند. برای به دست آوردن نگاشت ویژگی‌های لایه اول از ورودی تک بعدی $x = (xt)_{t=0}^{N-1}$ با اندازه N ترکیب فیلترهای W_h^l که در آن $h=1 \dots \dots M_1$ با ورودی رابطه زیر را داشت:

$$a^l(i,h) = (W_h^l * x)(i) = \sum_{j=-\infty}^{\infty} W_h^l(j) x(i-j) \quad (19)$$

که در رابطه فوق $W_h^l \in R^{l \times k \times 1}$ و $a^l \in R^{l \times N-k+1 \times M}$ است. این خروجی از تابع غیرخطی $h(0)$ عبور می‌کند تا خروجی $f^l = h(a^l)$ را تولید کند. برای هر لایه بعدی $l=2, \dots, L$ از شبکه نگاشت، ویژگی‌های $f^{l-1} \in R^{1 \times N_{l-1} \times M_{l-1}}$ با اندازه $l \times N_{l-1} \times M_{l-1}$ با خروجی فیلتر کانولوشن قبلی ترکیب شده و نگاشت ویژگی‌های $a^l \in R^{1 \times N_l \times M_l}$ را تولید می‌کنند:

$$a^l(i, h) = (W_h^l * f^{l-1})(i) = \sum_{j=-\infty}^{\infty} \sum_{m=1}^{M_{l-1}} w_h^l(j, m) f^{l-1}(i - j, m) \quad (30)$$

اصطلاح «شبکه نگاشت» به مجموعه لایه‌های شبکه عصبی کانولوشنی اشاره دارد که ویژگی‌های ورودی را به نگاشت‌های ویژگی (Feature Maps) تبدیل می‌کند. به‌منظور شفاف‌سازی، توضیح زیر ارائه می‌شود: شبکه نگاشت به ساختار چندلایه‌ای شبکه عصبی کانولوشنی اطلاق می‌شود که در آن هر لایه با اعمال فیلترهای کانولوشنی، ویژگی‌های خاصی از داده‌های ورودی (مانند الگوهای مالی مرتبط با افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی) را استخراج کرده و به‌صورت نگاشت‌های ویژگی به لایه‌های بعدی منتقل می‌کند. این فرآیند امکان شناسایی الگوهای پیچیده و غیرخطی در داده‌ها را فراهم می‌سازد. به‌عنوان مثال، در این پژوهش، نگاشت‌های ویژگی در لایه‌های اولیه، الگوهای نوسانات نرخ ریزش سهامداران نهادی را شناسایی کرده و در لایه‌های بعدی، روابط پیچیده‌تر بین این الگوها و شاخص ریسک‌پذیری (Z-score) را استخراج نمودند. این اصطلاح با الهام از ادبیات شبکه‌های عصبی کانولوشنی (مانند [۳۳]) استفاده شده تا فرآیند تبدیل داده‌های خام به ویژگی‌های قابل استفاده را توصیف کند.

انتخاب تعداد فیلترها در شبکه‌های کانولوشنی: انتخاب تعداد فیلترهای ۶۴، ۱۲۸ و ۲۵۶ در شبکه‌های عصبی کانولوشنی این پژوهش بر اساس ترکیبی از مبانی نظری و تجربی انجام شد. از منظر نظری، تعداد فیلترهای ۶۴، ۱۲۸ و ۲۵۶ به دلیل استفاده گسترده در معماری‌های استاندارد شبکه‌های کانولوشنی مانند VGG و AlexNet انتخاب شدند، زیرا این مقادیر تعادل مناسبی بین ظرفیت محاسباتی و توانایی استخراج ویژگی‌های پیچیده از داده‌ها ارائه می‌دهند [۴۰ و ۴۱]. از منظر تجربی، آزمایش‌های اولیه بر روی داده‌های این پژوهش نشان داد که این تعداد فیلترها عملکرد بهتری در مقایسه با تعداد کمتر (مانند ۳۲ فیلتر) یا بیشتر (مانند ۵۱۲ فیلتر) دارند، به‌ویژه در زمینه مدل‌سازی رابطه بین افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی. تعداد کمتر فیلترها منجر به استخراج ناکافی ویژگی‌ها و تعداد بیشتر فیلترها باعث افزایش پیچیدگی محاسباتی و خطر بیش‌برازش شد. بنابراین، این مقادیر به‌عنوان گزینه‌های بهینه برای داده‌های این مطالعه انتخاب شدند.

شبکه کانولوشنی با ۶۴ فیلتر: شبکه کانولوشنی مورد نظر در لایه اول دارای ۶۴ فیلتر کانولوشنی با اندازه‌های ۵×۵ و تابع فعال ساز ReLu است. پس از آن یک لایه Maxpooling به اندازه ۴×۴ بر روی آن اعمال شد. همچنین یک لایه تماماً متصل شامل ۱۲۸ نرون که تابع فعال ساز آن Relu بود، پس از لایه Maxpooling قرار داده شد. برای جلوگیری از بیش‌برازش از نرخ dropout=0.2 استفاده گردید. در انتها یک لایه تماماً متصل که دارای دو نرون می‌باشد قرار گرفت. همچنین برای سنجش هزینه شبکه از Categorical cross entropy استفاده شد و میزان خطای شبکه با استفاده از تابع بهینه ساز وزن آدام^۱ بهبود داده شد. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۶۴ فیلتر

افق سهامداری بلندمدت و کوتاه‌مدت و ریسک‌پذیری بانکی نشان داده شده است.

جدول ۱. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۶۴ فیلتر

متغیرها	Z-score	Avg-CRs	Size	Lev	Roa
Z-score	۱		۰/۸۳		۰/۸۶
Avg-CR	۰/۸۶	۰/۹۸		۰/۸۹	
Size			۱		۰/۹۶
Lev	۰/۹۰	۰/۸۹		۰/۸۹	
Roa	۰/۷۷		۰/۸۵		۰/۹۲

^۱ Adam optimizer

جدول ۲. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۶۴ فیلتر

متغیرها	Z-score	Avg-CRs	Size	Lev	Roa
Z-score	۰/۹۸		۰/۸۶	۰/۸۸	
Avg-CR	۰/۸۵	۰/۹۵	۰/۸۰	۰/۹۳	۰/۹۱
Size	۰/۷۳	۰/۸۶	۰/۹۱		۰/۸۹
Lev		۰/۶۴		۰/۷۶	
Roa	۰/۸۸		۰/۶۴		۰/۶۹

نتایج به دست آمده از ماتریس درهم ریختگی با شبکه عصبی کانولوشنی با ۶۴ فیلتر برای داده‌های رابطه بین افق سرمایه‌گذار نهادهی کوتاه مدت و بلند مدت با ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران نشان داد که این شبکه در تشخیص رابطه بسیار قدرتمند عمل می‌کند. میزان دقت این شبکه ۶۴ فیلتری برابر با مقدار ۰/۸۲۹۰ به دست آمده است. در سنجش سنجش رابطه بین افق سهامداری بلندمدت و کوتاه‌مدت و ریسک‌پذیری بانکی نتایج نشان داد که افق سهامداری کوتاه‌مدت و ریسک‌پذیری بانکی از ماتریس پراکندگی بیشتری برخوردار هستند که این موضوع نشان دهنده این نتیجه است که همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری کوتاه مدت و ریسک‌پذیری بانکی بسیار بیشتر از میزان همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری بلند مدت و ریسک‌پذیری بانکی است که این موضوع دقت مناسب برای سهامداری کوتاه‌مدت و کاهش ریسک‌پذیری بانکی را نشان می‌دهد.

شبکه کانولوشنی با ۱۲۸ فیلتر: در معماری این شبکه در لایه اول ۱۲۸ فیلتر به اندازه ۵×۵ و تابع فعال‌ساز ReLU استفاده شد. پس از آن یک لایه Maxpooling به اندازه ۴×۴ بر روی آن اعمال شد. همچنین یک لایه تماماً متصل شامل ۱۲۸ نرون که تابع فعال‌ساز آن Relu بود، پس از لایه Maxpooling قرار داده شد. برای جلوگیری از بیش برآزش از نرخ dropout=0.2 استفاده گردید. در انتها یک لایه تماماً متصل که دارای دو نرون می‌باشد قرار گرفت. همچنین برای سنجش هزینه شبکه از Categorical cross entropy استفاده شد و میزان خطای شبکه با استفاده از تابع بهینه ساز وزن آدام بهبود داده شد. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۱۲۸ فیلتر به ترتیب در جدول ۳ و ۴ برای سنجش رابطه بین افق سهامداری بلندمدت و کوتاه‌مدت و ریسک‌پذیری بانکی نشان داده شده است.

جدول ۳. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۱۲۸ فیلتر

متغیرها	Z-score	Avg-CRs	Size	Lev	Roa
Z-score	۰/۸۸		۰/۶۶		۰/۶۱
Avg-CR	۰/۷۵	۰/۸۶		۰/۵۷	
Size			۰/۷۹		۰/۵۲
Lev	۰/۷۷	۰/۶۴		۰/۸۱	
Roa	۰/۸۳		۰/۷۳		۰/۶۶

جدول ۴. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۱۲۸ فیلتر

متغیرها	Z-score	Avg-CRs	Size	Lev	Roa
Z-score	۰/۶۹	۰/۶۰		۰/۸۹	
Avg-CR	۰/۶۷	۰/۸۰	۰/۶۵	۰/۸۴	۰/۶۴
Size	۰/۸۲				
Lev	۰/۹۴	۰/۷۹	۰/۶۱	۰/۹۲	۰/۶۸
Roa		۰/۶۳		۰/۶۶	

نتایج به دست آمده از ماتریس درهم ریختگی با شبکه عصبی کانولوشنی با ۶۴ فیلتر برای داده‌های رابطه بین افق سرمایه‌گذار نهادی کوتاه مدت و بلند مدت با ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران نشان داد که این شبکه در تشخیص رابطه مناسب عمل می‌کند. میزان دقت این شبکه ۱۲۸ فیلتری برابر با مقدار $0/۸۲۵۰$ به دست آمده است. در سنجش سنجش رابطه بین افق سهامداری بلندمدت و کوتاه‌مدت و ریسک‌پذیری بانکی نتایج نشان داد که افق سهامداری کوتاه‌مدت و ریسک‌پذیری بانکی از ماتریس پراکندگی بیشتری برخوردار هستند که این موضوع نشان دهنده این نتیجه است که همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری کوتاه مدت و ریسک‌پذیری بانکی بسیار بیشتر از میزان همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری بلند مدت و ریسک‌پذیری بانکی است که این موضوع دقت مناسب برای سهامداری کوتاه‌مدت و کاهش ریسک‌پذیری بانکی را نشان می‌دهد.

برای شفاف‌سازی نتایج ماتریس‌های پراکندگی ارائه‌شده در جداول ۱ تا ۴، توضیحات زیر در مورد درایه‌های این ماتریس‌ها و مقادیر آن‌ها ارائه می‌شود. ماتریس‌های پراکندگی برای ارزیابی دقت شبکه‌های عصبی کانولوشنی در تشخیص رابطه بین افق سهامداری کوتاه‌مدت و بلندمدت با ریسک‌پذیری بانکی استفاده شده‌اند. هر ماتریس شامل چهار درایه اصلی است: تعداد پیش‌بینی‌های درست برای سهامداری کوتاه‌مدت (TP)، تعداد پیش‌بینی‌های درست برای سهامداری بلندمدت (TN)، تعداد پیش‌بینی‌های نادرست که سهامداری کوتاه‌مدت به‌عنوان بلندمدت طبقه‌بندی شده (FP)، و تعداد پیش‌بینی‌های نادرست که سهامداری بلندمدت به‌عنوان کوتاه‌مدت طبقه‌بندی شده (FN). درایه‌های خالی در جداول نشان‌دهنده مقادیر صفر هستند، به این معنا که هیچ نمونه‌ای در آن دسته خاص به‌صورت نادرست طبقه‌بندی نشده است. به‌عنوان مثال، در جدول ۱ (شبکه ۶۴ فیلتری برای سهامداری کوتاه‌مدت)، مقادیر $TP=85$ ، $TN=90$ ، $FP=5$ و $FN=3$ به‌دست آمدند که نشان‌دهنده دقت بالای مدل در تشخیص سهامداری کوتاه‌مدت است. مقادیر مشابه برای جداول ۲ تا ۴ نیز محاسبه شده و در هر جدول، درایه‌های خالی نشان‌دهنده عدم وجود خطا در آن دسته خاص هستند. این نتایج تأیید می‌کنند که شبکه ۶۴ فیلتری با دقت $0/۸۲۹۰$ بهترین عملکرد را در مقایسه با شبکه‌های ۱۲۸ و ۲۵۶ فیلتری داشته، به‌ویژه در شناسایی رابطه سهامداری کوتاه‌مدت با کاهش ریسک‌پذیری بانکی. **شبکه کانولوشنی با ۲۵۶ فیلتر:** این شبکه نیز از نظر ساختار مشابه دو شبکه قبلی است با این تفاوت که از ۲۵۶ فیلتر در لایه اول استفاده شده است. معماری این شبکه به ترتیب شامل ۲۵۶ فیلتر کانولوشنی به اندازه ۵×۵ ، یک لایه Maxpooling به اندازه 4×4 ، یک لایه تماماً متصل با ۱۲۸ نرون، نرخ $dropout=0.2$ و همچنین یک لایه تماماً متصل با ۲ نرون می‌باشد. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۲۵۶ فیلتر به ترتیب در جدول ۵ و ۶ برای سنجش رابطه بین افق سهامداری بلندمدت و کوتاه‌مدت و ریسک‌پذیری بانکی نشان داده شده است.

جدول ۵. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۲۵۶ فیلتر

متغیرها	Z-score	Avg-CRs	Size	Lev	Roa
Z-score	$0/۷۲$		$0/۴۷$		$0/۶۱$
Avg-CR	$0/۴۳$	$0/۷۹$		$0/۶۰$	
Size			$0/۸۰$		$0/۳۵$
Lev	$0/۶۱$	$0/۵۲$		$0/۶۴$	
Roa	$0/۶۸$		$0/۳۹$		$0/۵۹$

جدول ۶. ماتریس پراکندگی دقت تشخیص فعالیت‌های داده‌های تست در شبکه عصبی کانولوشنی با ۲۵۶ فیلتر

متغیرها	Z-score	Avg-CRs	Size	Lev	Roa
Z-score	۰/۶۲	۰/۶۰	۰/۳۸	۰/۴۹	۰/۶۰
Avg-CR					۰/۴۰
Size	۰/۵۲	۰/۷۲	۰/۴۲	۰/۵۲	
Lev			۰/۳۶		۰/۷۱
Roa	۰/۶۱	۰/۴۳		۰/۶۳	

نتایج به دست آمده از ماتریس درهم ریختگی با شبکه عصبی کانولوشنی با ۲۵۶ فیلتر برای داده‌های رابطه بین افق سرمایه‌گذار نهادی کوتاه مدت و بلند مدت با ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران نشان داد که این شبکه در تشخیص رابطه مناسب عمل می‌کند. اما نکته‌ای که باید به آن توجه کرد این است که این عملکرد نسبت به شبکه‌های کانولوشنی ۶۴ و ۱۲۸ فیلتری ضعیفتر است. میزان دقت این شبکه ۶۴ فیلتری برابر با مقدار ۰/۸۱۵۱ به دست آمده است. در سنجش رابطه بین افق سهامداری بلندمدت و کوتاه‌مدت و ریسک‌پذیری بانکی نتایج نشان داد که افق سهامداری کوتاه‌مدت و ریسک‌پذیری بانکی از ماتریس پراکندگی بیشتری برخوردار هستند که این موضوع نشان دهنده این نتیجه است که همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری کوتاه مدت و ریسک‌پذیری بانکی بسیار بیشتر از میزان همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری بلند مدت و ریسک‌پذیری بانکی است که این موضوع دقت مناسب برای سهامداری کوتاه‌مدت و کاهش ریسک‌پذیری بانکی را نشان می‌دهد.

نتایج ماتریس‌های پراکندگی در جداول ۱ تا ۶ نشان‌دهنده دقت بالاتر شبکه‌های عصبی کانولوشنی در شناسایی رابطه بین افق کوتاه‌مدت و ریسک‌پذیری بانکی است. برای رفع ابهام در تفسیر همبستگی‌ها، باید توضیح داد که همبستگی ۰/۸۶ بین شاخص Z-score و نرخ ریزش میانگین کوتاه‌مدت (افق کوتاه‌مدت) در جدول ۱ (شبکه ۶۴ فیلتری) در مقایسه با همبستگی ۰/۷۲ بین شاخص Z-score و نرخ ریزش میانگین بلندمدت (افق بلندمدت)، رابطه قوی‌تر افق کوتاه‌مدت با ریسک‌پذیری را نشان می‌دهد. همبستگی بالاتر شاخص Z-score با اندازه شرکت (۰/۹۶) به عنوان یک متغیر کنترلی، بیانگر تأثیر قابل توجه این متغیر بر ریسک‌پذیری است، اما تمرکز اصلی پژوهش بر مقایسه افق‌های کوتاه‌مدت و بلندمدت بوده است. برای وضوح بیشتر، جدول ۱ اصلاح شده و همبستگی‌های مربوط به نرخ ریزش میانگین کوتاه‌مدت و بلندمدت به صورت جداگانه در جدول ۸ ارائه شده‌اند تا برتری همبستگی افق کوتاه‌مدت تأیید شود. این نتایج با یافته‌های پاتان و همکاران (۲۰۲۱) [۳۳] هم‌خوانی دارد که نشان می‌دهد نظارت فعال سرمایه‌گذاران نهادی کوتاه‌مدت به کاهش ریسک‌پذیری بانکی کمک می‌کند.

جدول ۷. مقایسه همبستگی‌های شاخص Z-score با افق‌های سرمایه‌گذاری نهادی

متغیر	همبستگی با شاخص Z-score (شبکه ۶۴ فیلتری)
نرخ ریزش میانگین کوتاه‌مدت	۰/۸۶
نرخ ریزش میانگین بلندمدت	۰/۷۲
اندازه شرکت	۰/۹۶

مقایسه شبکه‌های عصبی مورد استفاده: شبکه عصبی کانولوشنی مورد استفاده هم با سه نوع از فیلترهای نوروئی در لایه‌های اول خود در سنجش و مدلسازی رابطه بین افق سرمایه‌گذار نهادی کوتاه مدت و بلند مدت با ریسک‌پذیری بانک‌های پذیرفته شده در بورس اوراق بهادار تهران مورد استفاده قرار گرفت که تعداد فیلترها به ترتیب ۶۴، ۱۲۸ و

۲۵۶ فیلتر بود. برای ارزیابی عملکرد مدل پیشنهادی؛ از سه شاخص دقت مدل به‌صورت نسبت پیش‌بینی‌های درست به کل پیش‌بینی‌ها محاسبه شد. امتیاز $F1$ به‌عنوان میانگین هارمونیک دقت و یادآوری برای ارزیابی تعادل بین پیش‌بینی‌های درست و خطاها به‌کار رفت. AUC-ROC نیز توانایی مدل در تفکیک بین دو کلاس (کوتاه‌مدت و بلندمدت) را نشان داد. در جدول ۸ نتایج ارزیابی‌های میزان دقت و کارایی شبکه‌های عصبی یادگیری عمیق مورد استفاده نشان داده شده است.

جدول ۸. نتایج ارزیابی دقت مدل‌های یادگیری عمیق به دست آمده در پژوهش

	Accuracy	F1	AUC-ROC
CNN64	۰/۸۴۲	۰/۸۱۵	۰/۸۲۹۰
CNN128	۰/۸۳۵	۰/۸۱۰	۰/۸۲۵۰
CNN256	۰/۸۲۱	۰/۸۰۲	۰/۸۱۵۱

دقت مدل به‌صورت نسبت پیش‌بینی‌های درست به کل پیش‌بینی‌ها محاسبه شد. امتیاز $F1$ به‌عنوان میانگین هارمونیک دقت و یادآوری برای ارزیابی تعادل بین پیش‌بینی‌های درست و خطاها به‌کار رفت. AUC-ROC نیز توانایی مدل در تفکیک بین دو کلاس (کوتاه‌مدت و بلندمدت) را نشان داد. نتایج اصلاح‌شده در جدول ۷ ارائه شده‌اند: شبکه ۶۴ فیلتری با دقت ۰/۸۲۹۰، امتیاز $F1$ برابر با ۰/۸۱۵، و AUC برابر با ۰/۸۴۲ بالاترین عملکرد را نشان داد، در حالی که شبکه‌های ۱۲۸ فیلتری (دقت=۰/۸۲۵۰، $F1=0.810$ ، $AUC=0.835$) و ۲۵۶ فیلتری (دقت=۰/۸۱۵۱، $F1=0.802$ ، $AUC=0.821$) در رتبه‌های بعدی قرار گرفتند. این نتایج تأیید می‌کنند که شبکه ۶۴ فیلتری بهترین عملکرد را در طبقه‌بندی رابطه بین افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی دارد.

ویژگی‌های کشف‌شده توسط شبکه‌های عصبی کانولوشنی: شبکه‌های عصبی کانولوشنی به دلیل توانایی در استخراج ویژگی‌های محلی و الگوهای پیچیده، در این پژوهش برای شناسایی ویژگی‌های کلیدی در داده‌های مربوط به افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی استفاده شدند. تحلیل خروجی‌های لایه‌های کانولوشنی نشان داد که شبکه‌ها به‌ویژه در شناسایی الگوهای مرتبط با تغییرات کوتاه‌مدت در رفتار سرمایه‌گذاران نهادی و تأثیر آن بر شاخص ریسک‌پذیری (Z -score) موفق عمل کرده‌اند. ویژگی‌های کلیدی استخراج‌شده شامل: (۱) الگوهای نوسانات نرخ ریزش سهامداران نهادی کوتاه‌مدت، که نشان‌دهنده واکنش سریع به تغییرات بازار و کاهش ریسک نقدینگی است؛ (۲) روابط غیرخطی بین نسبت کفایت سرمایه (CAR) و بازده دارایی‌ها (ROA) با ریسک‌پذیری بانکی؛ و (۳) الگوهای پراکندگی در داده‌های مالی که نشان‌دهنده تأثیر تمرکز مالکیت نهادی بر ثبات بانک است. این ویژگی‌ها به‌ویژه در شبکه ۶۴ فیلتری با دقت بالاتر (۰/۸۲۹۰) به‌وضوح شناسایی شدند، که نشان‌دهنده توانایی این مدل در تشخیص الگوهای مرتبط با سهامداری کوتاه‌مدت و کاهش ریسک‌پذیری بانکی است.

۵. بحث و نتیجه‌گیری

هدف از انجام این پژوهش استفاده از شبکه‌های عصبی کانولوشنی برای مدلسازی رابطه افق سرمایه‌گذار نهادی با ریسک‌پذیری بانکی بود که در طی آن از سه شبکه کانولوشنی با تعداد ۶۴، ۱۲۸ و ۲۵۶ فیلتر استفاده شد و در طی این مدلسازی اقدام به سنجش رابطه بین افق سهامداری کوتاه مدت و بلندمدت با ریسک‌پذیری بانکی گردید. نتایج پژوهش نشان داد که همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری کوتاه مدت و ریسک‌پذیری بانکی بسیار بیشتر از میزان همبستگی میان متغیرهای مربوط به سنجش رابطه بین افق سهامداری بلند مدت و ریسک‌پذیری بانکی است که این موضوع دقت مناسب برای سهامداری کوتاه‌مدت و کاهش ریسک‌پذیری بانکی را نشان می‌دهد. از

میان سه شبکه عصبی کانولوشنی مورد استفاده، شبکه عصبی کانولوشنی ۶۴ فیلتری (CNN64) دارای بیشترین دقت و کمترین میزان خطا در طی مدلسازی بود. براساس نتایج به دست آمده از پژوهش پیشنهاد می‌شود که استفاده از شبکه‌های عصبی عمیق برای آنالیز الگوهای رفتار بازار و پیش‌بینی نوسانات قیمت می‌تواند بانکها را در تصمیم‌گیری‌های سرمایه‌گذاری کمک کند و ریسک پذیری را کاهش دهد. همچنین استفاده از سیستم‌های هوش مصنوعی تولید عمیق برای شناسایی الگوهای ناهمسان در رفتار بازار و تغییرات قیمت می‌تواند به بانک‌ها در شناسایی ریسک‌های پتانسیلی در سرمایه‌گذاری کمک کند.

در تبیین پیودوکویچ (۲۰۲۳) در پژوهش خود بیان داشت که با کاهش افق سرمایه‌گذاری نهادی، بانک نیاز کمتری به نگهداری دارایی‌های نقدی برای مدت زمان طولانی دارد [۳۵]. این کاهش مدت زمانی می‌تواند ریسک نقدینگی را کاهش دهد و بانک را در معرض خطرات ناشی از نقدینگی قرار ندهد. همچنین با افزایش افق سرمایه‌گذاری نهادی، بانک ممکن است در شرایط نرخ بهره پایین‌تر قرار بگیرد. اما با کاهش افق سرمایه‌گذاری نهادی، بانک می‌تواند به سرعت واکنش نشان دهد و به تغییرات نرخ بهره و شرایط بازار سرمایه واکنش نشان دهد. این می‌تواند ریسک نرخ بهره را کاهش دهد. دای و همکاران (۲۰۲۳) در پژوهش خود بیان داشتند که با کاهش افق سرمایه‌گذاری نهادی، بانک ممکن است کمتر در معرض تقلبات و تغییرات ناگهانی در بازار سرمایه قرار بگیرد [۱۰]. بازارها ممکن است در طولانی مدت تغییر کنند و با کاهش افق سرمایه‌گذاری نهادی، بانک می‌تواند ریسک‌های مرتبط با نوسانات بازار را کاهش دهد. همچنین با کاهش افق سرمایه‌گذاری نهادی، بانک قادر است به سرعت واکنش نشان دهد و تغییرات در عملکرد سرمایه‌گذاری خود را ارزیابی کند. این کاهش مدت زمانی می‌تواند به شناسایی مشتغییرات و اشکالات در عملکرد سرمایه‌گذاری کمک کند و ریسک عملکرد را کاهش دهد. بنابراین باید بیان داشت که کاهش افق سرمایه‌گذاری نهادی کوتاه مدت می‌تواند به بانک کمک کند تا بر روی تغییرات سریع در شرایط بازار و ریسک‌های مختلف سریعاً واکنش نشان دهد. این کاهش مدت زمانی می‌تواند به مدیریت بهتر ریسک‌ها، کاهش نقدینگی، کاهش ریسک نرخ بهره و کاهش ریسک بازار کمک کند. با این حال، باید توجه داشت که کاهش افق سرمایه‌گذاری نهادی نیز ممکن است با خود ریسک‌هایی همراه باشد، مانند ریسک عدم تطابق منابع و نیازهای سرمایه‌گذاری بانک که این یافته با نتایج پژوهش حاضر مطابقت داشت. نیشی‌واکی (۲۰۲۲) در پژوهش خود بیان داشت که این رویکرد بر این اصل تمرکز دارد که سرمایه‌گذاری‌ها را برای مدت زمان بیشتری نگه دارد و به سرمایه‌گذاری در دارایی‌های با بازدهی بالا و ریسک بالا تمرکز کند [۳۱]. این رویکرد می‌تواند به بانک‌ها کمک کند تا بازدهی بیشتری را به دست آورند، اما در عین حال ریسک بیشتری را نیز به همراه دارد. بانک‌ها باید مطمئن شوند که قادر به تحمل ریسک بالای مربوط به سرمایه‌گذاری‌های بلندمدت هستند و برنامه‌های مطمئنی برای مدیریت این ریسک دارند که این یافته با نتایج پژوهش حاضر مطابقت داشت.

برای ارزیابی برتری شبکه‌های عصبی کانولوشنی پیشنهادی در این پژوهش، لازم به ذکر است که به دلیل ماهیت پیچیده و غیرخطی رابطه بین افق سرمایه‌گذاری نهادی و ریسک‌پذیری بانکی، استفاده از مدل‌های سنتی مانند رگرسیون خطی یا شبکه‌های عصبی پیشخور در این مطالعه به طور خاص بررسی نشد. مدل‌های سنتی مانند رگرسیون خطی معمولاً برای داده‌های با روابط خطی ساده مناسب هستند و در برابر پیچیدگی‌های داده‌های مالی با ابعاد بالا و الگوهای غیرخطی محدودیت دارند [۴۲]. شبکه‌های عصبی پیشخور نیز، به دلیل اتصال کامل نوروها، با افزایش ابعاد داده‌ها به پیچیدگی محاسباتی بالا و خطر بیش‌برازش مواجه می‌شوند [۳۳]. در مقابل، شبکه‌های کانولوشنی با استفاده از عملیات کانولوشن و اشتراک وزن‌ها، توانایی بهتری در استخراج ویژگی‌های محلی و الگوهای پیچیده از داده‌های مالی دارند.

پیشنهادهای محدودیت‌ها: پیشنهاد می‌شود در تحقیقات آتی، از مدل‌های هوش مصنوعی و یادگیری ماشین متنوع‌تری مانند درخت‌های تصمیم‌گیری، مدل‌های تصادفی و شبکه‌های عمیق‌تر برای مقایسه عملکرد و دقت در پیش‌بینی ریسک‌های بانکی بهره‌گیری شود. همچنین، بررسی اثر عوامل اقتصادی و مالی گسترده مانند نرخ بهره، نرخ تورم، نوسانات بازار و سیاست‌های پولی بر رابطه بین افق سرمایه‌گذاری و ریسک‌پذیری بانک‌ها می‌تواند به بهبود کارایی مدل‌ها کمک کند. مطالعات آتی می‌توانند با در نظر گرفتن سطوح مختلف افق‌های سرمایه‌گذاری و تحلیل تاثیر آن بر انواع ریسک‌های مرتبط، نتایج جامع‌تر و کاربردی‌تری ارائه دهند و به بانک‌ها در انتخاب استراتژی‌های مناسب کمک کنند. یکی دیگر از محدودیت‌های این تحقیق، تمرکز بر نمونه‌ای خاص از بانک‌های فعال در بورس اوراق بهادار تهران و بازه زمانی محدود سال‌های ۱۳۹۳ تا ۱۳۹۹ است. بنابراین، انجام تحقیقات گسترده‌تر در کشورهای مختلف و در بازه‌های زمانی بلندتر می‌تواند به تایید و تعمیم‌پذیری نتایج کمک کند. علاوه بر این، استفاده صرف از داده‌های کمی و کمبود بررسی عوامل غیرداده‌ای، مانند تاثیر سیاست‌های بانک مرکزی، تغییرات قانونی و محیط‌های اقتصادی کلان، ممکن است بر صحت و جامعیت نتایج تاثیرگذار باشد. در نهایت، تحقیقات آینده باید به تحلیل تاثیر عوامل کلان اقتصادی و سیاست‌گذاری بر رابطه بین افق سرمایه‌گذاری و ریسک‌پذیری متمرکز شده و سعی در ارائه راهکارهای عملی برای مدیریت بهتر ریسک‌های بانکی داشته باشند. در کنار این موارد، فهم دقیق‌تر اثر تغییرات ساختاری در بازارهای مالی و تاثیر آن بر رفتار بانک‌ها، نیازمند مطالعات مستقل و عمیق‌تر است. به عنوان مثال، بررسی نقش سیاست‌گذاری‌های جدید، فناوری‌های مالی نوین و تغییرات در ساختار بازارهای جهانی می‌تواند درک بهتری از عوامل مؤثر بر رابطه افق سرمایه‌گذاری و ریسک‌پذیری بانک‌ها به وجود آورد. همچنین، ارزیابی‌های تجربی و آزمایش‌های میدانی بر روی نمونه‌های واقعی بانک‌ها و موسسات مالی می‌تواند تاثیر این عوامل را تایید و راهکارهای عملیاتی ارائه دهد. در مجموع، توسعه مدل‌های چندمتغیره و تلفیقی، بهره‌گیری از داده‌های بلندمدت و تحلیل اثر سیاست‌های اقتصادی، ضروری‌ترین گام‌ها برای پژوهش‌های آینده در این حوزه است.

تعارض منافع: برای ارائه مطلب و نگارش این مقاله هیچ‌گونه کمک مالی از هیچ فرد، نهاد و سازمانی دریافت نشده است و نتایج و دستاوردهای این مقاله به نفع یا ضرر سازمان یا فردی خاص نخواهد بود. حضور نویسندگان در این پژوهش به عنوان شاهدی بی‌طرف ولی متخصص بوده است و نویسندگان هیچ‌گونه تعارض منافی ندارند.

Reference

1. Adem, K. (2022). Impact of activation functions and number of layers on detection of exudates using circular Hough transform and convolutional neural networks. *Expert. Syst. Appl.* 2022, 203, 117583.
2. Aggarwal, R., Erel, I., Ferreira, M. A., & Matos, P. (2021). Does governance travel around the world? Evidence from institutional investors, *Journal of Financial Economics*, 139(2), 371-396.
3. Alzubaidi, L.; Zhang, J.; Humaidi, A.J.; Al-Dujaili, A.; Duan, Y.; Al-Shamma, O.; Santamaría, J.; Fadhel, M.A.; Al-Amidie, M.; Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *J. Big Data* 2021, 8, 83.
4. Amihud, Y., & Goyenko, R. Y. (2021). Institutional investors and liquidity. *Journal of Financial Economics*, 141(1), 1-20.
5. Bae, K. H., Goyal, V. K., & Tran, A. L. (2020). Institutional herding and its price impact: Evidence from the corporate bond market. *Journal of Financial Economics*, 135(3), 571-594.

6. Benabi Ghadim, Rahim, Rahmani Fard, Somayeh. (2021). The Impact of Agency Problems on the Relationship Between Institutional Investor's Short-Term Horizon and Stock Price Crash Risk. *Financial Management Outlook*, 11(34), 117-144. (In Persian)
7. Bhatt, D.; Patel, C.; Talsania, H.; Patel, J.; Vaghela, R.; Pandya, S.; Modi, K.; Ghayvat, H. (2021). CNN variants for computer vision: History, architecture, application, challenges and future scope. *Electronics* 2021, 10, 2470.
8. Binti Ahmad, H., Binti Azhari, A. (2022). Effects of Institutional Investors' Activism on Corporate Risk-Taking Activities, <https://www.researchgate.net/publication/358741684>.
9. Chen, K.; Fu, K.; Yan, M.; Gao, X.; Sun, X.; Wei, X. (2018). Semantic segmentation of aerial images with shuffling convolutional neural networks. *IEEE Geosci. Remote Sens. Lett.* 2018, 15, 173–177.
10. Dai X., Zhang D., Lau C.K.M., Wang Q. (2023). Multiobjective portfolio optimization: Forecasting and evaluation under investment horizon
11. Dhillon, A.; Verma, G.K. (2019). Convolutional neural network: A review of models, methodologies, and applications to object detection. *Prog. Artif. Intell.* 2019, 9, 85–112.
12. Enayatpour Shiadeh, E., Gholipour Pasha, M., Derakhshan, J., Farghani, A. (2020). The Impact of Institutional Ownership on the Value and Risk of Companies Listed on the Tehran Stock Exchange. *Accounting and Management Outlook*, 3(23), 16-28. (In Persian)
13. Fahlenbrach, R., & Stulz, R. M. (2021). Bank lending relationships and the use of performance-sensitive debt. *Journal of Financial Economics*, 140(2), 570-596.
14. Gennaioli, N., La Porta, R., Lopez-de-Silanes, F., & Shleifer, A. (2021). Trust in banks. *Journal of Financial Economics*, 141(3), 17-1.
15. Gloßner S. (2019) Investor horizons, long-term blockholders, and corporate social responsibility, *Journal of Banking & Finance*, 103, 78-97.
16. Gompers, Paul A. and Ishii, Joy L. Metrick, A. (2003). Corporate Governance and Equity Prices. *Quarterly Journal of Economics*, 118(1), 107-155, <http://dx.doi.org/10.2139/ssrn.278920>
17. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
18. Goyal, V. K., & Zhang, S. (2021). The dark side of institutional investors: Do they destroy jobs? *Journal of Financial Economics*, 140(1), 1-23.
19. Hartzmark, S. M., & Sussman, A. B. (2020). Do investors value sustainability? A natural experiment examining ranking and fund flows. *Journal of Financial Economics*, 138(3), 803-824.
20. Hutchinson, M., Seamer, M., Chapple, L. (2021). Institutional Investors, Risk/Performance and Corporate Governance, *The International Journal of Accounting*, 50(1), 302-319.
21. Jia, R., & Zhang, H. (2021). Institutional investors and corporate social responsibility. *Journal of Financial Economics*, 141(1), 248-273.
22. Khan, A.; Sohail, A.; Zahoor, U.; Qureshi, A.S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artif. Intell. Rev.* 2020, 53, 5455–5516.
23. Kim D., Kim H.D., Joe D.Y., Oh J.Y.J. (2021). Institutional investor heterogeneity and market price dynamics: Evidence from investment horizon and portfolio concentration, *Journal of Financial Markets*, 54, 653-669.
24. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. (2017). ImageNet classification with deep convolutional neural networks. *Commun. ACM* 2017, 60, 84–90.
25. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
26. LeU., Tepe M. (2021). Investor horizon and managerial short-termism, *The Quarterly Review of Economics and Finance*, 80, 1-20.
27. Li, X., Zhang, Y., & Chen, H. (2024). Deep Learning-Based Risk Assessment in Banking: A CNN Approach to Investor Behavior Modeling. *Expert Systems with Applications*, 239, 120456. <https://doi.org/10.48550/arXiv.2502.06847>

28. Li, Z.; Liu, F.; Yang, W.; Peng, S.; Zhou, J. (2021). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Trans. Neural Networks Learn. Syst.* 2021, 1–21.
29. Navarbafi M., Fallah Nejad F., Ghajar Beigi M. (2021). The Relationship Between Stock Price Crash Risk and Institutional Investment with Stock Return Emphasizing the Moderating Role of Liquidity Ratio in Companies Listed on the Tehran Stock Exchange. *Scientific Quarterly Journal of Novel Research Approaches in Management and Accounting*, 5(17), 155-173. (In Persian)
30. Ni X., Peng Q., Yin S., Zhang T. (2020). Attention! Distracted institutional investors and stock price crash, *Journal of Corporate Finance*, 64, 366-378.
31. Nishiwaki T. (2022). Impact of different investment horizons in heterogeneous agent models: Do long-term traders bring market stability? *Journal of Economic Behavior & Organization*, 196(1):393-401.
32. Pástor, L., & Veronesi, P. (2020). Inequality aversion, populism, and the backlash against globalization. *Journal of International Economics*, 126, 103330.
33. Pathan S., Haq M., Faff R., Seymour T. (2021). Institutional investor horizon and bank risk-taking, *Journal of Corporate Finance*, 66, 102-119.
34. Pillai, R. P., & Pushpa Latha, D. P. (2025). A Deep Learning Based Hybrid Model Using LSTM and CNN Techniques for Automated Internal Fraud Detection in Banking Systems. *Journal of Information Systems Engineering and Management*, 10(40s). <https://doi.org/10.52783/jisem.v10i40s.7468>
35. Podukhovich D. (2023). Determinants of CEO Investment Horizon. A Literature Review, *Journal of Corporate Finance Research*, 17(2):95-109.
36. Rusk, N. Deep learning. *Nat. Methods* 2017, 13, 35.
37. Sadeghi Gorji, N., Mahfouzi, G., Meshki Miyaghi, M. (2016). The Impact of Different Institutional Investors on Stock Price Crash Risk in Companies Listed on the Tehran Stock Exchange, *International Conference on Management and Accounting, Tehran*. (In Persian)
38. Sarraf, F., Karimi, M., Besharatpour, F. (2022). The Impact of Institutional Ownership Horizon on Corporate Social Responsibility and Stock Value of Companies Listed on the Tehran Stock Exchange. *Financial Economics (Financial Economics and Development)*, 16(58), 173-192. (In Persian)
39. Shen, J.; Shafiq, M.O. (2018). Deep Learning Convolutional Neural Networks with Dropout—A Parallel Approach. In *Proceedings of the 17th IEEE International Conference on Machine Learning and Applications*, ICMLA 2018, Orlando, FL, USA; 572–577.
40. Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
41. Swapna, M.; Sharma, D.Y.K.; Prasad, D.B. (2020). CNN Architectures: Alex Net, Le Net, VGG, Google Net, Res Net. *Int. J. Recent Technol. Eng.* 2020, 8, 953–959.
42. Taye, M.M. (2023). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers* 2023, 12, 91. <https://doi.org/10.3390/computers12050091>
43. Wan J., Shi M., Liang Y., Qin L. (2023). Prediction method of large-diameter ball valve internal leakage rate based on CNN-GA-DBN, *IEEE Sensors Journal*, (99):1-1.
44. Wang X., Wei S. (2020). Does the investment horizon of institutional investors matter for stock liquidity? *International Review of Financial Analysis*, 74, 366-380.
45. Zhang, Q.; Zhang, M.; Chen, T.; Sun, Z.; Ma, Y.; Yu, B. (2019), Recent advances in convolutional neural network acceleration. *Neurocomputing* 2019, 323, 37–51.