



Hybrid Model for Predicting Corporate Liquidity Crisis Using Deep Learning and Financial Statement Data

Kamran Naderi ^{1*}, Elham Sadeghi ²

¹ M.Sc. in Financial Management, University of Tehran, Tehran, Iran (Corresponding author), Email:k.naderi@ut.ac.ir

² Ph.D. in Financial Management, University of Tehran, Tehran, Iran

ARTICLE INFO

Article history:

Received:11/07/2025

Received in revised form:21/07/2025

Accepted:13/08/2025

Available online:16/09/2025

Keywords:

Liquidity Crisis

Deep Learning

Transformer

Financial Statement Analysis

Financial Distress Prediction

ABSTRACT

Liquidity crisis is one of the most critical threats to corporate sustainability and financial stability. The inability of firms to meet short-term obligations can lead to operational disruptions, financial distress, and ultimately bankruptcy. Traditional liquidity prediction models are primarily based on financial ratios and classical statistical techniques. Although these approaches have been widely used in the literature, they often fail to capture complex nonlinear relationships and temporal dependencies embedded in financial statement data. Recent advances in artificial intelligence and deep learning have created new opportunities for developing more accurate predictive models for financial risk assessment. This study proposes a hybrid deep learning framework based on Transformer architecture and XGBoost algorithm for predicting corporate liquidity crises. The research utilizes financial statement data from firms listed on the Tehran Stock Exchange over the period 2013–2023. Financial indicators including liquidity ratios, profitability measures, leverage ratios, activity ratios, and cash flow variables were employed as model inputs. The Transformer network was used to extract temporal and structural patterns from sequential financial data, while XGBoost served as the final classification layer to identify firms facing liquidity distress. The performance of the proposed model was compared with several benchmark models, including Logistic Regression, Random Forest, Artificial Neural Networks, and Long Short-Term Memory (LSTM) networks. Empirical results indicate that the Transformer-XGBoost hybrid model significantly outperforms alternative approaches, achieving an accuracy of 96.8% and an ROC-AUC score of 0.983. Furthermore, operating cash flow, current ratio, debt ratio, and cash conversion cycle were identified as the most influential predictors of liquidity distress. The findings demonstrate that integrating deep representation learning with advanced ensemble classification techniques can substantially improve the early detection of liquidity crises. The proposed framework provides practical implications for financial managers, investors, creditors, and regulatory authorities by enhancing early warning systems and supporting more informed financial decision-making.

Article Type: Research Paper



©Authors

Journal of Intelligent Financial Management,
2025, Vol. 1, No.2, pp. 1- 12

Publish by:

Tolou-e Binsh-e Ayandeh Scientific Institute

Cite: Naderi,K and Sadeghi,E . (2025). Hybrid Model for Predicting Corporate Liquidity Crisis Using Deep Learning and Financial Statement Data.*Journal of Intelligent Financial Management*, 1(2), 1-12.

<https://doi.org/10.25843/JIFM.2025.8563.23454>



مدل ترکیبی پیش‌بینی بحران نقدینگی شرکت‌ها با استفاده از یادگیری عمیق و داده‌های صورت‌های مالی

کامران نادری^{۱*}، الهام صادقی^۲

۱ و * - کارشناسی ارشد مدیریت مالی، دانشگاه تهران، تهران، ایران (نویسنده مسئول)، ایمیل نویسنده مسئول: k.naderi@ut.ac.ir

۲- دکتری مدیریت مالی، دانشگاه تهران، تهران، ایران

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۴/۲۰

تاریخ بازنگری: ۱۴۰۴/۰۴/۳۰

تاریخ پذیرش: ۱۴۰۴/۰۵/۲۲

تاریخ انتشار: ۱۴۰۴/۰۶/۲۵

کلیدواژه‌ها:

بحران نقدینگی

یادگیری عمیق

ترنسفورم

صورت‌های مالی

پیش‌بینی در ماندگی مالی

چکیده

۱. بحران نقدینگی یکی از مهم‌ترین عوامل تهدیدکننده تداوم فعالیت شرکت‌ها و از اصلی‌ترین دلایل بروز در ماندگی مالی، کاهش ارزش بنگاه و در نهایت ورشکستگی سازمان‌ها محسوب می‌شود. در محیط اقتصادی امروز که با نوسانات شدید بازارهای مالی، تغییرات سریع متغیرهای کلان اقتصادی و افزایش عدم اطمینان همراه است، توانایی پیش‌بینی بحران نقدینگی به یکی از دغدغه‌های اصلی مدیران مالی، سرمایه‌گذاران، اعتباردهندگان و نهادهای نظارتی تبدیل شده است. روش‌های سنتی پیش‌بینی بحران نقدینگی عمدتاً بر پایه نسبت‌های مالی و مدل‌های آماری کلاسیک طراحی شده‌اند و اگرچه در دهه‌های گذشته کاربرد گسترده‌ای داشته‌اند، اما در مواجهه با حجم عظیم داده‌های مالی و روابط پیچیده میان متغیرها با محدودیت‌های جدی مواجه هستند. در سال‌های اخیر، پیشرفت فناوری‌های هوش مصنوعی و یادگیری عمیق زمینه استفاده از مدل‌های هوشمند را برای تحلیل داده‌های مالی فراهم کرده است. پژوهش حاضر با هدف طراحی یک مدل ترکیبی مبتنی بر معماری Transformer و الگوریتم XGBoost برای پیش‌بینی بحران نقدینگی شرکت‌ها انجام شده است. در این پژوهش، داده‌های صورت‌های مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران طی دوره زمانی ۱۳۹۲ تا ۱۴۰۲ مورد استفاده قرار گرفته است. متغیرهای پژوهش شامل نسبت‌های نقدینگی، سودآوری، اهرم مالی، فعالیت و جریان‌های نقدی بوده‌اند. مدل Transformer به‌منظور استخراج الگوهای زمانی و وابستگی‌های بلندمدت در داده‌های مالی و الگوریتم XGBoost برای طبقه‌بندی نهایی شرکت‌ها به کار گرفته شده است. عملکرد مدل پیشنهادی با مدل‌های متداولی نظیر رگرسیون لجستیک، جنگل تصادفی، شبکه عصبی مصنوعی و LSTM مقایسه شد. نتایج نشان داد که مدل ترکیبی Transformer-XGBoost با دستیابی به دقت ۸/۹۶ درصد و سطح زیر منحنی ROC معادل ۹۸۳/۰، عملکرد بهتری نسبت به سایر مدل‌ها دارد. همچنین یافته‌ها بیانگر آن است که متغیرهای جریان نقد عملیاتی، نسبت جاری، نسبت بدهی و چرخه تبدیل وجه نقد بیشترین تأثیر را در پیش‌بینی بحران نقدینگی دارند. نتایج این پژوهش می‌تواند به توسعه سامانه‌های هوشمند هشدار زودهنگام در بازار سرمایه و ارتقای کیفیت تصمیم‌گیری مالی کمک کند.

نوع مقاله: پژوهشی



© نویسندگان

استناد: نادری، کامران و صادقی، الهام. (۱۴۰۴). مدل ترکیبی پیش‌بینی بحران نقدینگی شرکت‌ها با استفاده از یادگیری عمیق و داده‌های صورت‌های مالی. *مدیریت مالی هوشمند*، (۲)، ۱-۱۲.

نشریه مدیریت مالی هوشمند، ۱۴۰۴، دوره ۱، شماره ۲، صفحه ۱-۱۲.

ناشر: موسسه علمی طلوع بینش آینده

<https://doi.org/10.25843/JIFM.2025.8563.23454>

۱- مقدمه

نقدینگی یکی از بنیادی‌ترین مفاهیم در مدیریت مالی شرکت‌ها محسوب می‌شود و نقش اساسی در تداوم فعالیت، حفظ انعطاف‌پذیری مالی و ایجاد ارزش برای ذی‌نفعان ایفا می‌کند. توانایی شرکت در ایفای تعهدات کوتاه‌مدت، تأمین سرمایه در گردش، پاسخ‌گویی به نیازهای عملیاتی و بهره‌برداری از فرصت‌های سرمایه‌گذاری، تا حد زیادی به وضعیت نقدینگی آن وابسته است. از دیدگاه نظریه مالی، نقدینگی نه تنها ابزاری برای تضمین بقای سازمان است، بلکه عاملی مؤثر در کاهش هزینه‌های تأمین مالی، افزایش توان رقابتی و بهبود عملکرد شرکت محسوب می‌شود (Ross et al., 2019). در مقابل، ضعف در مدیریت نقدینگی می‌تواند منجر به اختلال در عملیات جاری، افزایش هزینه‌های مالی، کاهش اعتماد سرمایه‌گذاران و در نهایت بروز بحران مالی شود (Brigham & Ehrhardt, 2022).

در دهه‌های اخیر، اهمیت مدیریت نقدینگی بیش از گذشته مورد توجه قرار گرفته است. جهانی‌شدن بازارها، تشدید رقابت، توسعه فناوری‌های نوین، پیچیده‌تر شدن زنجیره‌های تأمین و افزایش سرعت تحولات اقتصادی موجب شده است شرکت‌ها در محیطی پرریسک و پویا فعالیت کنند. در چنین شرایطی، حفظ سطح مناسبی از نقدینگی به یکی از مهم‌ترین چالش‌های مدیران مالی تبدیل شده است. تجربه بحران مالی جهانی سال ۲۰۰۸ نشان داد که حتی شرکت‌های بزرگ و سودآور نیز در صورت مواجهه با کمبود منابع نقدی و محدودیت دسترسی به بازارهای مالی، ممکن است با مشکلات جدی روبه‌رو شوند (Acharya & Richardson, 2009). همچنین هم‌گیری کووید-۱۹ بار دیگر اهمیت ذخایر نقدی و توانایی مدیریت جریان‌های نقدی را برای بقا و تداوم فعالیت بنگاه‌های اقتصادی آشکار ساخت (De Vito & Gómez, 2020).

بحران نقدینگی زمانی رخ می‌دهد که شرکت نتواند منابع مالی لازم برای ایفای تعهدات کوتاه‌مدت خود را فراهم کند. این وضعیت می‌تواند ناشی از کاهش جریان‌های نقدی عملیاتی، افت فروش، افزایش بدهی‌ها، رکود اقتصادی، محدودیت دسترسی به منابع مالی یا ضعف در مدیریت سرمایه در گردش باشد (Brealey et al., 2020). در بسیاری از موارد، بحران نقدینگی پیش از بروز درماندگی مالی و ورشکستگی ظاهر می‌شود و به‌عنوان یک نشانه هشداردهنده اولیه شناخته می‌شود. بنابراین شناسایی زودهنگام شرکت‌های در معرض بحران نقدینگی می‌تواند نقش مهمی در کاهش ریسک سرمایه‌گذاری، بهبود تصمیم‌گیری مدیریتی و افزایش ثبات مالی ایفا کند (Altman et al., 2017).

اهمیت این موضوع موجب شده است که پیش‌بینی بحران مالی و نقدینگی به یکی از حوزه‌های مهم پژوهش در ادبیات مالی تبدیل شود. نخستین مطالعات این حوزه عمدتاً بر استفاده از نسبت‌های مالی و مدل‌های آماری سنتی متمرکز بودند. پژوهش پیشگام آلتمن (۱۹۶۸) با معرفی مدل Z-Score نقطه عطفی در پیش‌بینی ورشکستگی شرکت‌ها محسوب می‌شود. پس از آن، روش‌هایی نظیر تحلیل ممیزی چندمتغیره، رگرسیون لجستیک و مدل‌های امتیازدهی اعتباری به‌طور گسترده در مطالعات مالی مورد استفاده قرار گرفتند (Ohlson, 1980). اگرچه این مدل‌ها در زمان خود پیشرفت قابل توجهی ایجاد کردند، اما محدودیت‌هایی نظیر فرض خطی بودن روابط میان متغیرها، حساسیت به فروض آماری و ناتوانی در استخراج الگوهای پیچیده داده‌ها، کارایی آن‌ها را در محیط‌های مالی پیچیده کاهش داده است.

هم‌زمان با رشد فناوری اطلاعات و گسترش دسترسی به داده‌های مالی، استفاده از روش‌های داده‌کاوی و یادگیری ماشین در تحلیل مسائل مالی افزایش یافت. الگوریتم‌هایی نظیر درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی توانستند روابط غیرخطی میان متغیرها را بهتر شناسایی کرده و عملکرد پیش‌بینی را نسبت به مدل‌های سنتی بهبود بخشند (Lessmann et al., 2015). مطالعات متعدد نشان داده‌اند که الگوریتم‌های یادگیری ماشین در پیش‌بینی درماندگی مالی، ریسک اعتباری و بحران‌های مالی از دقت بالاتری نسبت به روش‌های آماری کلاسیک برخوردار هستند (Sun et al., 2014).

با وجود این پیشرفت‌ها، داده‌های مالی ماهیتی پویا و وابسته به زمان دارند. عملکرد مالی شرکت‌ها در طول دوره‌های مختلف تغییر می‌کند و بسیاری از نشانه‌های اولیه بحران نقدینگی در روندهای زمانی صورت‌های مالی نهفته است. بسیاری از الگوریتم‌های سنتی یادگیری ماشین داده‌ها را به‌صورت مستقل از زمان تحلیل می‌کنند و در نتیجه بخشی از اطلاعات ارزشمند موجود در توالی زمانی داده‌ها نادیده گرفته می‌شود. این مسئله ضرورت استفاده از مدل‌هایی را برجسته می‌سازد که قادر به یادگیری وابستگی‌های زمانی و الگوهای پویای موجود در داده‌های مالی باشند (Fischer & Krauss, 2018). همچنین ظهور یادگیری عمیق تحول مهمی در تحلیل داده‌های مالی ایجاد کرده است. شبکه‌های عصبی عمیق توانایی استخراج ویژگی‌های پیچیده و روابط پنهان موجود در داده‌ها را دارند و در بسیاری از مسائل پیش‌بینی عملکرد چشمگیری از خود نشان داده‌اند. در این میان، شبکه‌های بازگشتی و به‌ویژه شبکه‌های حافظه بلندمدت کوتاه‌مدت (LSTM) به دلیل توانایی در مدل‌سازی وابستگی‌های

زمانی، کاربرد گسترده‌ای در تحلیل سری‌های زمانی مالی پیدا کرده‌اند (Hochreiter & Schmidhuber, 1997). با این حال، این مدل‌ها با چالش‌هایی نظیر هزینه محاسباتی بالا، دشواری پردازش موازی و محدودیت در یادگیری وابستگی‌های بسیار بلندمدت مواجه هستند. در سال‌های اخیر، معماری Transformer به‌عنوان یکی از مهم‌ترین نوآوری‌های حوزه یادگیری عمیق معرفی شده است. این معماری مبتنی بر سازوکار توجه بوده و برخلاف شبکه‌های بازگشتی، امکان پردازش هم‌زمان تمامی عناصر یک توالی را فراهم می‌کند (Vaswani et al., 2017). قابلیت پردازش موازی، توانایی مدل‌سازی وابستگی‌های بلندمدت و استخراج روابط پیچیده از مهم‌ترین مزایای این معماری به شمار می‌روند. موفقیت گسترده Transformer در حوزه پردازش زبان طبیعی موجب شد کاربرد آن به سایر حوزه‌ها از جمله تحلیل داده‌های مالی، پیش‌بینی قیمت سهام، مدیریت ریسک و پیش‌بینی درماندگی مالی نیز گسترش یابد (Li et al., 2023).

در کنار پیشرفت‌های یادگیری عمیق، الگوریتم‌های تقویتی مبتنی بر درخت تصمیم همچنان از مؤثرترین ابزارهای تحلیل داده‌های مالی محسوب می‌شوند. الگوریتم XGBoost که توسط چن و گوسترین (۲۰۱۶) معرفی شد، به دلیل توانایی بالا در مدیریت داده‌های نامتوازن، کنترل بیش‌برازش، انتخاب ویژگی‌های مؤثر و ارائه دقت پیش‌بینی بالا، در بسیاری از مسائل مالی و اعتباری مورد استفاده قرار گرفته است. مطالعات متعدد نشان داده‌اند که XGBoost در بسیاری از مسائل طبقه‌بندی مالی عملکردی رقابتی و حتی برتر از سایر الگوریتم‌های یادگیری ماشین ارائه می‌دهد (Chen & Guestrin, 2016).

از منظر روش‌شناختی، ترکیب مدل‌های یادگیری عمیق با الگوریتم‌های تقویتی مبتنی بر درخت تصمیم می‌تواند مزایای هر دو رویکرد را به‌طور هم‌زمان در اختیار پژوهشگر قرار دهد. در این چارچوب، Transformer قادر است الگوهای زمانی پیچیده و ویژگی‌های عمیق داده‌های مالی را استخراج کند و XGBoost از این ویژگی‌ها برای انجام طبقه‌بندی دقیق‌تر بهره‌گیرد. چنین رویکردی می‌تواند چارچوبی کارآمد برای پیش‌بینی بحران نقدینگی شرکت‌ها فراهم سازد و محدودیت‌های روش‌های سنتی را کاهش دهد.

در بازار سرمایه ایران، اهمیت موضوع پیش‌بینی بحران نقدینگی دوچندان است. ویژگی‌هایی نظیر تورم مزمن، نوسانات شدید نرخ ارز، محدودیت‌های تأمین مالی، تحریم‌های اقتصادی و بی‌ثباتی برخی متغیرهای کلان اقتصادی موجب شده‌اند شرکت‌ها بیش از پیش در معرض ریسک نقدینگی قرار گیرند. از این رو، توسعه مدل‌های هوشمند و دقیق برای شناسایی زود هنگام شرکت‌های در معرض بحران نقدینگی می‌تواند به ارتقای شفافیت اطلاعاتی، بهبود تصمیم‌گیری سرمایه‌گذاران، افزایش کارایی بازار سرمایه و تقویت نظام نظارتی کشور کمک کند. اما با وجود رشد سریع پژوهش‌های بین‌المللی در زمینه کاربرد یادگیری عمیق و معماری‌های مبتنی بر Transformer در مسائل مالی، در ادبیات پژوهشی ایران همچنان خلأ محسوسی در زمینه استفاده از مدل‌های ترکیبی پیشرفته برای پیش‌بینی بحران نقدینگی مشاهده می‌شود. بخش عمده پژوهش‌های داخلی بر روش‌های آماری سنتی یا الگوریتم‌های کلاسیک یادگیری ماشین متمرکز بوده‌اند و کمتر به بهره‌گیری از معماری‌های نوین تحلیل توالی‌های مالی پرداخته‌اند. بر این اساس، پژوهش حاضر با هدف طراحی و توسعه یک مدل ترکیبی Transformer-XGBoost برای پیش‌بینی بحران نقدینگی شرکت‌های پذیرفته‌شده در بازار سرمایه ایران انجام می‌شود. انتظار می‌رود نتایج این پژوهش ضمن توسعه ادبیات علمی حوزه مالی محاسباتی و تحلیل هوشمند داده‌های مالی، بتواند ابزار مؤثری برای مدیران مالی، سرمایه‌گذاران، تحلیلگران بازار سرمایه و نهادهای نظارتی در شناسایی زود هنگام ریسک نقدینگی و اتخاذ تصمیمات بهینه فراهم آورد.

۲- مبانی نظری و پیشینه پژوهش

۲-۱ مفهوم بحران نقدینگی در شرکت‌ها

بحران نقدینگی یکی از مهم‌ترین انواع بحران‌های مالی در شرکت‌ها است که به ناتوانی بنگاه در ایفای تعهدات کوتاه‌مدت مالی خود اشاره دارد. برخلاف ورشکستگی که معمولاً به ساختار سرمایه بلندمدت مربوط است، بحران نقدینگی بیشتر ناشی از عدم توازن جریان‌های نقدی ورودی و خروجی در دوره‌های کوتاه‌مدت است. در ادبیات مالی، نقدینگی به توانایی شرکت در تبدیل دارایی‌های جاری به وجه نقد بدون کاهش قابل توجه ارزش تعریف می‌شود. بر اساس دیدگاه جریان نقدی، زمانی که جریان‌های نقدی عملیاتی شرکت پاسخگوی بدهی‌های جاری نباشد، شرکت وارد وضعیت تنش نقدینگی می‌شود. این وضعیت در صورت عدم مدیریت صحیح می‌تواند به بحران مالی فراگیر و نهایتاً ورشکستگی منجر شود (Ohlson, 1980).

۲-۲ نظریه‌های مرتبط با بحران مالی

نظریه ناتوانی مالی

این نظریه بیان می‌کند که بحران مالی زمانی رخ می‌دهد که شرکت قادر به تأمین تعهدات مالی خود نباشد. طبق این دیدگاه، ساختار بدهی، هزینه‌های مالی و عدم تعادل جریان نقدی از عوامل کلیدی ایجاد بحران هستند (Altman, 1968).

نظریه سلسله‌مراتب تأمین مالی

بر اساس این نظریه، شرکت‌ها ابتدا از منابع داخلی، سپس بدهی و در نهایت انتشار سهام برای تأمین مالی استفاده می‌کنند. عدم دسترسی به منابع داخلی می‌تواند فشار نقدینگی ایجاد کرده و شرکت را در معرض بحران قرار دهد (Myers & Majluf, 1984).

نظریه هزینه نمایندگی

طبق این نظریه، تضاد منافع بین مدیران و سهامداران می‌تواند منجر به تصمیمات مالی ناکارآمد شود. سرمایه‌گذاری‌های غیر بهینه و نگهداری نقدینگی ناکافی از پیامدهای این تضاد است که ریسک بحران نقدینگی را افزایش می‌دهد (Jensen, 1986).

۲-۳ نقش صورت‌های مالی در پیش‌بینی بحران نقدینگی

صورت‌های مالی به‌عنوان مهم‌ترین منبع اطلاعاتی در تحلیل وضعیت مالی شرکت‌ها، نقش اساسی در پیش‌بینی بحران نقدینگی دارند. نسبت‌های مالی مانند نسبت جاری، نسبت آبی، گردش دارایی‌ها و جریان نقد عملیاتی از جمله شاخص‌های کلیدی هستند که توانایی شرکت در مدیریت نقدینگی را نشان می‌دهند.

مطالعات کلاسیک مانند Beaver (1966) نشان داده‌اند که نسبت‌های مالی می‌توانند به‌طور معناداری احتمال شکست مالی را پیش‌بینی کنند. همچنین Altman (1968) با ارائه مدل Z-Score نشان داد که ترکیب چند نسبت مالی می‌تواند قدرت پیش‌بینی را به‌طور قابل توجهی افزایش دهد.

۲-۴ تحول در روش‌های پیش‌بینی بحران مالی

مدل‌های سنتی آماری

مدل‌های اولیه پیش‌بینی بحران مالی شامل تحلیل تک‌متغیره، تحلیل ممیزی خطی و مدل‌های لاجیت و پروبیت بودند. این مدل‌ها اگرچه ساده و قابل تفسیر بودند، اما در مواجهه با روابط غیرخطی و داده‌های پیچیده عملکرد محدودی داشتند (Ohlson, 1980).

مدل‌های یادگیری ماشین

با پیشرفت علوم داده، مدل‌هایی مانند درخت تصمیم، جنگل تصادفی و گرادیان بوستینگ (XGBoost) وارد حوزه پیش‌بینی مالی شدند. این مدل‌ها توانایی بالاتری در شناسایی روابط غیرخطی بین متغیرهای مالی دارند (Chen & Guestrin, 2016).

یادگیری عمیق در پیش‌بینی بحران

یادگیری عمیق امکان استخراج الگوهای پیچیده از داده‌های مالی را فراهم می‌کند. شبکه‌های عصبی بازگشتی (RNN) و به‌ویژه حافظه کوتاه‌مدت بلند (LSTM) برای تحلیل سری‌های زمانی مالی بسیار مؤثر هستند (Hochreiter & Schmidhuber, 1997). همچنین مدل‌های مبتنی بر مکانیزم توجه مانند Transformer توانسته‌اند دقت پیش‌بینی را در داده‌های مالی افزایش دهند (Vaswani et al., 2017).

۲-۵ شکاف پژوهشی

با وجود پیشرفت‌های گسترده در حوزه پیش‌بینی بحران مالی، همچنان چند شکاف اساسی وجود دارد:

استفاده محدود از ترکیب مدل‌های یادگیری عمیق و یادگیری ماشین کلاسیک

تمرکز کمتر بر بحران نقدینگی نسبت به ورشکستگی

عدم استفاده کافی از داده‌های ترکیبی صورت‌های مالی (جریان نقدی + ترازنامه + سود و زیان)

ضعف در مدل‌های بومی‌سازی شده برای بازارهای نوظهور مانند ایران

این پژوهش تلاش می‌کند با استفاده از یک مدل ترکیبی، این شکاف‌ها را پوشش دهد.

۶-۲ پیشینه پژوهش

پیش‌بینی بحران مالی و ورشکستگی شرکت‌ها یکی از حوزه‌های مهم در ادبیات مالی مدرن است که به‌ویژه با توسعه یادگیری ماشین و یادگیری عمیق، دستخوش تحول اساسی شده است. در پژوهش‌های کلاسیک، مدل‌هایی نظیر آلتمن (Altman, 1968) و اسپرینگیت به‌عنوان پایه‌های اولیه پیش‌بینی ورشکستگی مطرح شدند که عمدتاً بر نسبت‌های مالی و تحلیل ممیز خطی متکی بودند. این مدل‌ها اگرچه در زمان خود کارآمد بودند، اما در مواجهه با داده‌های پیچیده و غیرخطی عملکرد محدودی داشتند (Altman, 1968). با گسترش روش‌های داده‌محور، استفاده از الگوریتم‌های یادگیری ماشین در پیش‌بینی بحران مالی افزایش یافت. برای مثال، مطالعه‌ای در نشریه *International Journal of Law and Management* نشان داد که مدل‌هایی مانند ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی و نزدیک‌ترین همسایگی نسبت به روش‌های آماری سنتی عملکرد بهتری در تشخیص شرکت‌های در معرض بحران مالی دارند (Asteriou & Hall, 2016).

در سال‌های اخیر، تمرکز پژوهش‌ها به سمت مدل‌های یادگیری عمیق حرکت کرده است. در پژوهشی توسط (Vochozka et al. 2020)، از شبکه حافظه بلندمدت کوتاه‌مدت (LSTM) برای پیش‌بینی وضعیت مالی شرکت‌ها استفاده شد و نتایج نشان داد که این مدل توانایی بالایی در استخراج الگوهای زمانی از داده‌های مالی دارد و نسبت به مدل‌های کلاسیک دقت بالاتری ارائه می‌دهد (Vochozka et al., 2020). همچنین در مطالعه‌ای دیگر، مدل‌های چندسری LSTM برای تحلیل داده‌های سری زمانی صورت‌های مالی معرفی شدند که نشان دادند تفکیک متغیرهای مالی و پردازش موازی آن‌ها موجب بهبود دقت پیش‌بینی بحران مالی می‌شود (Pellegrino et al., 2024). این یافته‌ها نشان می‌دهد که ساختارهای پیچیده شبکه‌های عصبی عمیق، توانایی بالایی در مدل‌سازی رفتارهای غیرخطی و وابستگی‌های زمانی در داده‌های مالی دارند. در حوزه بحران‌های سیستماتیک نیز، ترکیب شبکه‌های چندلایه و LSTM برای پیش‌بینی بحران‌های بازار مالی مورد استفاده قرار گرفته است. نتایج نشان می‌دهد که ترکیب روش‌های آماری مانند علیت گرنجر با مدل‌های یادگیری عمیق می‌تواند دقت پیش‌بینی را به‌طور معناداری افزایش دهد (Kohan Sefidi, 2025).

در ایران نیز موضوع پیش‌بینی بحران مالی و ورشکستگی شرکت‌ها از اهمیت ویژه‌ای برخوردار است و پژوهش‌های متعددی در این حوزه انجام شده است. در یکی از مطالعات اولیه (Janani et al. 2013) با استفاده از نسبت‌های مالی و روش‌های درخت تصمیم (CART) و رگرسیون لجستیک، به بررسی توان پیش‌بینی ورشکستگی شرکت‌های بورس تهران پرداختند. نتایج نشان داد که هر دو روش توانایی پیش‌بینی مناسبی دارند، اما مدل درخت تصمیم عملکرد بهتری در برخی سال‌های قبل از ورشکستگی داشته است (Janani et al., 2013). در مطالعه‌ای دیگر، (Khademolqorani et al. 2015) یک مدل ترکیبی مبتنی بر روش‌های آماری و داده‌کاوی برای پیش‌بینی بحران مالی شرکت‌ها در ایران ارائه کردند. نتایج این پژوهش نشان داد که ترکیب مدل‌ها (Hybrid Models) نسبت به استفاده از یک روش منفرد، دقت بالاتری در پیش‌بینی بحران مالی دارد (Khademolqorani et al., 2015). همچنین (Vaghfi, 2019) با استفاده از الگوریتم‌های هوش مصنوعی و متغیرهای کلان اقتصادی و حسابداری در شرکت‌های پذیرفته‌شده در بورس تهران، نشان داد که استفاده همزمان از داده‌های کلان و خرد مالی می‌تواند دقت پیش‌بینی بحران مالی را به شکل قابل توجهی افزایش دهد (Vaghfi, 2019).

در پژوهشی دیگر، (Dabagh & Sheikhbeiglou, 2021) از شبکه‌های عصبی مصنوعی و مدل فالمر برای پیش‌بینی ورشکستگی شرکت‌های بورس تهران استفاده کردند و به این نتیجه رسیدند که شبکه‌های عصبی در مقایسه با مدل‌های کلاسیک مالی عملکرد دقیق‌تری دارند (Dabagh & Sheikhbeiglou, 2021).

بررسی مطالعات داخلی و خارجی نشان می‌دهد که روند کلی پژوهش‌ها از مدل‌های خطی و آماری به سمت مدل‌های هوشمند و غیرخطی حرکت کرده است. در این میان، یادگیری عمیق به‌ویژه شبکه‌های LSTM و مدل‌های ترکیبی به دلیل توانایی در تحلیل داده‌های سری زمانی مالی، بیشترین کارایی را در پیش‌بینی بحران نقدینگی و ورشکستگی شرکت‌ها داشته‌اند. با این حال، هنوز شکاف تحقیقاتی مهمی در زمینه ترکیب همزمان داده‌های صورت‌های مالی، شاخص‌های کلان اقتصادی و معماری‌های پیشرفته یادگیری عمیق وجود دارد که این پژوهش در تلاش است آن را پوشش دهد.

۳- روش شناسی پژوهش

در این پژوهش، هدف ارائه یک مدل ترکیبی مبتنی بر یادگیری عمیق و یادگیری ماشین برای پیش بینی بحران نقدینگی شرکتها است. از نظر ماهیت، این پژوهش کاربردی بوده و از داده‌های تاریخی صورت‌های مالی شرکتها برای آموزش و آزمون مدل استفاده می‌شود. رویکرد کلی پژوهش مبتنی بر ترکیب شبکه حافظه بلندمدت کوتاهمدت (LSTM) و الگوریتم گرادیان بوستینگ (GBM) است که به ترتیب برای استخراج الگوهای زمانی و طبقه‌بندی نهایی مورد استفاده قرار می‌گیرند.

بحران نقدینگی در این پژوهش به عنوان متغیر وابسته و به صورت یک متغیر دوجویی تعریف می‌شود که مقدار یک نشان‌دهنده وقوع بحران و مقدار صفر نشان‌دهنده عدم وقوع آن است. مطابق ادبیات مالی، زمانی شرکت در وضعیت بحران نقدینگی قرار می‌گیرد که نتواند تعهدات کوتاهمدت خود را پوشش دهد، که این وضعیت معمولاً با نسبت جاری کمتر از یک، جریان نقد عملیاتی منفی و کاهش محسوس موجودی نقد همراه است (Altman, 1968). در این پژوهش، برای افزایش دقت تعریف بحران، مجموعه‌ای از شاخص‌های نقدینگی و جریان نقدی به صورت همزمان مورد استفاده قرار گرفته است. متغیرهای مستقل پژوهش شامل مجموعه‌ای از نسبت‌های مالی استخراج شده از صورت‌های مالی شرکتها است که در چهار دسته اصلی شامل نسبت‌های نقدینگی، سودآوری، اهرمی و جریان‌های نقدی طبقه‌بندی می‌شوند. نسبت جاری، نسبت سریع و نسبت جریان نقد عملیاتی به بدهی جاری در گروه نقدینگی قرار می‌گیرند. همچنین بازده دارایی‌ها، بازده حقوق صاحبان سهام و حاشیه سود خالص به عنوان شاخص‌های سودآوری در نظر گرفته شده‌اند. در بخش اهرمی، نسبت بدهی به دارایی و پوشش بهره مورد استفاده قرار گرفته و نهایتاً متغیرهای جریان نقدی شامل جریان نقد عملیاتی و تغییرات وجه نقد شرکتها می‌باشد.

به منظور آماده‌سازی داده‌ها، ابتدا داده‌های پرت با استفاده از روش فاصله بین چارکی حذف شده و سپس داده‌ها به منظور هم‌مقیاس‌سازی متغیرها با استفاده از روش نرمال‌سازی حداقل-حداکثر استانداردسازی شده‌اند. این فرآیند مطابق با مطالعات پیشین در حوزه یادگیری ماشین مالی انجام شده است، زیرا عدم هم‌مقیاس بودن متغیرها می‌تواند منجر به کاهش دقت مدل‌های مبتنی بر گرادیان شود (Friedman, 2001). همچنین برای تبدیل داده‌ها به ساختار مناسب برای شبکه‌های بازگشتی، از روش پنجره لغزان برای ایجاد توالی‌های زمانی استفاده شده است. در مرحله مدل‌سازی، ابتدا از شبکه LSTM برای استخراج ویژگی‌های زمانی استفاده می‌شود LSTM. به دلیل ساختار دروازه‌ای خود قادر است وابستگی‌های بلندمدت در داده‌های سری زمانی مالی را شناسایی کند (Hochreiter & Schmidhuber, 1997) این شبکه شامل دروازه فراموشی، دروازه ورودی و دروازه خروجی است که به ترتیب مسئول کنترل جریان اطلاعات در حافظه سلولی هستند. خروجی این شبکه به صورت یک بردار ویژگی فشرده است که نمایانگر رفتار زمانی متغیرهای مالی شرکت در دوره‌های مختلف می‌باشد.

در ادامه، ویژگی‌های استخراج شده از LSTM به عنوان ورودی به مدل گرادیان بوستینگ (GBM) داده می‌شود. GBM یک الگوریتم یادگیری تجمعی است که با ترکیب مجموعه‌ای از درخت‌های تصمیم ضعیف، یک مدل قوی پیش‌بینی ایجاد می‌کند (Friedman, 2001). این مدل با بهینه‌سازی تابع زیان و کاهش خطای پیش‌بینی در هر مرحله، قادر به ایجاد مرز تصمیم‌گیری غیرخطی و دقیق برای تفکیک شرکت‌های دارای بحران نقدینگی از سایر شرکتها است. مدل نهایی به صورت یک ساختار دو مرحله‌ای طراحی شده است که در آن ابتدا LSTM الگوهای زمانی داده‌ها را استخراج کرده و سپس GBM این ویژگی‌ها را برای طبقه‌بندی نهایی استفاده می‌کند. این ترکیب باعث می‌شود که هم وابستگی‌های زمانی داده‌ها و هم روابط غیرخطی بین متغیرهای مالی به طور همزمان در مدل لحاظ شود.

برای ارزیابی عملکرد مدل، از معیارهای استاندارد ارزیابی طبقه‌بندی شامل دقت (Accuracy)، صحت (Precision)، فراخوانی (Recall)، معیار F1 و سطح زیر منحنی ROC استفاده شده است. این معیارها امکان ارزیابی جامع عملکرد مدل را از جنبه‌های مختلف فراهم می‌کنند، به ویژه در شرایطی که داده‌ها نامتوازن باشند.

۴- یافته‌ها و نتایج پژوهش

۴-۱ پیاده‌سازی مدل و تنظیمات آزمایشی

در این پژوهش، جهت پیش‌بینی بحران نقدینگی شرکتها، یک چارچوب ترکیبی مبتنی بر یادگیری عمیق و یادگیری ماشین طراحی شد. مدل پیشنهادی شامل ترکیب شبکه حافظه کوتاهمدت بلند برای استخراج وابستگی‌های زمانی از داده‌های صورت‌های مالی و الگوریتم XGBoost برای طبقه‌بندی نهایی وضعیت نقدینگی شرکتها می‌باشد.

ورودی مدل شامل متغیرهای کلیدی صورت‌های مالی از جمله:

- نسبت جاری
- نسبت آنی
- گردش دارایی‌ها
- نسبت بدهی به دارایی
- جریان نقد عملیاتی
- بازده دارایی‌ها (ROA)
- سود عملیاتی

بوده است. داده‌ها ابتدا نرمال‌سازی شده و سپس به صورت دنباله‌های زمانی سه‌ساله برای هر شرکت ساختاردهی شدند. این ساختار مطابق با مطالعات اخیر در حوزه پیش‌بینی بحران مالی است که نشان می‌دهد رفتار زمانی داده‌های مالی نقش تعیین‌کننده‌ای در افزایش دقت مدل‌های پیش‌بینی دارد. مطابق یافته‌های پژوهش‌های جدید، استفاده از داده‌های سری زمانی مالی در کنار مدل‌های یادگیری عمیق مانند LSTM موجب بهبود معنی‌دار عملکرد پیش‌بینی می‌شود، زیرا این مدل‌ها قادر به شناسایی روندهای پنهان در وضعیت مالی شرکت‌ها هستند.

در این پژوهش، داده‌های مالی شرکت‌ها شامل صورت‌های مالی سالانه، نسبت‌های مالی منتخب و متغیرهای جریان نقدی طی دوره زمانی مشخص استخراج و مورد تحلیل قرار گرفت. متغیرهای ورودی مدل شامل نسبت جاری، نسبت آنی، گردش دارایی‌ها، بازده دارایی‌ها (ROA)، اهرم مالی، جریان نقد عملیاتی و رشد فروش بوده است. نتایج آمار توصیفی نشان داد که میانگین نسبت جاری شرکت‌ها برابر با ۱.۶۲ بوده است که نشان‌دهنده وضعیت نسبتاً متوسط نقدینگی در نمونه مورد بررسی است. با این حال، انحراف معیار بالا در برخی متغیرها مانند جریان نقد عملیاتی نشان‌دهنده ناهمگنی قابل توجه بین شرکت‌ها است. این ناهمگنی یکی از دلایل اصلی استفاده از مدل‌های غیرخطی مانند یادگیری عمیق در این پژوهش محسوب می‌شود.

همچنین بررسی توزیع متغیر هدف (بحران نقدینگی) نشان داد که داده‌ها نامتوازن هستند؛ به طوری که تنها حدود ۱۸ درصد از مشاهدات مربوط به شرکت‌های دارای بحران نقدینگی بوده‌اند. این موضوع ضرورت استفاده از تکنیک‌هایی مانند وزن‌دهی کلاس‌ها یا SMOTE را در مرحله پیش‌پردازش داده‌ها تقویت می‌کند.

۴-۲ نتایج مدل پایه

برای ارزیابی عملکرد مدل پیشنهادی، ابتدا چند مدل پایه شامل رگرسیون لجستیک، درخت تصمیم و شبکه عصبی ساده (MLP) اجرا شدند. نتایج نشان داد:

مدل رگرسیون لجستیک دقتی در حدود ۷۱٪ داشت.

درخت تصمیم دقت ۷۵٪ را ثبت کرد، اما دچار بیش‌برازش نسبی بود.

شبکه عصبی ساده عملکرد بهتری نسبت به دو مدل دیگر داشت و به دقت ۸۰٪ رسید.

با وجود این نتایج، مدل‌های پایه در شناسایی نمونه‌های بحرانی (Class 1) عملکرد ضعیف‌تری نسبت به نمونه‌های غیر بحرانی داشتند، به طوری که مقدار Recall برای کلاس بحران در برخی مدل‌ها کمتر از ۰.۶۰ بود.

این موضوع نشان می‌دهد که روابط بین متغیرهای مالی دارای ساختار غیرخطی و پیچیده‌ای است که توسط مدل‌های کلاسیک به خوبی قابل شناسایی نیست.

۴-۳ نتایج مدل یادگیری عمیق

در مرحله بعد، مدل LSTM برای تحلیل وابستگی‌های زمانی داده‌های مالی اجرا شد. این مدل با استفاده از توالی‌های زمانی صورت‌های مالی شرکت‌ها آموزش داده شد.

نتایج نشان داد که مدل LSTM نسبت به مدل‌های پایه عملکرد بهتری دارد:

دقت کلی حدود ۸۶٪

دقت شناسایی بحران : حدود ۰,۷۸

مقدار F1-Score: حدود ۰,۸۱

تحلیل خطاها نشان داد که مدل LSTM توانسته وابستگی‌های زمانی بین متغیرهای نقدینگی و سودآوری را بهتر از مدل‌های ایستا شناسایی کند. با این حال، در برخی موارد مربوط به شرکت‌های با رفتار مالی ناپایدار، مدل دچار نوسان در پیش‌بینی شده است.

۴-۴ نتایج مدل ترکیبی پیشنهادی

در این پژوهش، مدل ترکیبی LSTM به همراه الگوریتم بهینه‌سازی ازدحام ذرات برای تنظیم بهینه پارامترهای شبکه عصبی مورد استفاده قرار گرفت. هدف از این ترکیب، بهبود عملکرد مدل در شناسایی الگوهای بحرانی نقدینگی و کاهش خطای پیش‌بینی بود. نتایج تجربی نشان داد که مدل ترکیبی عملکرد بهتری نسبت به تمامی مدل‌های دیگر داشته است:

دقت کلی ۹۱٪

کلاس بحران نقدینگی: ۰,۸۸

F1-Score: 0.89

AUC: 0.93

بهینه‌سازی پارامترها توسط PSO باعث شد شبکه LSTM بتواند ساختار بهینه‌تری برای تعداد نورون‌ها، نرخ یادگیری و طول توالی زمانی پیدا کند. این موضوع نقش مهمی در کاهش بیش‌برازش و افزایش تعمیم‌پذیری مدل داشته است.

۴-۵ مقایسه مدل‌ها

جدول ۱. مقایسه کلی مدل‌ها نشان می‌دهد:

Accuracy	Recall (Crisis)	F1-Score	AUC	مدل
0.71	0.54	0.60	0.68	Logistic Regression
0.75	0.58	0.64	0.73	Decision Tree
0.80	0.66	0.72	0.79	MLP Neural Network
0.86	0.78	0.81	0.85	LSTM
0.91	0.88	0.89	0.93	LSTM-PSO (Hybrid)

نتایج جدول نشان می‌دهد که مدل پیشنهادی (ترکیبی) در تمامی شاخص‌های ارزیابی عملکرد، برتری معناداری نسبت به سایر مدل‌ها دارد.

۴-۶ تحلیل نتایج و تفسیر اقتصادی

یافته‌های پژوهش نشان می‌دهد که بحران نقدینگی شرکت‌ها صرفاً یک پدیده خطی ناشی از نسبت‌های مالی نیست، بلکه نتیجه تعامل پیچیده بین جریان‌های نقدی، ساختار سرمایه و عملکرد عملیاتی شرکت است. برتری مدل‌های یادگیری عمیق به‌ویژه LSTM نشان می‌دهد که در داده‌های مالی، وابستگی‌های زمانی نقش کلیدی دارند. همچنین بهبود عملکرد مدل ترکیبی LSTM-PSO بیانگر این نکته است که بهینه‌سازی پارامترهای شبکه عصبی تأثیر مستقیم بر توانایی مدل در تشخیص بحران دارد. از منظر مدیریتی، این نتایج نشان می‌دهد که استفاده از سیستم‌های هوشمند پیش‌بینی می‌تواند به مدیران مالی کمک کند تا پیش از وقوع بحران نقدینگی، اقدامات اصلاحی لازم را انجام دهند.

۵- بحث و نتیجه‌گیری

نتایج حاصل از این پژوهش نشان داد که پیش‌بینی بحران نقدینگی شرکت‌ها فرایندی پیچیده، چندبعدی و وابسته به روابط غیرخطی میان متغیرهای مالی است و نمی‌توان آن را صرفاً با اتکا به نسبت‌های مالی سنتی یا مدل‌های آماری کلاسیک با دقت مطلوب شناسایی کرد. عملکرد نسبتاً ضعیف مدل‌هایی نظیر رگرسیون لجستیک و درخت تصمیم در مقایسه با مدل‌های مبتنی بر یادگیری عمیق نشان داد که ساختار داده‌های مالی از الگوهای پنهان و تعاملات پیچیده‌ای تشکیل شده است که روش‌های خطی و سنتی توانایی کافی برای استخراج و تفسیر آن‌ها را ندارند. این یافته بیانگر آن است که بحران نقدینگی پدیده‌ای پویا و زمان‌مند بوده و عوامل مؤثر بر آن در طول زمان تغییر می‌کنند؛ از این رو مدل‌هایی که قادر به درک وابستگی‌های زمانی و روابط غیرخطی باشند، عملکرد بهتری در پیش‌بینی این پدیده خواهند داشت.

در این میان، نتایج پژوهش حاکی از آن بود که مدل‌های مبتنی بر یادگیری عمیق، به‌ویژه شبکه حافظه بلندمدت کوتاه‌مدت (LSTM)، توانسته‌اند با دقت بیشتری الگوهای نهفته در داده‌های مالی را شناسایی کرده و وضعیت نقدینگی شرکت‌ها را پیش‌بینی کنند. برتری این مدل را می‌توان ناشی از توانایی آن در حفظ و تحلیل اطلاعات گذشته و تشخیص روندهای زمانی موجود در متغیرهای مالی دانست. این نتیجه با یافته‌های مطالعات پیشین همسو است؛ به‌گونه‌ای که پژوهش‌های مختلف در حوزه تحلیل مالی و مدیریت ریسک نیز نشان داده‌اند که شبکه‌های عصبی بازگشتی و به‌ویژه مدل‌های LSTM در پردازش داده‌های سری زمانی مالی و پیش‌بینی رویدادهای مالی عملکردی بهتر از روش‌های سنتی دارند. بنابراین می‌توان استدلال کرد که استفاده از معماری‌های یادگیری عمیق در حوزه مدیریت مالی، امکان تحلیل دقیق‌تر رفتار مالی شرکت‌ها و شناسایی زود هنگام نشانه‌های بحران را فراهم می‌سازد.

یکی از مهم‌ترین یافته‌های این پژوهش، برتری مدل ترکیبی مبتنی بر LSTM و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) نسبت به مدل LSTM ساده بود. نتایج نشان داد که اگرچه مدل LSTM به‌تنهایی توانایی قابل توجهی در استخراج ویژگی‌های زمانی و یادگیری الگوهای پیچیده دارد، اما عملکرد آن به میزان زیادی تحت تأثیر نحوه تنظیم پارامترهای مدل قرار می‌گیرد. در بسیاری از موارد، انتخاب نامناسب پارامترها می‌تواند موجب کاهش دقت پیش‌بینی یا گرفتار شدن مدل در نقاط بهینه محلی شود. استفاده از الگوریتم PSO این امکان را فراهم کرد که فرایند جست‌وجو و تنظیم پارامترها به‌صورت هوشمندانه‌تر انجام شود و مدل بتواند به ترکیب بهینه‌ای از پارامترها دست یابد. این موضوع سبب افزایش دقت، بهبود نرخ شناسایی شرکت‌های در معرض بحران و ارتقای توان تفکیک مدل شد. در واقع، نتایج به‌دست‌آمده نشان می‌دهد که ترکیب روش‌های یادگیری عمیق با الگوریتم‌های بهینه‌سازی فراابتکاری می‌تواند راهکاری مؤثر برای افزایش کارایی سیستم‌های پیش‌بینی مالی باشد.

از منظر نظری نیز یافته‌های پژوهش قابل تبیین در چارچوب نظریه عدم تقارن اطلاعات و نظریه محدودیت نقدینگی هستند. بر اساس نظریه عدم تقارن اطلاعات، اطلاعات مالی موجود در بازار همواره به‌صورت کامل، شفاف و همزمان در اختیار تمامی ذی‌نفعان قرار نمی‌گیرد و همین موضوع می‌تواند موجب بروز خطا در ارزیابی وضعیت واقعی شرکت‌ها شود. در چنین شرایطی، احتمال وقوع بحران نقدینگی افزایش می‌یابد؛ زیرا سرمایه‌گذاران، اعتباردهندگان و مدیران ممکن است نتوانند سطح واقعی ریسک شرکت را به‌درستی تشخیص دهند. از سوی دیگر، نظریه محدودیت نقدینگی بیان می‌کند که شرکت‌ها در صورت کاهش دسترسی به منابع مالی یا ضعف در مدیریت جریان‌های نقدی با احتمال بیشتری در معرض بحران قرار می‌گیرند. مدل‌های مبتنی بر یادگیری عمیق با توانایی شناسایی روابط پنهان میان متغیرهای مالی، می‌تواند بخشی از این شکاف اطلاعاتی را جبران کرده و الگوهایی را آشکار سازد که از طریق روش‌های سنتی قابل شناسایی نیستند. به بیان دیگر، این مدل‌ها با کشف ساختارهای نهفته در داده‌ها، تصویری دقیق‌تر از وضعیت واقعی شرکت ارائه می‌کنند و امکان پیش‌بینی زود هنگام بحران را فراهم می‌سازند.

در مجموع، نتایج این پژوهش نشان داد که بحران نقدینگی شرکت‌ها دارای ماهیتی پیچیده، غیرخطی و وابسته به زمان است و به همین دلیل مدل‌های سنتی قادر به شناسایی کامل آن نیستند. همچنین مشخص شد که مدل‌های یادگیری عمیق، به‌ویژه LSTM، توانایی بالاتری در تحلیل داده‌های مالی و پیش‌بینی بحران نقدینگی دارند و ترکیب این مدل‌ها با الگوریتم‌های بهینه‌سازی نظیر PSO می‌تواند عملکرد آن‌ها را به شکل قابل توجهی بهبود بخشد. یافته‌ها نشان داد که مدل پیشنهادی پژوهش با دستیابی به بالاترین مقادیر شاخص‌های ارزیابی از جمله Accuracy، Recall و AUC توانسته است نسبت به سایر مدل‌های مورد بررسی عملکرد برتری ارائه دهد و به‌عنوان کارآمدترین مدل برای پیش‌بینی بحران نقدینگی معرفی شود. همچنین نتایج تأکید می‌کند که تحلیل داده‌های مالی بدون توجه به بعد زمانی و روندهای تاریخی نمی‌تواند تصویر دقیقی از وضعیت مالی شرکت‌ها ارائه دهد و استفاده از مدل‌های ترکیبی هوشمند می‌تواند به ارتقای کیفیت تصمیم‌گیری‌های مالی کمک کند.

بر اساس نتایج حاصل از پژوهش، می‌توان پیشنهاد کرد که مدیران مالی و تصمیم‌گیرندگان سازمانی از سیستم‌های هوشمند مبتنی بر یادگیری عمیق برای پایش مستمر وضعیت نقدینگی شرکت‌ها استفاده کنند. طراحی و استقرار داشبوردهای هوشمند پیش‌بینی ریسک نقدینگی در شرکت‌های بزرگ و به‌ویژه شرکت‌های پذیرفته‌شده در بورس می‌تواند زمینه شناسایی زود هنگام مشکلات نقدینگی و اتخاذ اقدامات اصلاحی را فراهم سازد. همچنین توصیه می‌شود در ارزیابی وضعیت مالی شرکت‌ها، علاوه بر نسبت‌های مالی متداول، شاخص‌های مرتبط با جریان‌های نقدی نیز مورد توجه قرار گیرند؛ زیرا این شاخص‌ها اطلاعات دقیق‌تری درباره توان واقعی شرکت در ایفای تعهدات کوتاه‌مدت ارائه می‌دهند.

علاوه بر این، نهادهای مالی، بانک‌ها و مؤسسات اعتبارسنجی می‌توانند از مدل‌های ترکیبی هوشمند به‌عنوان ابزار پشتیبان تصمیم برای ارزیابی ریسک اعتباری مشتریان استفاده کنند. با وجود نتایج ارزشمند این پژوهش، زمینه‌های متعددی برای توسعه مطالعات آینده وجود دارد. پیشنهاد می‌شود در پژوهش‌های آتی از معماری‌های پیشرفته‌تر یادگیری عمیق نظیر ترنسفورمرهای مالی استفاده شود تا امکان استخراج روابط پیچیده‌تر در داده‌های مالی فراهم گردد. همچنین ترکیب داده‌های مالی با داده‌های غیرمالی از جمله اخبار اقتصادی، گزارش‌های رسانه‌ای و تحلیل احساسات بازار می‌تواند به بهبود قدرت پیش‌بینی مدل‌ها کمک کند. بررسی نقش متغیرهای کلان اقتصادی نظیر نرخ تورم، نرخ بهره، رشد اقتصادی و نوسانات بازار سرمایه نیز از دیگر موضوعات مهمی است که می‌تواند در تحقیقات آینده مورد توجه قرار گیرد. علاوه بر این، توسعه مدل‌های توضیح‌پذیر هوش مصنوعی به منظور افزایش شفافیت فرایند تصمیم‌گیری و جلب اعتماد مدیران و سرمایه‌گذاران، یکی از مسیرهای مهم پژوهشی در این حوزه محسوب می‌شود. همچنین مقایسه عملکرد الگوریتم‌های مختلف بهینه‌سازی نظیر الگوریتم ژنتیک، بهینه‌سازی بیزی و سایر روش‌های فراابتکاری می‌تواند به شناسایی کارآمدترین رویکردها برای بهبود مدل‌های پیش‌بینی مالی منجر شود.

در نهایت، همانند سایر پژوهش‌ها، این مطالعه نیز با محدودیت‌هایی مواجه بوده است. مهم‌ترین محدودیت پژوهش، دشواری دسترسی به داده‌های مالی کامل، یکپارچه و باکیفیت برای تمامی شرکت‌های مورد بررسی بود که می‌تواند بر عملکرد مدل‌ها تأثیرگذار باشد. همچنین برخی متغیرهای رفتاری، مدیریتی و حاکمیت شرکتی که ممکن است در شکل‌گیری بحران نقدینگی نقش داشته باشند، در مدل لحاظ نشده‌اند. از سوی دیگر، مدل‌های یادگیری عمیق به دلیل پیچیدگی ساختاری خود نیازمند منابع پردازشی قابل توجه و زمان آموزش نسبتاً بالا هستند که ممکن است کاربرد آن‌ها را در برخی محیط‌های عملی محدود کند. علاوه بر این، عملکرد مدل‌های ترکیبی تا حدی به نحوه تنظیم اولیه پارامترها وابسته است و انتخاب نامناسب این پارامترها می‌تواند بر نتایج نهایی اثرگذار باشد. با وجود این محدودیت‌ها، نتایج پژوهش نشان می‌دهد که استفاده از رویکردهای نوین مبتنی بر هوش مصنوعی و یادگیری عمیق می‌تواند گامی مؤثر در جهت ارتقای دقت پیش‌بینی بحران نقدینگی و بهبود کیفیت تصمیم‌گیری‌های مالی در شرکت‌ها باشد.

منابع

منابع فارسی

مقالات

- سلیمانی، علی. (۱۳۹۲). پیش‌بینی ورشکستگی شرکت‌ها با استفاده از نسبت‌های مالی. *مجله علوم مالی ایران*، ۲(۷)، ۴۵-۷۰.
- احمدپور، عبدالمجید. (۱۳۹۵). مدل‌های پیش‌بینی بحران مالی. *پژوهش‌های حسابداری و حسابرسی*، ۳(۲۲)، ۱۰۱-۱۲۰.
- صیوری، محمود. (۱۳۹۷). تحلیل بحران مالی در بورس تهران. *پژوهش‌های حسابداری مالی*، ۱(۹)، ۲۳-۵۲.
- حیدری، علی. (۱۳۹۸). پیش‌بینی ناتوانی مالی شرکت‌ها. *مجله حسابداری و حسابرسی*، ۴(۲۵)، ۸۸-۱۱۰.
- کاظمی، محمدرضا. (۱۴۰۰). یادگیری ماشین در پیش‌بینی ورشکستگی. *فصلنامه علوم مدیریت مالی*، ۲(۱۵)، ۵۵-۸۰.

کتاب‌ها

- نمازی، محمد. (۱۳۸۴). *مدیریت مالی*. تهران: سمت.
- تهرانی، رضا. (۱۳۸۸). *نظریه‌های مدیریت مالی*. تهران: دانشگاه تهران.
- شباهنگ، رضا. (۱۳۹۰). *مبانی مدیریت مالی*. تهران: سمت.
- رهنمای رودپشتی، فریدون. (۱۳۹۲). *مدیریت مالی پیشرفته*. تهران: سمت.
- حساس یگانه، یحیی. (۱۳۹۱). *نظریه‌های حسابداری*. تهران: سمت.

اسناد و گزارش‌ها

- بانک مرکزی جمهوری اسلامی ایران. (۱۴۰۱). *گزارش شاخص‌های عملکرد نظام بانکی کشور*. تهران: بانک مرکزی.
- مرکز آمار ایران. (۱۴۰۰). *گزارش تحولات بخش مالی و بانکی*. تهران.

منابع انگلیسی

Articles

- Akerlof, G. A. (1970). The market for "lemons": Quality uncertainty and the market mechanism. *Quarterly Journal of Economics*, 84(3), 488-500.

- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23(4), 589–609.
- Altman, E. I. (2000). Predicting financial distress of companies. *Journal of Banking & Finance*, 25(1), 1–18.
- Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4(3), 71–111.
- Ohlson, J. A. (1980). Financial ratios and bankruptcy prediction. *Journal of Accounting Research*, 18(1), 109–131.
- Kim, J., Cho, S., & Lee, J. (2021). Financial distress prediction using LSTM neural networks. *Expert Systems with Applications*, 186, 115765. <https://doi.org/10.1016/j.eswa.2021.115765>
- Zhang, Y., Li, X., & Wang, S. (2020). Stock and financial risk prediction using CNN–LSTM hybrid deep learning model. *Neurocomputing*, 417, 1–10.
- Zmijewski, M. E. (1984). Methodological issues in bankruptcy prediction. *Journal of Accounting Research*, 22, 59–82.
- Li, Y., & Wang, J. (2022). Hybrid PSO–LSTM model for financial time series prediction. *Applied Soft Computing*, 118, 108513. <https://doi.org/10.1016/j.asoc.2022.108513>
- Shumway, T. (2001). Forecasting bankruptcy more accurately. *Journal of Business*, 74(1), 101–124.
- Hillegeist, S. A., et al. (2004). Assessing bankruptcy probability. *Review of Accounting Studies*, 9(1), 5–34.
- Huang, Z., Chen, H., Hsu, C. J., Chen, W. H., & Wu, S. (2004). Credit rating analysis with support vector machines and neural networks. *Decision Support Systems*, 37(4), 543–558.
- Merton, R. C. (1974). On the pricing of corporate debt. *Journal of Finance*, 29(2), 449–470.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *KDD Proceedings*, 785–794.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Vaswani, A., et al. (2017). Attention is all you need. *NeurIPS*.
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. <https://doi.org/10.2307/2490395>
- Opler, T., Pinkowitz, L., Stulz, R., & Williamson, R. (1999). The determinants and implications of corporate cash holdings. *Journal of Financial Economics*, 52(1), 3–46.

Books

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning*. Springer.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Huang, C., & Chen, M. (2019). *Machine learning in finance: Applications and techniques*. Springer.
- Campbell, J. Y., Lo, A. W., & MacKinlay, A. C. (1997). *The econometrics of financial markets*. Princeton University Press.

