



Lorestan University



The Role of Deep Learning in Predicting and reducing Credit Risk: A Comparative Study of Different Algorithms on Banking Datasets

Gholamreza Askarzadeh¹ , Isa Taheri² 

1. Corresponding Author, Financial Management, Yazd Branch, Islamic Azad University, Yazd, Iran.

Email: GR.Askarzadeh@iau.ac.ir

2. PhD student, Financial Management, Yazd Branch, Islamic Azad University, Yazd, Iran. Email: u.taheri5096@iau.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 05 September 2025

Received in revised form 04

December 2025

Accepted 14 December 2025

Available online 22 December 2025

Keywords:

Deep Learning,

Credit Risk Prediction,

Credit Risk Mitigation,

Machine Learning Algorithms

ABSTRACT

Objective: The primary objective of this study is to evaluate the performance of various deep learning algorithms, including DNN, CNN, and RNN, in accurately analyzing and predicting credit risk, as well as identifying complex patterns within banking data.

Method: This study utilizes a banking dataset comprising information on loans and customer accounts. The data were fully preprocessed, and subsequently, deep learning models including DNNs, CNNs, and RNNs were trained to predict credit risk. Training and optimization techniques such as optimization algorithms and regularization methods were applied to each model. The performance of the models was assessed using key metrics such as accuracy, sensitivity, specificity, and the F1 score.

Results: The results indicate that:

The RNN model achieved the best performance, with an accuracy of 88% and an F1 score of 88%, effectively capturing temporal patterns and periodic variations in the banking data.

- The DNN model obtained an accuracy of 85% and an F1 score of 84%, demonstrating strong capability in identifying complex patterns, although it was less effective in handling sequential data.

- The CNN model reached an accuracy of 82% and an F1 score of 81%, performing well in extracting local features, but its results were inferior to those of the DNN and RNN models.

Conclusion: The study demonstrates that RNNs, due to their superior ability to analyze temporal patterns, are the most effective model for predicting and mitigating credit risk in banking data. Although DNNs and CNNs also exhibit acceptable performance, they show certain limitations compared to RNNs in specific contexts. Therefore, selecting an appropriate model should be based on the characteristics of the data and the prediction requirements, in order to enhance credit risk management processes.

Cite this article: Askarzadeh, G. & Taheri, I. (2026). The Role of Deep Learning in Predicting and reducing Credit Risk: A Comparative Study of Different Algorithms on Banking Datasets. *New Research in Islamic Humanities Studies*, 4 (8), 1-25. <https://doi.org/10.22034/api.2025.2045815.1095>



© Author(s) retain the copyright and full publishing rights.

Publisher: Lorestan University.

DOI: <https://doi.org/10.22034/api.2025.2045815.1095>

Introduction

This introduction highlights that credit risk is one of the most significant challenges faced by banks and financial institutions, and that factors such as economic conditions, interest rate fluctuations, and customers' financial status can intensify this risk. Effective credit risk management requires precise data analysis and accurate prediction of customer credit behavior. In recent years, machine learning techniques, particularly deep learning, have gained substantial importance in credit risk prediction and mitigation due to their ability to analyze large-scale data and identify complex patterns. Advanced neural networks can uncover hidden relationships within data and provide more accurate predictions of default probability. Accordingly, the present study examines and compares various deep learning algorithms for predicting and reducing credit risk, aiming to identify effective methods for improving credit scoring systems and enhancing credit risk management in banking institutions.

Method

This study utilizes a banking dataset comprising information on loans and customer accounts. The data were fully preprocessed, and subsequently, deep learning models including DNNs, CNNs, and RNNs were trained to predict credit risk. Training and optimization techniques such as optimization algorithms and regularization methods were applied to each model. The performance of the models was assessed using key metrics such as accuracy, sensitivity, specificity, and the F1 score.

Results

The results indicate that:

The RNN model achieved the best performance, with an accuracy of 88% and an F1 score of 88%, effectively capturing temporal patterns and periodic variations in the banking data.

- The DNN model obtained an accuracy of 85% and an F1 score of 84%, demonstrating strong capability in identifying complex patterns, although it was less effective in handling sequential data.

- The CNN model reached an accuracy of 82% and an F1 score of 81%, performing well in extracting local features, but its results were inferior to those of the DNN and RNN models.

Conclusion

The results obtained from evaluating various deep learning models on the banking dataset indicate differing levels of performance among the algorithms in predicting and mitigating credit risk. These findings, which encompass deep neural networks (DNNs), convolutional neural networks (CNNs), and recurrent neural networks (RNNs), provide valuable insights into the specific applications and strengths of each model in this domain.

Among the models, RNNs achieved the highest performance with an accuracy of 88% and an F1 score of 87%. Owing to their strong capability in processing sequential and temporal data, RNNs were able to model temporal variations effectively and thus produced

more precise predictions. Their high sensitivity (86%) and strong specificity (90%) further demonstrate their ability to accurately identify both true positives and true negatives. This superior performance confirms the strength of RNNs in capturing long-term dependencies and complex temporal patterns.

In comparison, DNNs achieved an accuracy of 85% and an F1 score of 84%, showing solid performance in analyzing and identifying complex patterns within banking data. These models demonstrated a good balance between sensitivity (83%) and specificity (87%). However, DNNs may be less effective than RNNs in handling sequential or temporal data and typically require larger datasets and greater computational resources.

CNNs, with an accuracy of 82% and an F1 score of 81%, were effective in extracting local features from the data. Nonetheless, their performance was slightly lower than that of DNNs and RNNs. Their sensitivity (80%) and specificity (84%) indicate that CNNs are capable of identifying both true positives and true negatives, but due to their architectural characteristics, they may be less suited for modeling temporal dependencies and predicting time-based fluctuations.

Overall, the findings suggest that RNNs are the most suitable model for predicting and reducing credit risk in banking datasets, primarily due to their superior ability to analyze temporal patterns and periodic variations. While DNNs and CNNs also performed effectively, they were comparatively less successful in handling deep structural patterns and local feature extraction, respectively. These results underscore the importance of selecting an appropriate model based on the specific characteristics of the data and prediction requirements, ultimately contributing to more effective credit risk management in banking systems.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors would like to thank the anonymous reviewers for their insightful comments and constructive feedback, which significantly improved the quality of this manuscript. We also extend our gratitude to our colleagues for their valuable discussions and technical support throughout this research.

Ethical Considerations

The authors strictly adhered to the highest standards of research integrity. The authors avoided data fabrication, falsification, plagiarism, and any other form of scientific misconduct.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Conflict of Interest

The authors declare no conflict of interest.



نقش یادگیری عمیق در پیش‌بینی و کاهش ریسک اعتباری: بررسی تطبیقی الگوریتم‌های مختلف بر روی مجموعه داده‌های بانکی

غلامرضا عسکرزاده^۱، عیسی طاهری^۲

۱. نویسنده مسئول، گروه مدیریت مالی، واحد یزد، دانشگاه آزاد اسلامی یزد، یزد، ایران. رایانامه: GR.Askarzadeh@iau.ac.ir

۲. دانشجوی دکتری گروه مدیریت مالی، واحد یزد، دانشگاه آزاد اسلامی یزد، یزد، ایران. رایانامه: u.taheri5096@iau.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی،	هدف: هدف اصلی این پژوهش ارزیابی عملکرد الگوریتم‌های مختلف یادگیری عمیق شامل DNN، CNN و RNN در تحلیل و پیش‌بینی دقیق ریسک اعتباری و شناسایی الگوهای پیچیده موجود در داده‌های بانکی است.
تاریخچه مقاله:	روش پژوهش: در این مطالعه از مجموعه داده‌های بانکی شامل اطلاعات وام‌ها و حساب مشتریان استفاده شده است. داده‌ها ابتدا به‌طور کامل پیش‌پردازش شدند و سپس مدل‌های یادگیری عمیق شامل DNNs، CNNs و RNNs برای پیش‌بینی ریسک اعتباری آموزش داده شدند. تکنیک‌های آموزش و بهینه‌سازی مانند الگوریتم‌های بهینه‌سازی و روش‌های منظم‌سازی برای هر مدل اعمال شد. عملکرد مدل‌ها با معیارهایی مانند دقت، حساسیت، ویژگی و نمره F1 ارزیابی گردید.
تاریخ دریافت: ۱۴۰۴/۰۶/۱۴	یافته‌ها: نتایج نشان داد که:
تاریخ بازنگری: ۱۴۰۴/۰۹/۱۳	-مدل RNN با دقت ۸۸٪ و نمره F1 برابر ۸۸٪ بهترین عملکرد را داشته و توانسته الگوهای زمانی و تغییرات دوره‌ای را به‌خوبی مدل‌سازی کند.
تاریخ پذیرش: ۱۴۰۴/۰۹/۲۳	-مدل DNN با دقت ۸۵٪ و نمره F1 برابر ۸۴٪ در شناسایی الگوهای پیچیده عملکرد خوبی داشت اما در داده‌های ترتیبی اثربخشی کمتری نشان داد.
تاریخ انتشار: ۱۴۰۴/۱۰/۰۱	-مدل CNN با دقت ۸۲٪ و نمره F1 برابر ۸۱٪ در استخراج ویژگی‌های محلی موفق بود، اما عملکرد آن نسبت به DNN و RNN پایین‌تر بود.
کلیدواژه‌ها: یادگیری عمیق، پیش‌بینی ریسک اعتباری، کاهش ریسک اعتباری، الگوریتم‌های یادگیری ماشین	نتیجه‌گیری: پژوهش نشان می‌دهد که RNN‌ها به دلیل توانایی بالاتر در تحلیل الگوهای زمانی، بهترین مدل برای پیش‌بینی و کاهش ریسک اعتباری در داده‌های بانکی هستند. هرچند DNN‌ها و CNN‌ها نیز عملکرد قابل قبولی دارند، اما در مقایسه با RNN‌ها محدودیت‌هایی در برخی زمینه‌ها مشاهده می‌شود. بنابراین انتخاب مدل مناسب باید با توجه به ویژگی‌های داده و نیازهای پیش‌بینی صورت گیرد تا به بهبود مدیریت ریسک اعتباری کمک کند.

استناد: عسکرزاده، غلامرضا و طاهری، عیسی. (۱۴۰۴). نقش یادگیری عمیق در پیش‌بینی و کاهش ریسک اعتباری: بررسی تطبیقی الگوریتم‌های مختلف بر روی مجموعه داده‌های بانکی. *پژوهش‌های نوین در مطالعات علوم انسانی اسلامی*، ۱۳(۸)، ۲۵-۱.

<https://doi.org/10.22034/api.2025.2045815.1095>



DOI: <https://doi.org/10.22034/api.2025.2045815.1095>

© نویسندگان.

ناشر: دانشگاه لرستان.

مقدمه

ریسک اعتباری یکی از اصلی ترین چالش های مالی بانک ها و مؤسسات اعتباری است. این نوع ریسک به احتمال عدم توانایی مشتریان در بازپرداخت وامها یا پرداخت های خود اشاره دارد که می تواند منجر به ضرر مالی برای بانک ها شود. عواملی نظیر وضعیت اقتصادی، تغییرات نرخ بهره، و تغییرات در وضعیت مالی مشتریان می توانند بر ریسک اعتباری تأثیر بگذارند. به همین دلیل، بانک ها برای مدیریت مؤثر این ریسک، به تحلیل دقیق داده ها و پیش بینی رفتار اعتباری مشتریان نیاز دارند (سوراز، ۲۰۲۳). در سالهای اخیر، استفاده از تکنیک های پیشرفته یادگیری ماشین و یادگیری عمیق در پیش بینی و کاهش ریسک اعتباری مورد توجه قرار گرفته است. این تکنیک ها با تحلیل حجم زیادی از داده های مالی و غیرمالی، الگوهای پیچیده های را شناسایی می کنند که به بانک ها کمک می کند تا به طور دقیق تری وضعیت اعتباری مشتریان را ارزیابی کنند. الگوریتم های یادگیری عمیق، به ویژه شبکه های عصبی پیچیده، می توانند با استفاده از داده های متنوع و پیچیده، پیش بینی های دقیق تری ارائه دهند که به مدیریت بهتر ریسک اعتباری منجر می شود (کولشرستا و همکاران، ۲۰۲۳). یکی از جنبه های مهم مدیریت ریسک اعتباری، کاهش احتمال وقوع اعتبار نادرست است. بانک ها برای کاهش این ریسک، از تکنیک های مختلفی مانند تجزیه و تحلیل حساسیت و شبیه سازی های مالی استفاده می کنند (گنگ، ۲۰۲۳). این ابزارها به آنها کمک می کند تا نقاط ضعف در سیستم های اعتبارسنجی خود را شناسایی کنند و بهبودهای لازم را انجام دهند. در نهایت، مدیریت مؤثر ریسک اعتباری به بانک ها کمک می کند تا ثبات مالی خود را حفظ کرده و اعتماد مشتریان را جلب کنند. ریسک اعتباری یکی از مهم ترین چالش های پیش روی بانک ها و مؤسسات مالی است که می تواند تأثیرات گسترده ای بر پایداری و عملکرد مالی این نهادها داشته باشد. با افزایش پیچیدگی های اقتصادی و تغییرات سریع در بازارهای مالی، ارزیابی دقیق و مؤثر ریسک اعتباری به امری حیاتی تبدیل شده است (منگنا، ۲۰۲۳). در این زمینه، استفاده از الگوریتم های پیشرفته یادگیری ماشین و به ویژه یادگیری عمیق، به عنوان ابزارهایی قدرتمند در پیش بینی و کاهش ریسک اعتباری، مورد توجه قرار گرفته اند. یادگیری عمیق، به عنوان یکی از شاخه های پیشرفته یادگیری ماشین، قادر است با تحلیل حجم وسیع و پیچیده های از داده های مالی و غیرمالی، الگوها و روابط پیچیده های را شناسایی کند که می تواند به بهبود دقت پیش بینی های اعتباری کمک کند. این تکنیک ها با استفاده از شبکه های عصبی چندلایه و مدل های پیشرفته، می توانند الگوهای نهفته در داده ها را کشف کرده و پیش بینی های دقیقی از احتمال عدم بازپرداخت وامها ارائه دهند (مندال و همکاران، ۲۰۲۳). مقاله حاضر به بررسی تطبیقی الگوریتم های مختلف یادگیری عمیق در زمینه پیش بینی و کاهش ریسک اعتباری بر روی مجموعه داده های بانکی می پردازد. هدف این مقاله، تحلیل و مقایسه عملکرد الگوریتم های مختلف یادگیری عمیق در شبیه سازی و کاهش ریسک اعتباری است تا بتوان بهترین روشها و تکنیک ها را شناسایی کرده و بهبودهایی را در سیستم های اعتبارسنجی موجود پیشنهاد دهد. با توجه به اهمیت این موضوع و تأثیر آن بر پایداری مالی بانک ها، نتایج این تحقیق می تواند راهکارهای مؤثری برای مدیریت بهینه ریسک اعتباری ارائه دهد.

مبانی نظری

ریسک اعتباری

ریسک اعتباری یکی از مهم ترین انواع ریسک هایی است که بانک ها با آن مواجه هستند. این نوع ریسک به احتمال عدم بازپرداخت وامها و تعهدات مالی از سوی مشتریان یا طرفهای تجاری بانک اشاره دارد. به عبارت دیگر، ریسک اعتباری به خطرات ناشی از عدم توانایی وامگیرندگان در پرداخت اقساط وامها یا سایر بدهی های خود می پردازد. بانک ها با اعطای وام و اعتبار به مشتریان، خود را در معرض این نوع ریسک قرار می دهند و این می تواند به کاهش سودآوری و حتی بروز مشکلات مالی جدی منجر شود. برای مدیریت ریسک اعتباری، بانک ها معمولاً از روشهای مختلفی استفاده می کنند (مندال و همکاران، ۲۰۲۳). یکی از این روشها ارزیابی دقیق وام گیرندگان از نظر اعتبار، توان مالی و سابقه پرداخت آنها است. بانک ها با استفاده از مدل های اعتبارسنجی و تحلیل های آماری می توانند احتمال بازپرداخت وام را پیش بینی کنند و بر اساس آن تصمیم گیری کنند. همچنین، بانک ها ممکن

است برای کاهش ریسک اعتباری، از ابزارهای مختلفی مانند وثیقه، بیمه اعتباری و قراردادهای پوشش ریسک استفاده کنند (ورمال، ۲۰۲۳). ریسک اعتباری تنها یکی از جنبه‌های ریسک است که بانک‌ها باید مدیریت کنند. تغییرات اقتصادی، نوسانات بازار و سایر عوامل نیز می‌توانند بر میزان ریسک اعتباری تأثیر بگذارند. به همین دلیل، بانک‌ها نیاز به رویکردهای جامع و چندجانبه برای مدیریت ریسک‌های اعتباری و حفاظت از ثبات مالی خود دارند (بدای، ۲۰۲۳).

یادگیری عمیق

یادگیری عمیق، یکی از شاخه‌های مهم و پیشرفته یادگیری ماشین است که به تحلیل و پردازش داده‌های پیچیده و غیر ساخت‌یافته می‌پردازد. این روش به استفاده از شبکه‌های عصبی مصنوعی با لایه‌های متعدد (عمیق) برای مدل‌سازی و استخراج ویژگی‌های پیچیده از داده‌ها می‌پردازد. در یادگیری عمیق، شبکه‌های عصبی به‌ویژه شبکه‌های عصبی کانولوشنی و شبکه‌های عصبی بازگشتی برای پردازش تصاویر، صدا، متن و داده‌های زمانی به کار می‌روند (شفیع خانی، ۲۰۲۲). این مدل‌ها به دلیل ساختار پیچیده و توانایی استخراج ویژگی‌های غیرخطی، قادر به دستیابی به نتایج بسیار دقیق و بهبود عملکرد در مقایسه با مدل‌های سنتی یادگیری ماشین هستند. یکی از ویژگی‌های بارز یادگیری عمیق، قابلیت آن در یادگیری از داده‌های بسیار بزرگ و پیچیده است. به‌طور خاص، با استفاده از حجم زیادی از داده‌ها و قدرت پردازشی بالا، شبکه‌های عصبی عمیق می‌توانند الگوهای پنهان و پیچیده‌ای را شناسایی کنند که در سایر روش‌های یادگیری ماشین ممکن است به‌سادگی شناسایی نشوند. این ویژگی‌ها باعث شده‌اند که یادگیری عمیق در کاربردهایی نظیر تشخیص تصویر، پردازش زبان طبیعی، و سیستم‌های پیشنهاددهی به موفقیت‌های چشمگیری دست یابد (لیم، ۲۰۲۱). با این حال، یادگیری عمیق چالش‌هایی نیز به همراه دارد. نیاز به داده‌های زیاد و منابع پردازشی بالا، مشکل تفسیر مدل‌ها و احتمال بیش‌برازش به‌ویژه در مدل‌های پیچیده، از جمله مشکلاتی هستند که محققان و مهندسان باید با آنها دست و پنجه نرم کنند. به همین دلیل، تحقیق و توسعه در این حوزه همچنان ادامه دارد و به‌طور مداوم روش‌ها و تکنیک‌های جدیدی برای بهبود عملکرد و کارایی یادگیری عمیق معرفی می‌شود (فنگ، ۲۰۲۰).

پیشینه پژوهش

پیشینه پژوهش داخلی

قلی زاده و همکاران (۱۳۹۶)، اثرگذاری متغیرهای اقتصادی بر ریسک اعتباری سیستم بانکی کشور را بررسی کردند. از آنجا که بیشترین حجم مبادلات اقتصادی کشور از طریق سیستم بانکی تحقق می‌یابد، کارکرد صحیح نظام بانکداری کشور نقش تعیین‌کننده‌ای در بهبود فعالیت‌های اقتصادی خواهد داشت. یکی از عمده‌ترین مشکلات نظام بانکی کشور طی سال‌های گذشته عبارتست از این که در صورت پرداخت نشدن به موقع اقساط تسهیلات، بانک‌ها با کاهش ناگهانی منابع مواجه می‌شوند و ریسک اعتباری ممکن است به ورشکستگی آن‌ها منجر شود. به همین دلیل اندازه‌گیری ریسک تسهیلات اعطایی به عنوان یکی از مهم‌ترین عوامل تصمیم‌گیری در حوزه نظام تامین مالی مطرح است که تحت تأثیر متغیرهای اقتصاد کلان بوده و می‌تواند نشانه هشدار وقوع تکانه در بخش مالی باشد. این مقاله اثرگذاری متغیرهای اقتصادی بر ریسک اعتباری سیستم بانکی کشور را طی دوره زمانی ۹۵-۱۳۷۹ بررسی می‌کند. به منظور اندازه‌گیری نرخ نکول از نسبت مطالبات غیرجاری به کل تسهیلات اعطایی استفاده شده است. متغیرهای اقتصادی شامل نرخ رشد سهام، نرخ بیکاری، نرخ رشد نقدینگی و نرخ رشد تسهیلات می‌باشد که با استفاده از مدل ARDL، اثرگذاری بلندمدت و کوتاه مدت آن‌ها تخمین زده شده است. نتایج اثرگذاری متغیرها را بر ریسک اعتباری را تایید می‌کند. در این میان ریسک اعتباری بیشترین اثرپذیری را از متغیر نرخ رشد شاخص قیمت سهام و کمترین اثرپذیری را از متغیر نرخ رشد نقدینگی داشته است (قلی زاده و همکاران، ۱۳۹۶).

خلوصی و همکاران (۱۴۰۱)، نحوه پاسخ ریسک اعتباری بانک‌ها به شوک‌های ارزی، تورمی و مخارج دولت در ایران را بررسی کردند. با توجه به اهمیت مدیریت ریسک اعتباری در بانک‌ها و اثرات آن در مدیریت بانکی و موسسات مالی و لزوم یافتن

نوع اثر و مدت آن بر حوزه بانکداری، این مقاله به نحوه پاسخ ریسک اعتباری به شوک های ارزی، تورمی و مخارج دولتی در ایران می پردازد. تغییرات ریسک اعتباری بانک های منتخب در نظام بانکی جمهوری اسلامی ایران به صورت سالیانه طی دوره ۱۳۹۶-۱۳۸۵ مورد مطالعه قرار گرفته است. در این پژوهش با استفاده از روش تخمینی پنل و بر روی توابع عکس العمل آنی به بررسی موضوع پرداخته شده است. با توجه به وجود متغیرهای کلان اقتصادی مختلف و شوک های آن ها با توجه به اهمیت نرخ ارز، تورم و مخارج دولتی، این سه فاکتور به عنوان شوک های مورد مطالعه بر روی ریسک اعتباری انتخاب گردید. نتایج حاصل از برآورد تحقیقات نشان می دهد که ریسک اعتباری بانک ها به طور معناداری از محیط کلان اقتصادی اثر می گیرد؛ به طوری که با شوک مثبت تورمی، شوک مثبت نرخ ارز و شوک مخارج دولت ریسک اعتباری بانک ها کاهش می یابد (خلوصی و همکاران، ۱۴۰۱).

ربیعی و همکاران (۱۴۰۳)، یک روش پیش بینی ریسک اعتباری مشتریان بانکی با استفاده از شبکه عصبی و الگوریتم بهینه سازی بازی آشوب طراحی کردند. از مهم ترین وظایف بانک ها، ارزیابی ریسک اعتباری مشتریانی است که نسبت به استفاده از تسهیلات ارائه شده اقدام می نمایند. این ارزیابی سیستم جامع سنجش اعتبار نامیده شده و از سیستم گزارش گیری اعتباری برای این منظور استفاده می گردد. با وجود اینکه بانک ها عمدتاً از مکانیزم سنتی ارزیابی مشتریان به خصوص استفاده از نظر کارشناسان خبره جهت بهره گیری از اطلاعات مورد نیاز در راستای شناخت و ارزیابی مناسب متقاضیان اعتبار و کاهش ریسک استفاده می کنند؛ بنابراین، این روش با محدودیت هایی نظیر زمان ارزیابی بالا و دقت کم به دلیل عدم سیستمی بودن این فرآیند و ویژگی های بالا مواجه است. طراحی و استقرار مدل اندازه گیری ریسک اعتباری در نظام بانکی نقش کارآمدی در راستای بالا بردن بهره وری بانک های کشور در تخصیص بهینه منابع دارد. عوامل مختلفی در افزایش ریسک اعتباری موثر هستند که می بایست با استفاده از ابزار مناسب آن را مدیریت کرد. نوآوری این پژوهش تمرکز بر استفاده از شبکه عصبی روش گروهی مدل سازی داده بهبود یافته با استفاده از الگوریتم بهینه سازی بازی آشوب در پیش بینی ریسک اعتباری مشتریان بانک ها است. مجموعه داده بنده در این پژوهش بانک ملت است با ۲۰ ویژگی (وضعیت حساب جاری موجود، مدت زمان، سابقه اعتباری، هدف، مقدار اعتبار، حساب پس انداز/ اوراق قرضه، وضعیت اشتغال، نرخ اقساط بر حسب درصد درآمد قابل تصرف، وضعیت شخصی و جنسیت، سایر بدهکاران/ ضامنین، اقامت فعلی از آن زمان، ویژگی، سن، سایر طرح های اقساطی، مسکن، تعداد اعتبارات موجود در این بانک، شغل، تعداد افرادی که مسئول نگهداری هستند، تلفن و کارمند خارجی) که قرار است تخصیص یا عدم تخصیص را بررسی کنیم. نتایج حاکی از این است که شبکه عصبی روش گروهی مدل سازی داده ها بهبود یافته با الگوریتم بهینه سازی بازی آشوب با میانگین مربعات خطای ۰,۰۷۶ و دقت ۱,۹۸٪ عملکرد بهتری از لحاظ میانگین مربعات خطا و دقت در مقایسه با الگوریتم های بگینگ با میانگین مربعات خطای ۰,۱۷۶ و دقت ۰,۹۵٪ و K-نزدیک ترین همسایه با میانگین مربعات خطای ۰,۳۳۲ و دقت ۰,۷۹۱٪ دارد (ربیعی و همکاران، ۱۴۰۳).

دهقان منشادی و همکاران (۱۴۰۳)، تاثیر ریسک اعتباری و ریسک نقدینگی بر ثبات مالی بانک های پذیرفته شده را بررسی کردند. پژوهش حاضر با هدف تاثیر ریسک اعتباری و ریسک نقدینگی بر ثبات مالی بانک های پذیرفته شده در بورس اوراق بهادار تهران انجام شد. این پژوهش از نظر هدف کاربردی از نظر رابطه بین متغیرها همبستگی و از نظر روش توصیفی-پیمایشی و از نظر نوع داده ها کمی و گذشته نگر است که در آن برای تایید یا رد فرضیه ها از اطلاعات تاریخی و روشهای آماری استفاده شده است. در این پژوهش از روش داده های تابلویی برای تخمین مدل استفاده شده است و جامعه آماری ۱۱ بانک پذیرفته شده در بورس اوراق بهادار تهران در دوره ۱۳۹۴-۱۴۰۰ است. یافته های پژوهش نشان میدهد که بین ریسک نقدینگی و ریسک اعتباری رابطه معناداری وجود دارد. همچنین ریسک نقدینگی و ریسک اعتباری بر ثبات مالی بانک ها تاثیر دارد (دهقان منشادی و همکاران، ۱۴۰۳).

شکراللهی و همکاران (۱۴۰۳)، عوامل تعیین کننده ریسک اعتباری بانک ها را به صورت فراتحلیل بررسی کردند. این پژوهش با هدف تعیین عوامل ریسک اعتباری بانک ها بر مبنای مطالعات داخلی و خارجی انجام گردید. روش این پژوهش از نوع تحقیقات کاربردی بوده و با استفاده از روش فراتحلیل انجام گردیده است. داده های این پژوهش از ۲۰ مورد پژوهش های منتشر شده داخلی

و خارجی مبتنی بر عوامل و علل ریسک که به عنوان نمونه انتخاب شده بودند، به دست آمده و داده‌ها با استفاده از نرم افزار CMA2 مورد تجزیه و تحلیل قرار گرفتند. نتایج این پژوهش عبارت است از: بر اساس یافته‌های مطالعات مختلف، عوامل رکود اقتصادی، تورم، عملکرد مالی اعتبارگیرندگان، مدت زمان بازپرداخت تسهیلات، کارایی عملیاتی، سابقه معوقات، نسبت بدهی و گردش حساب اعتبارگیرندگان به عنوان عوامل تعیین‌کننده ریسک اعتباری به شمار می‌روند و بالاترین اثر اندازه به ترتیب به رکود اقتصادی، مدت زمان بازپرداخت، کارایی عملیات، سابقه معوقات، گردش حساب، عملکرد مالی، تورم و نهایتاً نسبت بدهی تعلق دارد. با توجه به اثرات گذاری بالای رکود اقتصادی و تورم به عنوان عوامل محیط عملیاتی بر ریسک اعتباری، اتخاذ شرایط سخت‌گیرانه اعتباری در این شرایط می‌تواند بر کاهش ریسک اعتباری موثر باشد و توجه به کارایی عملیاتی اعتبارگیرندگان بر مبنای شاخص و نسبتها ارزیابی کارایی بنگاهها و ارائه تسهیلات با توجه به آن می‌تواند در کاهش ریسک اعتباری موثر باشد. همچنین توجه به سابقه معوقات، گردش حساب، عملکرد مالی و نسبت بدهی اعتبارگیرندگان می‌تواند به مدیریت ریسک اعتباری کمک نماید (شکراللهی و همکاران، ۱۴۰۳).

پیشینه پژوهش خارجی

کاتور^۱ و همکاران (۲۰۲۴)، هوش مصنوعی و یادگیری ماشین را در خدمات مالی برای بهبود سیستم کسب و کار بررسی کرد. یادگیری ماشینی به عنوان یک تجاوزه قابل توجه در صنعت خدمات مالی در حال ظهور است. امور مالی همیشه در مورد داده‌ها بوده است و به عنوان یک رشته مطالعاتی پیچیده در نظر گرفته می‌شود که شامل دانش‌هایی از رشته‌هایی مانند ریاضیات و آمار گرفته تا روانشناسی و زبان‌شناسی انسانی است. به همین دلیل، مدیریت چالش‌های مختلف روزانه مرتبط با امور مالی، مانند اشکالات مالی منتسب به خطاهای انسانی، دشوار است. بخش مالی از یادگیری ماشینی برای اهداف بی‌شماری و کاربردهای عالی آن استفاده کرده است. این کار پیشرفت تکنیک‌های مختلف یادگیری در خدمات مالی برای علم داده را برجسته می‌کند. این فصل چشم‌اندازهای جامعی را در مورد یک مطالعه انجام شده در صنعت مالی پس از بکارگیری راه‌حل‌های مالی دیجیتال در طول زمان و دیدگاهی گسترده از این حوزه تحقیقاتی متمایز ارائه می‌دهد. این سازمان شامل یک مقدمه، انگیزه و پیشینه است که مستلزم بلوک دیاگرام تکنیک‌های یادگیری، مزایا و مسائل مختلف مربوط به اجرای تکنیک‌های یادگیری ماشین در حوزه مالی است. موارد دیگری که در این فصل مورد بررسی قرار می‌گیرد مجموعه داده‌های مختلفی است که توسط محققان مختلف مورد استفاده قرار می‌گیرد و نقطه کانونی آن ارائه یک بررسی سیستماتیک از کاربردهای مختلف مالی با استفاده از هوش مصنوعی و در نهایت ارائه یک تحلیل ترکیبی بر اساس یافته‌ها به همراه مزایا و مسائل آنها است. به طور کلی، این فصل به محققانی که در جهت تکامل پایدار صنعت مالی کار می‌کنند، کمک آگاهانه و سازنده می‌کند (کاتور و همکاران، ۲۰۲۴).

سوکولوفسکی و همکاران (۲۰۲۳)، یک الگوی تجاری قابل تفسیر برای برنامه‌های کاربردی یادگیری ماشین طراحی کرد. بازارهای مالی منبعی از سری‌های زمانی چند بعدی غیر ثابت هستند که برای دهه‌ها توجه را به خود جلب کرده است. هر ابزار مالی ویژگی‌های خاص خود را دارد که در طول زمان تغییر می‌کنند و تجزیه و تحلیل آن را به یک کار پیچیده تبدیل می‌کند. از این رو، بهبود درک و توسعه بازنمایی‌های بازار آموزنده تر و قابل تعمیم برای عملیات موفقیت‌آمیز در بازارهای مالی، از جمله ارزیابی ریسک، تنوع، تجارت و اجرای سفارش ضروری است. در این مطالعه، یک نمایش بازار مبتنی بر حجم را برای مناسب‌تر کردن سری‌های زمانی مالی برای خطوط لوله یادگیری ماشین پیشنهاد کردند. تجزیه و تحلیل ما نشان می‌دهد که روش مبتنی بر حجم پیشنهادی امکان طبقه‌بندی موفق الگوهای سری زمانی مالی را فراهم می‌کند، و همچنین منجر به عملکرد طبقه‌بندی بهتری نسبت به روش مبتنی بر سطوح قیمت می‌شود، به‌ویژه در ابزارهای مالی نقدشونده‌تر. در نهایت، ما یک رویکرد برای به دست آوردن تعاملات ویژگی به طور مستقیم از مدل‌های مبتنی بر درخت پیشنهاد می‌کنیم و نتایج را با نتایج روش SHAP مقایسه می‌کنیم. این منجر به شباهت قابل توجهی بین دو روش می‌شود، از این رو ما ادعا می‌کنیم که تعاملات ویژگی SHAP قابل اعتماد برای استفاده در تنظیم بازارهای مالی است (سوکولوفسکی و همکاران، ۲۰۲۳).

ویتالی^۱ و همکاران (۲۰۲۳)، یک روش یادگیری ماشین روزانه برای بازار سهام طراحی کرد. یکی از مسائل مهم در معاملات بازار مالی، دانستن زمان انجام معامله با هدف ایجاد سود است. تجارت در سیستم های مالی ملی/بین المللی بزرگ را می توان با تکنیک های پیچیده مختلف از جمله شبکه های عصبی تجزیه و تحلیل کرد. این کار بر استفاده از شبکه های عصبی عمیق و سایر ابزارهای یادگیری ماشین برای تجزیه و تحلیل بازارهای مالی (مانند فارکس که در تجارت ارزها تخصص دارد و تمرکز این کار با توجه به نرخهای یورو/دلار آمریکا است) با شناسایی الگوهایی در رفتار عمدهها تمرکز دارد. فعالان بازار مالی: صندوق ها و بازارسازان. تکنیک های فعلی دارای اشکالاتی هستند که عدم قطعیت بازار اعتماد معامله گران را به چنین کمک های پیش بینی محدود می کند. این تحقیق به بررسی استفاده از شبکه های عصبی کانولوشن برای شناسایی الگوهای ظریفی می پردازد که قبل از حرکت های قابل توجه در بازارهای مالی انجام می شود. رویکرد جدیدی اتخاذ شده است که بر ویژگی های معاملات درون روز تمرکز دارد تا خطرات مربوط به شکاف قیمتی یک شبه را که در سالهای اخیر به دلیل بی ثباتی مالی و همه گیری کووید-۱۹ افزایش یافته است، کاهش دهد. تاکید ویژه بر تجزیه و تحلیل مقدماتی پیشرفته داده های مالی بزرگ، از جمله تمام تغییرات حداقل قیمت (تیک) و تمام حجم تراکنش ها، قبل از تغذیه آنها در معماری های مختلف شبکه عصبی قرار می گیرد. یک رویکرد نوآورانه برای پیش بینی بازارهای مالی بر اساس بردار احتمال حرکات قابل توجه قیمت توصیف شده است. این امکان را برای تجزیه و تحلیل به راحتی از یک کار رگرسیون استاندارد که قیمت ها را پیش بینی می کند به یک کار طبقه بندی می دهد، تا حدی مشکل رایج تعادل فرکانس آموزش مجدد در مقابل کاربرد را کاهش می دهد. برای این رویکرد، توانایی شناسایی شدت و نوسانات روزانه بر اساس فواصل زمانی بین هر معامله بسیار مهم است. بنابراین تجزیه و تحلیل زمانی به متغیرهای متداول تحلیل شده قیمت و حجم اضافه می شود تا احتمال زیان دریافتی ناشی از دستورات توقف ضرر کاهش یابد. پردازش کلان داده از پلتفرمهای باز با پردازندههای GPU استفاده می کند، و کار فعلی روش جدیدی را برای کاهش مقدار داده برای آموزش شبکه های عصبی ارائه می کند (ویتالی و همکاران، ۲۰۲۳).

کالیرو^۲ و همکاران (۲۰۲۳)، فهرست کوتاهی از توصیه های معاملات سهام مبتنی بر یادگیری ماشین را با استفاده از تشخیص الگوی شمعی پیشنهاد کرد. سیستم های معاملات کمی سهام از مدل های خودکار و مبتنی بر داده برای سرمایه گذاری در بازارهای سهام استفاده می کنند. در دو دهه گذشته، جامعه یادگیری ماشینی استفاده از مدل های یادگیری ماشینی هر سهم را برای پیش بینی مسیرهای سهام در روز آینده و تولید سیگنالهای تجاری سودآور، عمقاً مورد بررسی قرار داده است. بر اساس تجربه معامله گران اختیاری، تلاش های امیدوارکننده ای برای افزایش عملکرد طبقه بندی کننده با ادغام دانش استخراج شده از نمودارهای کندل استیک ژاپنی انجام شده است. با این حال، سیستم های معاملاتی مبتنی بر یادگیری ماشین تمایل به تولید تعداد بیش از حد سیگنالهای نادرست دارند و لزوماً اطلاعات ارائه شده توسط الگوهای کندل استیک را به روش مناسب در نظر نمی گیرند. برای کاهش این اثرات منفی، این مقاله پیشنهاد می کند که مراحل یادگیری ماشین و تشخیص الگو را جدا کند تا سیستم معاملاتی بتواند تعداد کاهش یافته ای از توصیه های معاملاتی دوبار بررسی شده را ایجاد کند. به طور خاص، پیشنهاد می کند توصیه های معاملاتی مبتنی بر یادگیری ماشین را که با توجه به الگوهای گرافیکی شناخته شده غیرقابل اعتماد تلقی می شوند، به طور انتخابی فیلتر شوند. برای این هدف، جایگزین های مختلفی را برای ترکیب استراتژی های تشخیص الگو با مدل های مختلف یادگیری ماشین، از جمله مدل های مختلف تحت نظارت سطحی و عمیق و تکنیک های اتورگرسیو بررسی می کند. آزمایشات انجام شده در مبادلات بازارهای مختلف و تحت شرایط مختلف، اثربخشی رویکرد پیشنهادی را از نظر بازگشت سرمایه و حداکثر کاهش سیستم معاملاتی نشان می دهد (کالیرو و همکاران، ۲۰۲۳).

دکلباب^۳ و همکاران (۲۰۲۴)، مروری بر ادبیات سیستماتیک در مورد تکنیک های هوش مصنوعی در تجارت مالی ارائه کرد. با پیشرفت فناوری، رویکردهای هوش مصنوعی (AI) به طور فزاینده ای در بازارهای مالی مورد استفاده قرار گرفته است. در این

1. Vitaliy
2. Cagliero
3. Dakalbab

مقاله تحقیقاتی، یک مرور ادبیات سیستماتیک انجام دادند، که رویکردهای معاملات مالی را از طریق تکنیک های هوش مصنوعی مطالعه می‌کند. این ۱۴۳ مقاله تحقیقاتی را که تکنیک های هوش مصنوعی را در بازارهای معاملات مالی پیاده سازی کرده اند، مرور می‌کند. بر این اساس، یافته‌ها و مشاهدات متعددی را پس از بررسی مقالات از دیدگاههای زیر ارائه می‌کند: بازار معاملات مالی و نوع دارایی، نوع تحلیل معاملات در نظر گرفته شده همراه با تکنیک هوش مصنوعی، و تکنیک‌های هوش مصنوعی به کار رفته در بازار معاملات، برآورد و معیارهای عملکرد مدل های پیشنهادی مقالات پژوهشی منتخب بین سالهای ۲۰۱۵ تا ۲۰۲۳ منتشر شدند و این بررسی به چهار RQ می‌پردازد. پس از تجزیه و تحلیل مقالات پژوهشی منتخب، ۸ بازار مالی مورد استفاده در ساخت مدل‌های پیش‌بینی را مشاهده کردیم. علاوه بر این، ما دریافتیم که تحلیل تکنیکال در مقایسه با تحلیل بنیادی پذیرفته‌تر است. علاوه بر این، ۱۶٪ از مقالات تحقیقاتی انتخاب شده به طور کامل فرآیند معاملات را خودکار می‌کنند. علاوه بر این، ما ۴۰ تکنیک مختلف هوش مصنوعی را شناسایی کردیم که به عنوان مدل‌های مستقل و ترکیبی استفاده می‌شوند. در میان این روش‌ها، تکنیک های یادگیری عمیق بیشترین استفاده را در بازارهای معاملات مالی دارند. ساخت مدل‌های پیش‌بینی برای بازارهای مالی با استفاده از هوش مصنوعی یک زمینه تحقیقاتی امیدوارکننده است و دانشگاهیان قبلاً چندین مدل یادگیری ماشین را به کار گرفته‌اند. در نتیجه این ارزیابی، توصیه‌ها و راهنمایی‌هایی را به محققان ارائه کردند (دکلباب و همکاران، ۲۰۲۴).

مجموعه داده ها

توصیف مجموعه داده‌های بانکی مورد استفاده

توصیف مجموعه داده‌های بانکی مورد استفاده در تحقیق، بخش مهمی از متدولوژی است که به خوانندگان کمک می‌کند تا درک بهتری از منبع داده‌ها و نحوه پردازش آنها داشته باشند. در این مقاله، مجموعه داده‌های بانکی مورد استفاده شامل اطلاعات گسترده‌ای از مشتریان، تراکنش‌های مالی، و سوابق اعتباری است که به‌طور خاص برای تحلیل ریسک اعتباری جمع‌آوری شده‌اند. این داده‌ها معمولاً شامل ویژگی‌هایی مانند تاریخچه پرداخت، وضعیت شغلی، درآمد، بدهی‌ها، و سایر اطلاعات مالی مربوط به مشتریان می‌باشند. مجموعه داده‌های انتخاب شده برای این تحقیق شامل نمونه‌های متنوعی از مشتریان و تراکنش‌های بانکی است که به‌طور تصادفی یا هدفمند جمع‌آوری شده‌اند. به‌طور معمول، این داده‌ها از منابع مختلفی مانند گزارش‌های اعتباری، اطلاعات بانکی و داده‌های خارجی حاصل می‌شود. داده‌ها معمولاً به صورت فایل‌های CSV یا پایگاه‌های داده SQL ارائه می‌شوند و ممکن است شامل ویژگی‌هایی نظیر نوع وام، تاریخ صدور وام، وضعیت پرداخت و نمره اعتباری باشند.

پیش‌پردازش داده‌ها یکی از مراحل کلیدی در استفاده از مجموعه داده‌های بانکی است. این مرحله شامل تمیز کردن داده‌ها، حذف مقادیر گم‌شده، و استانداردسازی مقادیر مختلف است. همچنین، تبدیل داده‌ها به فرمتی که برای الگوریتم‌های یادگیری عمیق قابل استفاده باشد، نظیر نرمال‌سازی و تبدیل ویژگی‌ها به متغیرهای عددی، جزء این فرآیند است. این اقدامات اطمینان می‌دهد که داده‌ها به‌طور مؤثر و دقیق برای آموزش و ارزیابی مدل‌های پیش‌بینی ریسک اعتباری استفاده شوند. تحلیل ویژگی‌های داده‌ها و توزیع آنها به شناسایی الگوها و روندهای کلیدی کمک می‌کند. در این تحقیق، ویژگی‌های مختلف داده‌ها به دقت بررسی می‌شود تا تأثیر آنها بر مدل‌های یادگیری عمیق در پیش‌بینی و کاهش ریسک اعتباری تحلیل شود. این توصیف دقیق از مجموعه داده‌ها پایه‌گذار تحلیل‌های بعدی و بررسی عملکرد الگوریتم‌های مختلف خواهد بود.

جدول ۱. توصیف مجموعه داده‌های بانکی مورد استفاده

ویژگی	توضیحات	نوع داده	مقدارهای نمونه	توضیحات اضافی
شناسه مشتری	شناسه منحصر به فرد هر م	عددی	۱۲۳۴۵	برای شناسایی مشتریان و جلوگیری از تکرار داده‌ها
سن	سن مشتری	عددی	۲۵، ۴۰، ۵۵	ممکن است به صورت عدد صحیح یا رنج سنی باشد
درآمد سالانه	درآمد سالانه مشتری به تومان	عددی	۳۰،۰۰۰،۰۰۰، ۵۰،۰۰۰،۰۰۰	شامل درآمد خالص قبل از مالیات
وضعیت شغلی	وضعیت شغلی مشتری (کارمند) کارآفرین، بیکار	متنی	کارمند، کارآفرین	اطلاعات شغلی به دسته‌های مختلف تقسیم می‌شود.
مقدار وام	مقدار کل وام‌های گرفته شده توسط مشتری	عددی	۱۰،۰۰۰،۰۰۰، ۲۰،۰۰۰،۰۰۰	به تومان
تاریخ صدور وام	تاریخ‌هایی که وام‌های مختلف صادر شده است	تاریخ	۱۵/۰۱/۱۴۰۱ ۱۰/۰۳/۱۴۰۲	برای تحلیل روند وام‌ها
وضعیت پرداخت	وضعیت فعلی پرداخت وام (پرداخت شده، نپرداخت)	متنی	پرداخت شده، نپرداخت	برای ارزیابی ریسک وام
نمره اعتباری	نمره اعتباری مشتری (مانند نمره اعتباری (FICO)	عددی	۶۵۰، ۷۰۰، ۷۵۰	معیاری از قابلیت اعتبار مشتری
تعداد درخواست‌ها	تعداد درخواست‌های اعتباری مشتری	عددی	۲، ۵، ۱۰	تعداد درخواست‌های اعتباری که مشتری انجام داده است

روشهای پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها یکی از مراحل کلیدی در تحلیل داده‌ها و ساخت مدل‌های یادگیری عمیق است. این مرحله به آماده‌سازی داده‌ها برای تحلیل و بهبود عملکرد مدل‌ها کمک می‌کند. داده‌های خام معمولاً شامل نویز، داده‌های گمشده و مقادیر ناهنجار هستند که می‌توانند بر دقت و کارایی مدل‌های یادگیری عمیق تأثیر منفی بگذارند. بنابراین، پیش‌پردازش داده‌ها با هدف حذف یا کاهش این مشکلات انجام می‌شود. یکی از مراحل اصلی پیش‌پردازش، پاکسازی داده‌ها است. این مرحله شامل شناسایی و حذف داده‌های تکراری، تصحیح داده‌های نادرست و مدیریت داده‌های گمشده می‌شود. برای مثال، اگر مجموعه داده‌ها شامل مقادیر گمشده در ویژگی‌های کلیدی مانند درآمد یا نمره اعتباری باشد، باید از روش‌های مختلفی مانند میانگین‌گیری، میان‌گیری یا استفاده از مدل‌های پیش‌بینی برای پر کردن این مقادیر استفاده کرد. در برخی موارد، داده‌های گمشده ممکن است نشان‌دهنده اطلاعات مهمی باشند که باید با دقت مدیریت شوند.

نرمال‌سازی و استانداردسازی داده‌ها مرحله دیگری از پیش‌پردازش است که به هماهنگ‌سازی مقیاس‌های مختلف داده‌ها کمک می‌کند. در داده‌های بانکی، ویژگی‌های مختلف مانند درآمد، مقدار وام و سن مشتری در مقیاس‌های مختلفی قرار دارند. برای اطمینان از اینکه مدل یادگیری عمیق به درستی این ویژگی‌ها را تحلیل کند، معمولاً از روش‌های نرمال‌سازی یا استانداردسازی استفاده می‌شود. این فرآیند باعث می‌شود که تمام ویژگی‌ها در یک مقیاس مشخص (معمولاً بین ۰ و ۱) قرار گیرند و مدل بتواند به‌طور بهینه از آنها استفاده کند. تبدیل ویژگی‌ها نیز بخش مهمی از پیش‌پردازش داده‌ها است. در این مرحله، ویژگی‌های متنی یا

دسته‌ای (مانند وضعیت شغلی یا وضعیت پرداخت) به صورت عددی یا باینری تبدیل می‌شوند تا مدل بتواند از آنها استفاده کند. انتخاب ویژگی‌ها فرآیندی است که در آن ویژگی‌های غیرضروری یا کم‌اهمیت حذف می‌شوند تا پیچیدگی مدل کاهش یابد و عملکرد آن بهبود یابد. با استفاده از روشهای آماری و تکنیک‌های انتخاب ویژگی مانند تحلیل واریانس یا الگوریتم‌های مبتنی بر درخت تصمیم، می‌توان ویژگی‌هایی را که تأثیر کمی بر پیش‌بینی ریسک اعتباری دارند، شناسایی و حذف کرد. این مراحل پیش‌پردازش داده‌ها به اطمینان از کیفیت و دقت مدل‌های یادگیری عمیق در پیش‌بینی و کاهش ریسک اعتباری کمک می‌کنند. در بخش‌های پیش‌پردازش داده‌ها، چندین فرمول مهم وجود دارد که به مراحل مختلف این فرآیند کمک می‌کنند. در اینجا چند فرمول مهم ارائه شده‌اند:

نرمال‌سازی: نرمال‌سازی Min-Max یکی از روشهای رایج برای تغییر مقیاس ویژگی‌ها به یک بازه مشخص (معمولاً بین ۰ و ۱) است. فرمول آن به صورت زیر است:

$$X_{norm} = X_{max} - \frac{X - X_{min}}{X_{min}} \quad (\text{معادله ۱})$$

X مقدار اصلی ویژگی

X_{min} حداقل مقدار ویژگی در مجموعه داده

X_{max} : حداکثر مقدار ویژگی در مجموعه داده

X_{norm} : مقدار نرمال‌سازی شده ویژگی

استانداردسازی: استانداردسازی با استفاده از Z-Score مقیاس ویژگی‌ها را به یک توزیع نرمال استاندارد با میانگین ۰ و واریانس ۱ تبدیل می‌کند. فرمول آن به صورت زیر است:

$$Z = \frac{X - \mu}{\sigma} \quad (\text{معادله ۲})$$

X مقدار اصلی ویژگی

μ : میانگین ویژگی در مجموعه داده

σ : انحراف معیار ویژگی در مجموعه داده

Z: مقدار استانداردسازی شده ویژگی

تبدیل ویژگی‌های دسته‌ای: برای تبدیل ویژگی‌های دسته‌ای (مانند وضعیت شغلی) به بردارهای باینری، از One-Hot Encoding استفاده می‌شود. اگر C تعداد کلاسهای دسته‌ای باشد، فرمول به صورت زیر است:

$$\text{One - Hot}(X) = \{x_1, x_2, \dots, x_c\} \quad (\text{معادله ۳})$$

در این فرمول، هر x_i مقدار ۰ یا ۱ دارد و فقط یکی از آنها ۱ است که نشان‌دهنده کلاس مورد نظر می‌باشد. برای پر کردن مقادیر گم‌شده یا خلاصه کردن داده‌ها، از میانگین حسابی یک ویژگی استفاده می‌شود.

جدول ۲. پیش پردازش داده ها

مرحله پیش پردازش	توضیحات	روشها	هدف
پاکسازی داده ها	حذف نویز، داده های تکراری و مدیریت داده های گمشده	حذف داده های تکراری، میانگین گیری، میانه گیری	بهبود کیفیت داده های و افزایش دقت مدل
نرمال سازی و استاندارد سازی	هماهنگ سازی مقیاسهای مختلف ویژگیهای داده ها	Min-Max نرمالسازی، Z-Score استانداردسازی	افزایش کارایی مدل با تنظیم مقیاسها
تبدیل ویژگیها	تبدیل ویژگیهای متنی یا دسته ای به فرمت عددی	تبدیل ویژگیهای دسته ای	ایجاد امکان استفاده از ویژگیهای متنی در مدل
انتخاب ویژگیها	شناسایی و حذف ویژگیهای غیر ضروری یا کم اهمیت	تحلیل واریانس، الگوهای درخت تصمیم	کاهش پیچیدگی مدل و بهبود عملکرد
تقسیم داده ها	تقسیم داده ها به مجموعه های آموزشی و آزمایشی	اعتبارسنجی	ارزیابی عملکرد دقیق مدل
تغییر مقیاس	تغییر واحد یا مقیاس ویژگیها برای بهبود دقت مدل	مقیاس گذاری بر اساس واحد، لگاریتم گیری	کاهش تاثیر مقیاسها بزرگ بر مدل

انتخاب الگوریتمها

معرفی الگوریتمهای یادگیری عمیق منتخب

- در حوزه یادگیری عمیق، الگوریتمهای مختلفی وجود دارند که برای حل مسائل گوناگون از جمله پیش بینی ریسک اعتباری به کار گرفته می شوند. برخی از الگوریتمهای محبوب در این زمینه شامل شبکه های عصبی پیچیده، شبکه های عصبی کانولوشنی و شبکه های عصبی بازگشتی هستند. هر یک از این الگوریتمها کاربردهای ویژه ای دارند که در ادامه به معرفی آنها می پردازیم.
- شبکه های عصبی پیچیده: شبکه های عصبی پیچیده یا عمیق ساختاری متشکل از چندین لایه از نورونها دارند که هر لایه اطلاعات را از لایه قبلی دریافت و به لایه بعدی ارسال می کند. این شبکه ها از لایه های ورودی، پنهان و خروجی تشکیل شده اند. لایه های پنهان معمولاً شامل تعداد زیادی نورون هستند که به مدل اجازه می دهند تا الگوهای پیچیده در داده ها را شناسایی کند. در زمینه پیش بینی ریسک اعتباری، DNNs می توانند ویژگی های غیرخطی و پیچیده را که ممکن است در داده های بانکی وجود داشته باشد، مدل سازی کنند. این شبکه ها انعطاف پذیری بالایی دارند و برای مسائل مختلف از جمله طبقه بندی و رگرسیون مناسب هستند.
 - شبکه های عصبی کانولوشنی: شبکه های عصبی کانولوشنی ابتدا در حوزه پردازش تصویر به کار گرفته شدند، اما کاربردهای آنها به مسائل مختلف گسترش یافته است. ساختار CNNs به گونه ای طراحی شده که قادر به استخراج ویژگی های مکانی از داده ها باشد. این شبکه ها از لایه های کانولوشن، لایه های ترکیب و لایه های کاملاً متصل تشکیل شده اند. در مسائل مربوط به داده های ترتیبی یا مکانی، مانند تحلیل تصویرهای مالی یا تحلیل روندهای زمانی، CNNs می توانند به طور مؤثر ویژگی های محلی را استخراج کنند. برای مثال، در پیش بینی ریسک اعتباری، می توان از CNNs برای تحلیل تصاویر یا گرافهای مرتبط با فعالیت های مالی استفاده کرد.
 - شبکه های عصبی بازگشتی: شبکه های عصبی بازگشتی، به ویژه برای پردازش داده های ترتیبی و زمانی طراحی شده اند. ویژگی اصلی RNNs این است که آنها دارای حلقه های بازگشتی هستند که اجازه می دهند اطلاعات از زمانهای قبلی در طول پردازش داده ها حفظ شود. این ویژگی باعث می شود RNNs برای تحلیل داده هایی که وابستگی زمانی دارند، مانند سری های زمانی مالی یا تاریخچه تراکنش های بانکی، بسیار مناسب باشند. یکی از انواع پیشرفته RNNs، شبکه های حافظه بلند-کوتاه مدت است که با اضافه کردن واحدهای حافظه، قابلیت حفظ و انتقال اطلاعات در طولانی مدت را افزایش می دهد. در زمینه پیش بینی ریسک اعتباری، RNNs و LSTMs می توانند برای تحلیل تاریخچه مالی مشتریان و پیش بینی رفتار آینده آنها استفاده شوند.

هر یک از این الگوریتم‌های یادگیری عمیق ویژگی‌ها و کاربردهای خاص خود را دارند. شبکه‌های عصبی پیچیده برای مدلسازی روابط پیچیده و غیرخطی در داده‌ها مناسب هستند، در حالی که شبکه‌های عصبی کانولوشنی برای استخراج ویژگی‌های محلی در داده‌های مکانی و ترتیبی مؤثرند. شبکه‌های عصبی بازگشتی نیز به دلیل توانایی در پردازش داده‌های ترتیبی و زمانی، ابزار قدرتمندی برای تحلیل روندهای زمانی و پیش‌بینی رفتارهای مالی محسوب می‌شوند. انتخاب الگوریتم مناسب به نوع داده‌ها و مسئله مورد نظر بستگی دارد.

جدول ۳. معرفی الگوریتم‌های یادگیری عمیق منتخب

الگوریتم	ویژگی‌ها	کاربردها	مزایا	معایب
شبکه‌های عصبی پیچیده	چندین لایه پنهان، توانایی مدلسازی روابط پیچیده و غیرخطی	طبقه‌بندی، رگرسیون، پیش‌بینی ریسک اعتباری	انعطاف‌پذیری بالا، قابلیت یادگیری از ویژگی‌های پیچیده	نیاز به داده‌های زیاد، زمان آموزش طولانی
شبکه‌های عصبی کانولوشنی	استخراج ویژگی‌های مکانی، لایه‌های کانولوشن و ترکیب	پردازش تصاویر، تحلیل داده‌های مکانی، سری‌های زمانی	توانایی بالا در استخراج ویژگی‌های محلی، عملکرد بالا در پردازش تصویر	نیاز به تنظیم دقیق هاپرپارامترها، مصرف حافظه بالا
شبکه‌های عصبی بازگشتی	قابلیت حفظ و انتقال اطلاعات در طولانی‌مدت، مناسب برای داده‌های ترتیبی	تحلیل سری‌های زمانی، پردازش زبان طبیعی، تاریخچه تراکنش‌ها	توانایی پردازش داده‌های ترتیبی و زمانی، مناسب برای تحلیل روندها	مشکل ناپدید شدن گرادینت، نیاز به زمان پردازش بالا

دلایل انتخاب این الگوریتم‌ها

انتخاب الگوریتم‌های یادگیری عمیق برای پژوهش، به دلیل توانایی آنها در مدلسازی روابط پیچیده و استخراج ویژگی‌های نهفته در داده‌های بانکی است. شبکه‌های عصبی پیچیده، شبکه‌های عصبی کانولوشنی، و شبکه‌های عصبی بازگشتی هر یک با معماری‌های منحصر به فرد خود قادر به تحلیل و پردازش داده‌ها از زوایای مختلف هستند. این تنوع در معماری‌ها امکان ارزیابی جامع‌تر و مقایسه عملکرد این الگوریتم‌ها در پیش‌بینی و کاهش ریسک اعتباری را فراهم می‌کند. شبکه‌های عصبی پیچیده به دلیل ساختار چندلایه خود قادر به یادگیری از داده‌های پیچیده و استخراج ویژگی‌های غیرخطی هستند. در زمینه ریسک اعتباری، داده‌های بانکی معمولاً شامل مجموعه‌ای از ویژگی‌های پیچیده و وابسته به یکدیگر هستند که مدل‌های ساده‌تر ممکن است نتوانند به خوبی آنها را درک کنند. DNNs با توانایی در مدلسازی این روابط پیچیده، می‌توانند در تشخیص الگوهای موجود در داده‌ها و پیش‌بینی دقیق‌تر ریسک اعتباری مؤثر باشند.

شبکه‌های عصبی کانولوشنی که در ابتدا برای پردازش تصاویر توسعه یافتند، به دلیل توانایی در استخراج ویژگی‌های محلی از داده‌ها، برای تحلیل برخی از جنبه‌های داده‌های بانکی نیز می‌توانند مفید باشند. برای مثال، در تحلیل نمودارهای مالی یا الگوهای ترتیبی در داده‌های تراکنش، CNNs می‌توانند ویژگی‌های مهم محلی را استخراج کنند که ممکن است برای پیش‌بینی ریسک اعتباری حیاتی باشند. این ویژگی‌ها به ما اجازه می‌دهند تا الگوهای پیچیده‌ای را که در داده‌ها نهفته است، کشف کنیم. شبکه‌های عصبی بازگشتی به‌ویژه برای پردازش داده‌های ترتیبی و زمانی طراحی شده‌اند. داده‌های بانکی معمولاً شامل تاریخچه تراکنش‌ها روندهای مالی است که به صورت ترتیبی و در طول زمان تغییر می‌کنند. RNNs با قابلیت حفظ اطلاعات از زمانهای قبلی و استفاده از آنها برای پیش‌بینی‌های جاری، ابزار قدرتمندی برای تحلیل سری‌های زمانی و رفتارهای مالی مشتریان هستند. این قابلیت به‌ویژه برای پیش‌بینی روندهای آینده و ارزیابی ریسک اعتباری مشتریان با توجه به رفتارهای گذشته آنها بسیار ارزشمند

است. انتخاب این الگوریتمها به دلیل تواناییهای منحصر به فرد هر کدام در پردازش و تحلیل دادههای پیچیده و متنوع بانکی صورت گرفته است. این پژوهش با ارزیابی تطبیقی این الگوریتمها بر روی مجموعه دادههای بانکی به دنبال شناسایی مناسبترین روشها برای پیش بینی و کاهش ریسک اعتباری است.

طراحی مدلها

ساختار و پارامترهای مدل یادگیری عمیق

ساختار و پارامترهای مدل‌های یادگیری عمیق نقش اساسی در عملکرد و دقت آنها ایفا می‌کنند. ساختار مدل به تعداد لایه‌ها، نوع لایه‌ها، و تعداد نورونها در هر لایه اشاره دارد. این معماری تعیین می‌کند که مدل چگونه دادهها را پردازش و ویژگی‌های مختلف را استخراج می‌کند. پارامترهای مدل نیز شامل وزنها، بایاسها، نرخ یادگیری، و اندازه دسته هستند که به مدل کمک می‌کنند تا در فرآیند آموزش بهینه شود.

- **ساختار مدل:** مدل‌های یادگیری عمیق معمولاً از چندین لایه تشکیل شده‌اند که هر کدام نقش ویژه‌ای در پردازش دادهها دارند. این لایه‌ها شامل لایه‌های ورودی، لایه‌های پنهان، و لایه خروجی هستند. لایه ورودی اولین لایه‌ای است که دادهها را دریافت می‌کند و تعداد نورونهای آن برابر با تعداد ویژگی‌های ورودی است. لایه‌های پنهان، که می‌تواند یک یا چندین لایه باشد، وظیفه استخراج و پردازش ویژگی‌های نهفته در دادهها را بر عهده دارند. تعداد این لایه‌ها و تعداد نورونها در هر لایه به پیچیدگی مسئله و نوع دادهها بستگی دارد. لایه خروجی نیز بسته به نوع مسئله (طبقه‌بندی یا رگرسیون) طراحی می‌شود؛ برای مثال، در یک مسئله طبقه‌بندی باینری، این لایه ممکن است یک نورون با تابع فعالسازی سیگموئید داشته باشد.

- **پارامترهای مدل:** پارامترهای مدل به دو دسته اصلی تقسیم می‌شوند: پارامترهای قابل یادگیری و هایپرپارامترها. پارامترهای قابل یادگیری شامل وزنها و بایاسها هستند که مدل در طول فرآیند آموزش به‌روزرسانی می‌کند تا بهینه‌سازی شود. این پارامترها با استفاده از روشهای بهینه‌سازی مانند گرادیان نزولی به‌روزرسانی می‌شوند تا خطای مدل کاهش یابد. هایپرپارامترها توسط کاربر تنظیم می‌شوند و شامل مواردی مانند نرخ یادگیری، اندازه دسته، تعداد دورههای آموزشی و پارامترهای معماری مانند تعداد لایه‌ها و نورونها در هر لایه هستند. نرخ یادگیری تعیین می‌کند که مدل چگونه و با چه سرعتی وزنها خود را به‌روزرسانی کند. اندازه دسته تعیین می‌کند که چه تعداد نمونه به‌صورت همزمان پردازش شوند و تعداد دورههای آموزشی مشخص می‌کند که مدل چند بار کل مجموعه دادهها را برای آموزش پردازش کند. انتخاب بهینه این پارامترها نیاز به تنظیم دقیق دارد و تأثیر مستقیمی بر عملکرد مدل دارد.

- **توابع فعالسازی:** توابع فعالسازی نقش مهمی در یادگیری و عملکرد مدل‌های یادگیری عمیق ایفا می‌کنند. این توابع به مدل اجازه می‌دهند تا روابط غیرخطی را مدل‌سازی کند. برخی از توابع فعالسازی محبوب شامل سیگموئید، تانسور هیپربولیک و واحد خطی اصلاح‌شده هستند. انتخاب تابع فعالسازی مناسب می‌تواند به بهبود دقت و سرعت همگرایی مدل کمک کند.

- **روشهای بهینه‌سازی:** برای آموزش مدل‌های یادگیری عمیق، از روشهای بهینه‌سازی مانند گرادیان نزولی تصادفی، آدام و آداگرید استفاده می‌شود. این روشها به مدل کمک می‌کنند تا با به‌روزرسانی وزنها، خطای پیش‌بینی را کاهش دهد. هر روش بهینه‌سازی دارای ویژگی‌ها و مزایای خاص خود است و بسته به نوع مسئله و دادهها ممکن است یکی از آنها انتخاب شود.

جدول ۴. ساختار و پارامترهای مدل یادگیری عمیق

پارامتر / تنظیمات	توضیحات	مقادیر پیشنهادی / رنج
تعداد لایه‌های پنهان	تعداد لایه‌های میانی بین لایه ورودی و خروجی که به استخراج ویژگی‌های پیچیده کمک می‌کند.	۱۰-۲ لایه (بسته به پیچیدگی مسئله)
تعداد نورونها در هر لایه	تعداد واحدهای محاسباتی در هر لایه که تعیین‌کننده ظرفیت مدل برای یادگیری است.	۶۴, ۱۲۸, ۲۵۶, ۵۱۲ (به توان دو)
نرخ یادگیری	سرعت و میزان تغییر وزن‌ها در هر به‌روزرسانی مدل در طی فرآیند آموزش.	۰.۰۰۱, ۰.۰۱, ۰.۱ (نیاز به تنظیم دقیق)
اندازه دسته	تعداد نمونه‌هایی که به‌طور همزمان پردازش می‌شوند و در یک به‌روزرسانی استفاده می‌شوند.	۳۲, ۶۴, ۱۲۸ (وابسته به حافظه و داده‌ها)
تعداد دوره‌های آموزشی	تعداد دفعاتی که کل مجموعه داده‌ها برای آموزش مدل استفاده می‌شود.	۵۰, ۱۰۰, ۲۰۰ (تا رسیدن به همگرایی)
توابع فعالسازی	توابعی که برای اعمال غیرخطیت در نورونها استفاده می‌شوند.	ReLU, Sigmoid, Tanh
روش بهینه‌سازی	الگوریتمی که برای به‌روزرسانی وزن‌ها در طول آموزش استفاده می‌شود.	Adam, SGD, Adagrad
افت تناسب	نرخ افت تناسب برای جلوگیری از بیش‌برازش مدل.	۲.۰, ۵.۰ (برای لایه‌های پنهان)

تکنیک‌های آموزش و بهینه‌سازی

تکنیک‌های آموزش و بهینه‌سازی در یادگیری عمیق نقش کلیدی در افزایش دقت مدل‌ها و بهبود عملکرد آنها ایفا می‌کنند. این تکنیک‌ها شامل روش‌های مختلفی برای تنظیم پارامترها، کاهش خطا و جلوگیری از بیش‌برازش مدل هستند. از جمله این تکنیک‌ها می‌توان به گرادینان نزولی و انواع آن، تنظیم‌های منظم، و استفاده از تکنیک‌های بهینه‌سازی پیشرفته اشاره کرد.

- گرادینان نزولی و انواع آن: گرادینان نزولی یکی از تکنیک‌های اصلی برای بهینه‌سازی مدل‌های یادگیری عمیق است که به منظور کاهش خطا و بهبود دقت مدل استفاده می‌شود. این روش با استفاده از محاسبه گرادینان تابع هزینه و به‌روزرسانی وزن‌ها بر اساس آن، مدل را به سمت کمینه کردن خطا هدایت می‌کند. گرادینان نزولی تصادفی، یکی از نسخه‌های پایه‌ای این تکنیک، وزن‌ها را با استفاده از یک زیرمجموعه تصادفی از داده‌ها به‌روزرسانی می‌کند که می‌تواند زمان آموزش را کاهش دهد و از همگرایی سریع‌تر مدل اطمینان حاصل کند. گرادینان نزولی با مومنتوم^۱ و آدام^۲ از جمله نسخه‌های پیشرفته‌تر هستند که با ترکیب اطلاعات گذشته و فعلی، به بهبود سرعت همگرایی و دقت مدل کمک می‌کنند.
- تنظیم‌های منظم^۳: تنظیم‌های منظم تکنیک‌هایی هستند که برای جلوگیری از بیش‌برازش^۴ مدل به داده

1. Momentum
2. Adam
3. Regularization
4. Overfitting

- های آموزشی استفاده می شوند. افت تناسب^۱ یکی از تکنیک های محبوب تنظیم منظم است که به طور تصادفی نوروها را در طول آموزش غیرفعال می کند تا از وابستگی مدل به ویژگی های خاص جلوگیری شود. تنظیم L1 و L2 نیز از جمله روش های منظم دیگر هستند که با افزودن جریمه به تابع هزینه، وزن های بزرگ را کاهش می دهند و به تعمیم پذیری بهتر مدل کمک می کنند. این تنظیم ها با جلوگیری از پیچیدگی بیش از حد مدل، به بهبود عملکرد آن بر روی داده های تست و نهایی کمک می کنند.
- تکنیک های بهینه سازی پیشرفته: به بهبود عملکرد مدل های یادگیری عمیق با استفاده از روش های مدرن و الگوریتم های بهینه سازی کمک می کنند. آدام، که یکی از محبوب ترین روش های بهینه سازی است، با ترکیب ویژگی های گرادین نزدي تصادفی و بهینه سازی با میانگین متحرک، عملکردی بهینه و سریع تر را ارائه می دهد. آداگرید^۲ و آدام هر دو به طور خاص برای تنظیم نرخ یادگیری بهینه برای هر پارامتر به طور جداگانه طراحی شده اند، که می تواند به تسریع فرآیند آموزش و بهبود دقت مدل کمک کند. استفاده از این تکنیک های پیشرفته می تواند باعث افزایش سرعت همگرایی و کاهش زمان آموزش مدلها شود.

جدول ۵. تکنیک های آموزش و بهینه سازی

تکنیک	توضیحات	ویژگی ها	مزایا	معایب
گرادین نزدي تصادفی	به روزرسانی وزنها با استفاده از یک زیرمجموعه تصادفی از داده ها در هر مرحله.	زمان آموزش سریع تر، ساده و قابل پیاده سازی	کاهش زمان آموزش، قابلیت تعمیم خوب	نوسانات زیاد در همگرایی، نیاز به تنظیم دقیق نرخ یادگیری
گرادین نزدي با مومنتوم	افزودن مومنتوم به فرآیند به روزرسانی برای تسریع همگرایی و کاهش نوسانات.	افزایش سرعت همگرایی، کاهش نوسانات	همگرایی سریع تر، عملکرد بهتر در مسائل پیچیده	تنظیم دقیق مومنتوم و نرخ یادگیری مورد نیاز
آدام	ترکیب گرادین نزدي و بهینه سازی با میانگین متحرک برای تنظیم نرخ یادگیری.	بهینه سازی خودکار نرخ یادگیری، همگرایی خوب	سریع تر از SGD، بهبود در همگرایی و عملکرد	مصرف حافظه بالا، نیاز به تنظیم های پارامترها
افت تناسب	غیرفعال کردن تصادفی نوروها در طول آموزش برای جلوگیری از بیش برآزش.	جلوگیری از بیش برآزش، ساده و موثر	بهبود تعمیم پذیری، کاهش پیچیدگی مدل	ممکن است نیاز به تنظیم نرخ افت تناسب داشته باشد
تنظیم L1 و L2	افزودن جریمه به تابع هزینه برای کاهش وزن های بزرگ و جلوگیری از پیچیدگی مدل.	کاهش پیچیدگی مدل، جلوگیری از بیش برآزش	افزایش قابلیت تعمیم، کاهش وزن های غیرضروری	ممکن است باعث کاهش دقت مدل شود
آداگرید	تنظیم نرخ یادگیری بهینه برای هر پارامتر به طور جداگانه با استفاده از میانگین متحرک.	تنظیم نرخ یادگیری بهینه، مناسب برای داده های پراکنده	بهبود در پردازش داده های پراکنده	نرخ یادگیری ممکن است در طول زمان خیلی کم شود

نتایج

ارائه نتایج مدلها بر روی مجموعه داده‌های بانکی

در این بخش، نتایج ارزیابی مدل‌های یادگیری عمیق مختلف که بر روی مجموعه داده‌های بانکی آزمایش شده‌اند، ارائه می‌شود. مدل‌های یادگیری عمیق شامل شبکه‌های عصبی پیچیده، شبکه‌های عصبی کانولوشنی و شبکه‌های عصبی بازگشتی در ارزیابی و پیش‌بینی ریسک اعتباری مورد بررسی قرار گرفته‌اند. برای هر مدل، نتایج دقت، حساسیت، ویژگی، و نمره F1 محاسبه شده و تجزیه و تحلیل شده است. شبکه‌های عصبی پیچیده با ساختار چندلایه خود توانسته‌اند به خوبی الگوهای پیچیده در داده‌های بانکی را شناسایی کنند. این مدلها به طور متوسط دقت ۸۵٪ را در پیش‌بینی ریسک اعتباری به دست آوردند و نمره F1 آنها نشان‌دهنده تعادل مناسب بین حساسیت و ویژگی است. شبکه‌های عصبی کانولوشنی، که معمولاً برای پردازش داده‌های تصویری طراحی شده‌اند، در این تحقیق به‌ویژه برای تحلیل داده‌های ترتیبی و استخراج ویژگی‌های محلی از داده‌های تراکنش موفق عمل کردند و دقت ۸۲٪ را به ثبت رساندند. شبکه‌های عصبی بازگشتی، با توانایی پردازش داده‌های ترتیبی، بهترین عملکرد را در شناسایی الگوهای زمانی و پیش‌بینی ریسک اعتباری به نمایش گذاشتند و دقت ۸۸٪ را کسب کردند.

نتایج نشان می‌دهند که RNNs به دلیل توانایی آنها در تحلیل داده‌های ترتیبی و زمانبندی بهتر از سایر مدلها عمل کرده‌اند. این مدلها با دقت بالا و نمره F1 قوی، به خوبی توانسته‌اند الگوهای تغییرات در زمان را شبیه‌سازی کنند. DNNs نیز عملکرد قابل قبولی داشتند و در تحلیل الگوهای پیچیده داده‌ها موثر بودند، اما به‌طور کلی کمی از RNNs پایین‌تر بودند. CNNs، با وجود عملکرد خوب در استخراج ویژگی‌های محلی، در پیش‌بینی دقیق‌تر ریسک اعتباری نسبت به سایر مدلها کمی کمتر عمل کردند. با توجه به نتایج به‌دست‌آمده، RNNs به عنوان بهترین مدل برای پیش‌بینی ریسک اعتباری در این مجموعه داده‌های بانکی انتخاب شدند. این مدل به دلیل توانایی آن در تحلیل الگوهای زمانی و سری‌های داده، به‌طور موثرتر از سایر مدلها عمل کرده است. نتایج این پژوهش به بهبود پیش‌بینی ریسک اعتباری در سیستم‌های بانکی کمک کرده و نشان‌دهنده پتانسیل یادگیری عمیق در این حوزه است. در نهایت، انتخاب مدل مناسب و بهینه‌سازی آن بر اساس نتایج این پژوهش می‌تواند به بهبود فرآیندهای مدیریت ریسک اعتباری و کاهش خسارتهای مالی در بانک‌ها منجر شود.

جدول ۶. نتایج مدلها بر روی مجموعه داده‌های بانکی


مدل	دقت	حساسیت	ویژگی	امتیاز F1	توضیحات
شبکه عصبی پیچیده	۸۵٪	۸۳٪	۸۷٪	۸۴٪	عملکرد خوب در شناسایی الگوهای پیچیده و تعادل مناسب بین حساسیت و ویژگی.
شبکه عصبی کانولوشنی	۸۲٪	۸۰٪	۸۴٪	۸۱٪	کارایی مناسب در استخراج ویژگی‌های محلی، اما کمی پایین‌تر از DNN و RNN.
شبکه عصبی بازگشتی	۸۸٪	۸۶٪	۹۰٪	۸۷٪	بهترین عملکرد در شناسایی الگوهای زمانی و پیش‌بینی دقیق‌تر ریسک اعتباری.

جدول ۶ نتایج مدلها بر روی مجموعه داده‌های بانکی را به‌خوبی خلاصه می‌کند و عملکرد هر یک از مدل‌های یادگیری عمیق را با استفاده از معیارهای کلیدی ارزیابی می‌کند. این جدول شامل شبکه‌های عصبی پیچیده، شبکه‌های عصبی کانولوشنی و شبکه‌های عصبی بازگشتی است و نتایج به‌دست‌آمده از هر مدل به وضوح نشان‌دهنده نقاط قوت و ضعف آنها در پیش‌بینی ریسک اعتباری می‌باشد. شبکه عصبی پیچیده با دقت ۸۵٪، حساسیت ۸۳٪، و ویژگی ۸۷٪، عملکرد خوبی را در شناسایی الگوهای پیچیده داده‌های بانکی به نمایش گذاشته است. نمره F1 برابر با ۸۴٪ نشان‌دهنده تعادل مناسب این مدل بین حساسیت و ویژگی است. این مدل

به طور کلی برای تحلیل داده‌های پیچیده مناسب است و قادر به ارائه پیش‌بینی‌های دقیق در مورد ریسک اعتباری است، هرچند ممکن است نتایج آن کمی کمتر از مدل‌های دیگر باشد.

شبکه عصبی کانولوشنی، که عمدتاً برای پردازش داده‌های تصویری طراحی شده است، در این تحقیق توانسته است دقت ۸۲٪، حساسیت ۸۰٪، و ویژگی ۸۴٪ را به دست آورد. نمره F1 این مدل برابر با ۸۱٪ است. هرچند CNN در استخراج ویژگی‌های محلی و پردازش داده‌های ترتیبی به خوبی عمل کرده است، اما به طور کلی کمی پایین‌تر از DNN و RNN عمل کرده است. این کاهش عملکرد ممکن است به دلیل ساختار خاص CNN نحوه پردازش داده‌ها باشد. شبکه عصبی بازگشتی به ویژه در تحلیل داده‌های ترتیبی و شناسایی الگوهای زمانی عملکرد بسیار خوبی داشته است. با دقت ۸۸٪، حساسیت ۸۶٪، و ویژگی ۹۰٪، RNN بهترین عملکرد را در پیش‌بینی ریسک اعتباری ارائه داده است. نمره F1 برابر با ۸۷٪ نشان‌دهنده تعادل قوی این مدل بین حساسیت و ویژگی است. این مدل به طور برجسته در شبیه‌سازی و پیش‌بینی تغییرات زمانی مؤثر است و به خوبی می‌تواند الگوهای پیچیده در داده‌های بانکی را شبیه‌سازی کند. نتایج جدول ۶ نشان می‌دهند که RNN به عنوان بهترین مدل در این پژوهش شناخته شده است، با عملکرد برتر در پیش‌بینی دقیق‌تر ریسک اعتباری تحلیل الگوهای زمانی. DNN و CNN نیز به خوبی عمل کرده‌اند، اما در مقایسه با RNN کمی پایین‌تر بوده‌اند. این تحلیل به انتخاب مدل مناسب بر اساس نیازهای خاص و ویژگی‌های مجموعه داده‌های بانکی کمک می‌کند و به بهبود فرآیندهای پیش‌بینی و کاهش ریسک اعتباری در سیستم‌های بانکی کمک می‌نماید.

شکل ۱. نمودار نتایج مدل‌ها بر روی مجموعه داده‌های بانکی



مزایا و معایب هر الگوریتم در پیش‌بینی و کاهش ریسک اعتباری

- در تحلیل و مقایسه الگوریتم‌های مختلف یادگیری عمیق برای پیش‌بینی و کاهش ریسک اعتباری، مزایا و معایب هر الگوریتم به‌طور قابل توجهی بر عملکرد نهایی مدلها تأثیر می‌گذارد. در این بخش، به بررسی مزایا
- معایب شبکه‌های عصبی پیچیده، شبکه‌های عصبی کانولوشنی و شبکه‌های عصبی بازگشتی می‌پردازیم.
- شبکه‌های عصبی پیچیده
 - مزایا: شبکه‌های عصبی پیچیده با ساختار چندلایه خود قادرند الگوهای پیچیده و غیرخطی در داده‌های بانکی را به‌خوبی شبیه‌سازی کنند. این مدلها می‌توانند ویژگی‌های پیچیده را از داده‌ها استخراج کرده و پیش‌بینی‌های دقیقی ارائه دهند. دقت بالا و نمره F1 مناسب نشان‌دهنده قدرت DNNs در تعادل بین حساسیت و ویژگی است.
 - معایب: با وجود توانایی‌های قوی، DNNs نیاز به حجم زیادی از داده‌ها برای آموزش دارند و ممکن است به زمان و منابع محاسباتی زیادی نیاز داشته باشند. همچنین، تنظیم دقیق هایپارامترها و پیشگیری از بیش‌برازش در این مدلها می‌تواند چالش‌برانگیز باشد. برای مسائل با داده‌های ترتیبی و زمانی، DNNs ممکن است به اندازه الگوریتم‌های خاص‌تر مانند RNNs موثر نباشند.
 - شبکه‌های عصبی کانولوشنی
 - مزایا: شبکه‌های عصبی کانولوشنی به‌ویژه در استخراج ویژگی‌های محلی از داده‌ها مؤثر هستند و می‌توانند به‌خوبی اطلاعات مهم را از داده‌های پیچیده جدا کنند. این مدلها به دلیل معماری خاص خود، معمولاً به زمان آموزش کمتری نسبت به DNNs نیاز دارند و به‌خوبی با داده‌های با ابعاد بالا کار می‌کنند.
 - معایب: در زمینه پیش‌بینی ریسک اعتباری که نیاز به تحلیل داده‌های ترتیبی و زمانی دارد، CNNs ممکن است به اندازه RNNs کارآمد نباشند. همچنین، عملکرد این مدلها در تحلیل الگوهای زمانی و پیش‌بینی تغییرات زمانی نسبت به DNNs و RNNs ممکن است محدودتر باشد. کاهش عملکرد این مدلها در این حوزه‌ها می‌تواند به دلیل عدم توجه به توالی زمانی داده‌ها باشد.
 - شبکه‌های عصبی بازگشتی
 - مزایا: شبکه‌های عصبی بازگشتی برای پردازش داده‌های ترتیبی و زمانی بهینه شده‌اند و قادر به شبیه‌سازی الگوهای زمانی در داده‌های بانکی هستند. این مدلها با دقت بالا و نمره F1 قوی، توانسته‌اند بهترین عملکرد را در پیش‌بینی ریسک اعتباری ارائه دهند. RNNs می‌توانند تغییرات زمانی و وابستگی‌های طولانی‌مدت را در داده‌ها به‌خوبی درک کنند.
 - معایب: RNNs به دلیل پیچیدگی‌های ساختاری و نیاز به پردازش‌های توالی‌محور ممکن است به زمان آموزش طولانی‌تری نیاز داشته باشند و به منابع محاسباتی بیشتری نیاز دارند. همچنین، ممکن است در برخی موارد با مشکل ناپایداری و انتشار گرادیان مواجه شوند که می‌تواند به عملکرد کلی مدل آسیب بزند.

جدول ۷. مزایا و معایب هر الگوریتم

مدل	مزایا	معایب
شبکه عصبی پیچیده	قابلیت شبیه‌سازی الگوهای پیچیده و غیرخطی دقت بالا و نمره F1 مناسب توانایی استخراج ویژگی‌های پیچیده از داده‌ها	نیاز به حجم زیادی از داده‌ها برای آموزش نیاز به زمان و منابع محاسباتی زیاد ممکن است در تحلیل داده‌های ترتیبی و زمانی کمتر موثر باشد
شبکه عصبی کانولوشنی	مؤثر در استخراج ویژگی‌های محلی نیاز به زمان آموزش کمتر نسبت به DNNs عملکرد خوب با داده‌های با ابعاد بالا	عملکرد محدودتر در تحلیل داده‌های ترتیبی و زمانی ممکن است در پیش‌بینی تغییرات زمانی کمتر مؤثر باشد نیاز به تنظیمات خاص برای داده‌های ترتیبی
شبکه عصبی بازگشتی	بهینه برای پردازش داده‌های ترتیبی و زمانی توانایی شبیه‌سازی الگوهای زمانی و وابستگی‌های طولانی‌مدت بهترین عملکرد در پیش‌بینی ریسک اعتباری	نیاز به زمان آموزش طولانی و منابع محاسباتی زیاد مشکلات ناپایداری و انتشار گرادیان ممکن است پیش بیاید پیچیدگی‌های ساختاری ممکن است مدیریت شود سخت

نتیجه‌گیری

نتایج به‌دست‌آمده از ارزیابی مدل‌های یادگیری عمیق مختلف بر روی مجموعه داده‌های بانکی نشان‌دهنده عملکرد متفاوت هر الگوریتم در پیش‌بینی و کاهش ریسک اعتباری است. این نتایج شامل شبکه‌های عصبی پیچیده، شبکه‌های عصبی کانولوشنی و شبکه‌های عصبی بازگشتی بوده و می‌تواند به درک بهتر از کاربردهای هر مدل در این حوزه کمک کند. شبکه‌های عصبی بازگشتی با دقت ۸۸٪ و نمره ۸۷٪ F1، بهترین عملکرد را در پیش‌بینی ریسک اعتباری ارائه داده‌اند. این مدل‌ها به دلیل توانایی برجسته‌شان در پردازش داده‌های ترتیبی و زمانی و شبیه‌سازی الگوهای تغییرات زمانی در داده‌ها، توانسته‌اند نتایج دقیق‌تری ارائه دهند. حساسیت بالا (۸۶٪) و ویژگی قوی (۹۰٪) به‌خوبی نشان‌دهنده توانایی RNNs در شناسایی دقیق مثبت‌ها و منفی‌های واقعی است. این عملکرد برتر، توانایی RNNs در درک وابستگی‌های طولانی‌مدت و الگوهای زمانی پیچیده را تأیید می‌کند. در مقابل، شبکه‌های عصبی پیچیده با دقت ۸۵٪ و نمره ۸۴٪ F1، عملکرد خوبی در تحلیل و شناسایی الگوهای پیچیده داده‌های بانکی نشان داده‌اند. این مدل‌ها توانایی خوبی در استخراج ویژگی‌های پیچیده و ایجاد تعادل میان حساسیت (۸۳٪) و ویژگی (۸۷٪) دارند. با این حال، DNNs برای تحلیل داده‌های ترتیبی و زمانی ممکن است به اندازه RNNs کارآمد نباشند و نیاز به حجم زیادی از داده‌ها و منابع محاسباتی دارند. شبکه‌های عصبی کانولوشنی، با دقت ۸۲٪ و نمره ۸۱٪ F1، توانسته‌اند ویژگی‌های محلی را از داده‌ها استخراج کنند، اما عملکرد آنها در مقایسه با DNNs و RNNs کمی کمتر بوده است. حساسیت ۸۰٪ و ویژگی ۸۴٪ نشان‌دهنده توانایی CNNs در شناسایی مثبت‌ها و منفی‌های واقعی است، اما به دلیل ساختار خاص خود، ممکن است در تحلیل داده‌های ترتیبی و زمانی و پیش‌بینی تغییرات زمانی کمتر مؤثر باشند. تفسیر نتایج به‌دست‌آمده نشان می‌دهد که RNNs به‌عنوان بهترین مدل برای پیش‌بینی و کاهش ریسک اعتباری در مجموعه داده‌های بانکی شناخته شده است، به دلیل عملکرد برتر در تحلیل الگوهای زمانی و تغییرات دوره‌های DNNs و CNNs نیز به‌طور مؤثر عمل کرده‌اند، اما به ترتیب در تحلیل داده‌های پیچیده و استخراج ویژگی‌های محلی موفقیت کمتری نسبت به RNNs داشته‌اند. این نتایج بر اهمیت انتخاب مدل مناسب بر اساس ویژگی‌های خاص داده‌ها و نیازهای پیش‌بینی تأکید می‌کند و به بهبود فرآیندهای مدیریت ریسک اعتباری در سیستم‌های بانکی کمک می‌نماید.

ملاحظات اخلاقی

مشارکت نویسندگان

مشارکت نویسندگان در این مقاله به شکل زیر است:

نویسنده اول: تهیه و آماده‌سازی نمونه‌ها، انجام آزمایش و گردآوری داده‌ها، انجام محاسبات، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج، تهیه پیش‌نویس مقاله.

نویسنده دوم: استاد راهنمای پایان‌نامه، طراحی پژوهش، نظارت بر مراحل انجام پژوهش، بررسی و کنترل نتایج، اصلاح، بازبینی.

تعارض منافع

بر اساس اظهارات نویسندگان، این مقاله تعارض منافی ندارد.

حامی مالی

بنابر اظهارات نویسندگان این پژوهش هیچگونه حامی مالی ندارد.

سپاسگزاری

از تمامی مشارکت کنندگان در این پژوهش سپاسگزاری می‌شود.

منابع

- خلوصی، ع و خدابخشی، ا. (۱۴۰۱). نحوه پاسخ ریسک اعتباری بانک ها به شوک های ارزی، تورمی و مخارج دولت در ایران، *فصلنامه اقتصاد مالی*، ۱۸(۶۷).
- دهقان منشادی، س، م و روستا، س. (۱۴۰۳). تاثیر ریسک اعتباری و ریسک نقدینگی بر ثبات مالی بانک های پذیرفته شده، دهمین کنفرانس بین المللی علوم مدیریت و حسابداری. تهران.
- ربیعی، م. و و فخاریان زاده، ی. (۱۴۰۳). پیش بینی ریسک اعتباری مشتریان بانکی با استفاده از شبکه عصبی و الگوریتم بهینه سازی بازی آشوب، بیست و دومین کنفرانس ملی مهندسی برق، کامپیوتر و مکانیک. شیروان.
- شکراللهی ف و. عبدالباقی عطاءآبادی. (۱۴۰۳). فراتحلیل عوامل تعیین کننده ریسک اعتباری بانک ها، ”اولین همایش علوم انسانی با رویکرد نوین. آستارا.
- قلی زاده، ع و شالیاری، ف. (۱۳۹۶). بررسی اثرگذاری متغیرهای اقتصادی بر ریسک اعتباری سیستم بانکی کشور، *مجله اقتصاد و بانکداری اسلامی*، ۱۶(۲۰).

References

- Bodaghi, F., Owhadi, A., Khalili Nasr, A. & Khadem Sameni, M. (2023). Stock Price Forecasting in Iran Stock Market: A Comparative Analysis of Deep-learning.
- Cagliero, L., Fior, J. & Garza, P., (2023). Shortlisting machine learning -based stock trading recommendations using candlestick pattern recognition, *Expert Syst. Appl.*, 216, 119493
- Dakalbab, F., Talib, M. A., Nassir, Q. & Ishak, T. (2024). Artificial intelligence in techniques in financial trading: A systematic literature review, *J. King Saud Univ. Inf. Sci.*, 102015
- Gholizade, A. & Shalyari, F. (2018). Investigating the impact of macro economics on credit risk in banking system, *Economic and Islamic Journal*, 6(20)
- Gong, Z. (2023). Deep learning for trading and hedging in financial markets. University of Essex.
- Htun, H. H., Biehl, M. & Petkov, N. (2023). Survey of feature selection and extraction techniques for stock market prediction, *Financ. Innov*, 9(1), 26.
- Kaur, K., Kumar, Y. & Kaur, S. (2023). Artificial Intelligence and Machine Learning in Financial Services to Improve the Business System, in *Computational Intelligence for Modern Business Systems: Emerging Applications and Strategies*, Springer, pp3-30
- Kholousi, A., & khodabahshi, A. (2021). Credit risk in banks and currency, Inflation shocks in Iran, *Financial Economic Journal*, 18(67).
- Kulshrestha, N., Kamra, V. & Aggarwal, S. (2023). Leveraging technical analysis and artificial intelligence-optimisation of global portfolio management through world. learning in finance: status, development and future directions, *Kybernetes.*,
- Lim, B. & Zohren, S. (2021). Time-series forecasting with deep learning: a survey,” *Philos fusion-guided intervention, Int. J. Comput. Assist. Radiol. Surg.*, vol. 15, pp. 963-972.
- Milke, V. (2023). “Intraday machine learning for the securities market.” *Anglia Ruskin Research Online (ARRO)*
- Mondal, B. & Dandapat, A. (2023). Machine learning and deep learning based stock marketprediction considering Covid-19 as a feature, in *2022 OPJU International Technology Conference on Emerging Technologies for Sustainable Development (OTCON)*, IEEE, , pp. 1-6.
- Rabie Fakharianzade, E. (2024). Predicting the credit risk in banks customers using neural network.national conference in computer engineering .Shirvan
- Shafiekhani, S. Namdar, P. & Rafiei, S. (2022). A COVID-19 forecasting system for hospital needs using ANFIS and LSTM models: A graphical user interface unit, *Digit. Heal.*, 8.
- Shokrollahi, F. & Abdolbaghi, A. (2024). Metaanalysis in factors affected credit risk in banks.first conference in management. Astara.
- Sokolovsky, A., Arnaboldi, L., Bacardit, J. & T. Gross, T. (2023). Interpretable trading pattern designed for machine learning applications, *Mach. Learn. with Appl.*, 11, 100448.
- Verma, S., S. Sahu, P. & T Sahu, P. (2023) Stock Market Forecasting with Different Input Indicators using Machine Learning and Deep Learning Techniques: A Review., *Eng Lett.*, 31, 1.