دوره ۱، شماره ۵، سال ۱۴۰۴

هوشمندسازی در حسابداری، اقتصاد و مدیریت مالی

ارائه مدل پیش‌بینی بحران‌های مالی مبتنی بر یادگیری عمیق، شاخص‌های کلان اقتصادی و داده‌های بازار سرمایه

۱. مریم رضوی*: گروه حسابداری، دانشگاه یزد، یزد، ایران (نویسنده مسئول). maryam.razavi@gmail.com

۲. محمد رضا احمدی تبار: گروه حسابداری، دانشگاه یزد، یزد، ایران

چکیده

هدف این پژوهش، طراحی یک مدل مفهومی برای پیش‌بینی بحران‌های مالی با اتکا بر یادگیری عمیق، شاخص‌های کلان اقتصادی، داده‌های بازار سرمایه و دیدگاه خبرگان مالی، اقتصادی و فناوری داده بود. پژوهش حاضر با رویکرد کیفی و با استفاده از روش تحلیل مضمون انجام شد. مشارکت‌کنندگان شامل ۱۸ نفر از خبرگان مالی، اقتصاددانان، تحلیلگران بازار سرمایه، مدیران ریسک بانکی، متخصصان علم داده و سیاست‌گذاران مالی در شهر تهران بودند که به‌صورت هدفمند و گلوله‌برفی انتخاب شدند. داده‌ها از طریق مصاحبه‌های نیمه‌ساختاریافته گردآوری شد و فرایند مصاحبه تا دستیابی به اشباع نظری ادامه یافت؛ به‌گونه‌ای که اشباع اولیه در مصاحبه شانزدهم حاصل شد و دو مصاحبه تکمیلی برای اطمینان انجام گرفت. داده‌ها با استفاده از نرم‌افزار NVivo و طی مراحل کدگذاری باز، محوری و انتخابی تحلیل شدند. برای افزایش اعتبار یافته‌ها از بازبینی مشارکت‌کنندگان، بازبینی همتایان، ثبت مسیر تحلیل و مقایسه مستمر کدها استفاده شد. تحلیل داده‌ها به استخراج پنج مقوله اصلی منجر شد: یکپارچه‌سازی داده‌های کلان اقتصادی و بازار سرمایه، طراحی معماری یادگیری عمیق برای آشکارسازی الگوهای پیشابحران، تبیین‌پذیری و اعتبارسنجی مدل، حکمرانی داده و مدیریت ریسک مدل، و کاربست نهادی سامانه هشدار زودهنگام. مشارکت‌کنندگان تأکید داشتند که پیش‌بینی بحران مالی صرفاً مسئله‌ای محاسباتی نیست، بلکه مستلزم ترکیب داده‌های چندمنبعی، مدل‌های توالی‌محور مانند LSTM، شاخص‌های قابل تفسیر، سازوکارهای هشدار سطح‌بندی‌شده و ظرفیت نهادی برای واکنش سریع است. مدل پیشنهادی نشان می‌دهد که سامانه پیش‌بینی بحران مالی باید از سطح پیش‌بینی عددی فراتر رود و به چارچوبی تصمیم‌یار برای تنظیم‌گران، بانک‌ها، نهادهای مالی و فعالان بازار سرمایه تبدیل شود. ترکیب یادگیری عمیق با شاخص‌های کلان اقتصادی، داده‌های معاملاتی و لایه‌های تبیین‌پذیری می‌تواند امکان شناسایی زودهنگام آسیب‌پذیری‌های مالی، کاهش غافلگیری سیاستی و ارتقای تاب‌آوری بازار را فراهم سازد.

کلیدواژه‌ها: بحران مالی؛ یادگیری عمیق؛ شاخص‌های کلان اقتصادی؛ بازار سرمایه؛ سامانه هشدار زودهنگام؛ تحلیل مضمون؛ پیش‌بینی ریسک.

شیوه استناددهی: رضوی، مریم.، و احمدی تبار، محمد رضا. (۱۴۰۴). ارائه مدل پیش‌بینی بحران‌های مالی مبتنی بر یادگیری عمیق، شاخص‌های کلان اقتصادی و داده‌های بازار سرمایه. *هوشمندسازی در حسابداری، اقتصاد و مدیریت مالی*، *۱*(۵)، ۴۱-۲۹.

© ۱۴۰۴ تمامی حقوق انتشار این مقاله متعلق به نویسنده است.

Volume 1, Issue 5, Year 2025

Smartification in Accounting, Economics, and Financial Management

Developing a Deep Learning-Based Model for Predicting Financial Crises Using Macroeconomic Indicators and Capital Market Data

1. Maryam Razavi*: Department of Accounting, Yazd University, Yazd, Iran (Corresponding Author). maryam.razavi@gmail.com
2. Mohammad Reza Ahmadi Tabar: Department of Accounting, Yazd University, Yazd, Iran

Abstract

This study aimed to develop a conceptual model for predicting financial crises by integrating deep learning techniques, macroeconomic indicators, capital market data, and expert perspectives in finance, economics, and data science. This qualitative study employed thematic analysis. The participants consisted of 18 experts from Tehran, including finance specialists, economists, capital market analysts, bank risk managers, data science professionals, and financial policy experts. Participants were selected through purposive and snowball sampling. Data were collected using semi-structured interviews and continued until theoretical saturation was achieved; initial saturation occurred at the sixteenth interview, and two additional interviews were conducted to confirm saturation. The interview data were analyzed using NVivo software through open, axial, and selective coding. Credibility and trustworthiness were enhanced through member checking, peer review, audit trail documentation, and constant comparison of codes and themes. The analysis resulted in five main categories: integration of macroeconomic and capital market data, deep learning architecture for detecting pre-crisis patterns, model interpretability and validation, data governance and model risk management, and institutional application of early warning systems. Participants emphasized that financial crisis prediction is not merely a computational problem; rather, it requires multi-source data integration, sequence-based models such as LSTM, interpretable risk indicators, tiered warning mechanisms, and institutional capacity for timely intervention. The proposed model suggests that a financial crisis prediction system should move beyond numerical forecasting and operate as a decision-support framework for regulators, banks, financial institutions, and capital market actors. Integrating deep learning with macroeconomic indicators, trading data, and explainability layers may facilitate early identification of financial vulnerabilities, reduce policy surprise, and improve market resilience.

Keywords: *Financial crisis; Deep learning; Macroeconomic indicators; Capital market; Early warning system; Thematic analysis; Risk prediction.*

How to cite: Razavi, M. & Ahmadi Tabar, M. R. (2025). Developing a Deep Learning-Based Model for Predicting Financial Crises Using Macroeconomic Indicators and Capital Market Data. *Smartification in Accounting, Economics, and Financial Management, 1*(5), 29-41.

© 2025 the authors.

مقدمه

بحران‌های مالی از پیچیده‌ترین و پرهزینه‌ترین پدیده‌های اقتصادی هستند؛ زیرا آثار آن‌ها محدود به افت قیمت دارایی‌ها یا اختلال در بازارهای مالی نیست، بلکه می‌تواند به کاهش رشد اقتصادی، افزایش بیکاری، تضعیف اعتماد عمومی، بحران نقدینگی، افت سرمایه‌گذاری و بی‌ثباتی نهادی منجر شود. تجربه بحران‌های مالی در دهه‌های اخیر نشان داده است که بسیاری از بحران‌ها پیش از آشکار شدن در سطح رسمی، نشانه‌هایی در رفتار متغیرهای کلان اقتصادی، بازار پول، بازار ارز، بازار سرمایه، اعتبارات بانکی و انتظارات فعالان اقتصادی بروز می‌دهند. ادبیات سامانه‌های هشدار زودهنگام نیز بر این نکته تأکید دارد که متغیرهایی مانند رشد اعتبارات، نرخ ارز واقعی، ذخایر ارزی، تورم، نرخ بهره، قیمت دارایی‌ها، شاخص سهام و شاخص‌های فشار مالی می‌توانند پیش از وقوع بحران، رفتار غیرعادی نشان دهند (Kaminsky et al., ۱۹۹۸; Berg & Pattillo, ۱۹۹۹). مطالعه کلاسیک Kaminsky ، Lizondo و Reinhart نشان داد که پایش آستانه‌ای برخی شاخص‌ها می‌تواند سیگنال‌هایی درباره احتمال وقوع بحران ارزی در افق زمانی پیش‌رو ارائه کند؛ درحالی‌که Berg و Pattillo نیز نشان دادند که مدل‌های هشدار زودهنگام، اگرچه کاملاً قطعی نیستند، می‌توانند اطلاعاتی فراتر از حدس تصادفی فراهم کنند.

با وجود اهمیت بالای پیش‌بینی بحران‌های مالی، ماهیت این بحران‌ها به‌گونه‌ای است که پیش‌بینی آن‌ها با دشواری‌های جدی همراه است. بحران مالی معمولاً محصول تعامل غیرخطی میان متغیرهای اقتصادی، مالی، رفتاری و نهادی است. برای مثال، افزایش نرخ بهره ممکن است در یک دوره به کنترل تورم کمک کند، اما در دوره‌ای دیگر موجب تشدید فشار بر بنگاه‌های بدهکار، افزایش نکول، کاهش ارزش دارایی‌ها و تشدید بحران نقدینگی شود. به‌همین‌ترتیب، رشد سریع بازار سرمایه در ظاهر می‌تواند نشانه رونق اقتصادی تلقی شود، اما اگر با حباب قیمتی، اهرم مالی بالا، رفتار گله‌ای و ضعف نظارت همراه باشد، می‌تواند به یکی از نشانه‌های پیشابحران تبدیل شود. این ویژگی‌ها موجب می‌شود که رویکردهای خطی و تک‌بعدی برای پیش‌بینی بحران‌های مالی کافی نباشند و ضرورت استفاده از مدل‌هایی مطرح شود که بتوانند وابستگی‌های زمانی، تعاملات غیرخطی، شکست‌های ساختاری و الگوهای پنهان در داده‌های چندمنبعی را شناسایی کنند.

در ادبیات مالی، مدل‌های اولیه پیش‌بینی بحران عمدتاً بر رویکردهای اقتصادسنجی سنتی، مدل‌های لاجیت و پروبیت، تحلیل شاخص‌های هشدار و روش‌های آستانه‌ای تکیه داشتند. این مدل‌ها مزیت‌هایی از جمله سادگی، تفسیرپذیری و قابلیت استفاده سیاستی داشتند؛ بااین‌حال، محدودیت‌هایی مانند فرض روابط خطی، حساسیت به انتخاب آستانه، ضعف در شناسایی روابط پیچیده و ناتوانی در یادگیری پویا از داده‌های پرتکرار نیز در آن‌ها مشاهده می‌شد. پژوهش‌های بعدی در حوزه ریسک سیستمی نشان دادند که ترکیب شاخص‌های کلان مالی، شاخص‌های فشار مالی و داده‌های بازار می‌تواند قدرت پیش‌بینی رویدادهای سیستمی را بهبود دهد (Lo Duca & Peltonen, ۲۰۱۳). از این منظر، بحران مالی نه یک رخداد ناگهانی، بلکه نتیجه انباشت تدریجی آسیب‌پذیری‌هایی است که در لایه‌های مختلف نظام مالی شکل می‌گیرند و در

صورت وقوع شوک، به‌صورت بحران آشکار می‌شوند Lo Duca .و Peltonen چارچوبی برای ارزیابی ریسک‌های سیستمی و پیش‌بینی رویدادهای شدید بی‌ثباتی مالی ارائه کردند.

در سال‌های اخیر، گسترش یادگیری ماشین و یادگیری عمیق، مسیر تازه‌ای برای پیش‌بینی بحران‌های مالی ایجاد کرده است. یادگیری عمیق به‌دلیل توانایی در استخراج بازنمایی‌های پیچیده از داده‌های خام و شناسایی الگوهای غیرخطی، در حوزه‌هایی مانند پردازش تصویر، زبان طبیعی، تشخیص تقلب، اعتبارسنجی اعتباری و پیش‌بینی بازارهای مالی مورد توجه قرار گرفته است .(LeCun et al., ۲۰۱۵) در میان مدل‌های یادگیری عمیق، شبکه‌های بازگشتی و به‌ویژه شبکه‌های حافظه کوتاه‌مدت بلندمدت یا LSTM به‌دلیل توانایی در یادگیری وابستگی‌های زمانی بلندمدت، برای تحلیل سری‌های زمانی مالی اهمیت ویژه‌ای دارند .(Hochreiter & Schmidhuber, ۱۹۹۷) پژوهش Fischerو Krauss نشان داد که LSTM می‌تواند در برخی وظایف پیش‌بینی بازار سهام، الگوهای زمانی را بهتر از مدل‌های سنتی شناسایی کند.

بااین‌حال، انتقال یادگیری عمیق به حوزه پیش‌بینی بحران مالی، صرفاً مسئله انتخاب الگوریتم نیست. بحران مالی پدیده‌ای چندسطحی است و مدل پیش‌بینی آن باید هم‌زمان به کیفیت داده، انتخاب متغیرهای پیش‌نگر، تناوب زمانی داده‌ها، پنجره پیش‌بینی، تعریف بحران، اعتبارسنجی برون‌نمونه‌ای، تبیین‌پذیری خروجی‌ها و قابلیت استفاده نهادی توجه کند. برای مثال، استفاده از شاخص‌های بازار سرمایه مانند بازده شاخص کل، نوسان‌پذیری، ارزش معاملات، نسبت قیمت به سود، جریان نقدینگی، صف‌های خرید و فروش، حجم معاملات غیرعادی و همبستگی بین صنایع می‌تواند سیگنال‌های سریع‌تری نسبت به برخی متغیرهای کلان اقتصادی فراهم کند. در مقابل، شاخص‌های کلان اقتصادی مانند تورم، نرخ ارز، رشد نقدینگی، کسری بودجه، نرخ بهره، رشد اقتصادی، تراز پرداخت‌ها، بدهی دولت و نرخ بیکاری می‌توانند زمینه ساختاری آسیب‌پذیری مالی را نشان دهند. بنابراین، مدل مطلوب باید از ترکیب داده‌های آهسته‌حرکت کلان و داده‌های پرتکرار بازار سرمایه استفاده کند.

یکی از چالش‌های جدی مدل‌های یادگیری عمیق در حوزه مالی، مسئله تبیین‌پذیری است. تصمیم‌های مالی و سیاستی صرفاً بر اساس یک خروجی عددی یا احتمال بحران اتخاذ نمی‌شوند؛ بلکه مدیران ریسک، نهادهای ناظر و سیاست‌گذاران باید بدانند که چرا مدل، سطح ریسک را بالا ارزیابی کرده است، کدام شاخص‌ها بیشترین سهم را در هشدار داشته‌اند و آیا هشدار صادرشده با منطق اقتصادی قابل دفاع است یا خیر. روش‌هایی مانند SHAP و سایر ابزارهای تبیین‌پذیری می‌توانند بخشی از این شکاف را کاهش دهند، زیرا اهمیت نسبی متغیرها را در پیش‌بینی مدل نشان می‌دهند .(Lundberg & Lee, ۲۰۱۷) این موضوع در بازارهای نوظهور اهمیت بیشتری دارد؛ زیرا کیفیت داده‌ها، تغییرات مقرراتی، شوک‌های ارزی، مداخلات سیاستی و رفتارهای غیرعادی بازار ممکن است الگوهای تاریخی را دچار ناپایداری کند.

در بازارهای سرمایه نوظهور، از جمله بازار سرمایه ایران، پیش‌بینی بحران مالی با پیچیدگی‌های مضاعفی مواجه است. وجود تورم مزمن، نوسان نرخ ارز، مداخلات مقرراتی، محدودیت‌های معاملاتی، رفتار هیجانی سرمایه‌گذاران، تغییرات سریع انتظارات، وابستگی شرکت‌ها به سیاست‌های

کلان و حساسیت بازار به اخبار سیاسی و اقتصادی، موجب می‌شود که مدل‌های صرفاً کمی بدون فهم زمینه نهادی و رفتاری، کارایی محدودی داشته باشند. ازاین‌رو، طراحی مدل پیش‌بینی بحران مالی در چنین زمینه‌ای نیازمند بهره‌گیری از دانش خبرگان و فهم عمیق از سازوکارهای محلی بازار است. رویکرد کیفی می‌تواند به شناسایی ابعاد، مؤلفه‌ها، الزامات و موانعی کمک کند که در مدل‌سازی صرفاً عددی نادیده گرفته می‌شوند. به بیان دیگر، پیش از ساخت یک مدل محاسباتی کامل، لازم است معماری مفهومی آن بر اساس تجربه متخصصان مالی، اقتصادی، ریسک، فناوری داده و سیاست‌گذاری طراحی شود.

پژوهش حاضر با چنین رویکردی انجام شده است و هدف آن ارائه مدل پیش‌بینی بحران‌های مالی مبتنی بر یادگیری عمیق، شاخص‌های کلان اقتصادی و داده‌های بازار سرمایه است. نوآوری پژوهش در آن است که به‌جای تمرکز صرف بر دقت الگوریتمی، تلاش می‌کند یک مدل مفهومی و نهادی برای سامانه هشدار زودهنگام ارائه دهد؛ مدلی که در آن داده‌های کلان اقتصادی، داده‌های بازار سرمایه، معماری یادگیری عمیق، تبیین‌پذیری، حکمرانی داده و سازوکار تصمیم‌گیری به‌صورت یکپارچه دیده شوند. بر این اساس، پرسش اصلی پژوهش چنین است: «مدل پیش‌بینی بحران‌های مالی مبتنی بر یادگیری عمیق، شاخص‌های کلان اقتصادی و داده‌های بازار سرمایه از دیدگاه خبرگان دارای چه ابعاد و مؤلفه‌هایی است؟»

مواد و روش‌ها

پژوهش حاضر از نظر هدف، کاربردی و توسعه‌ای، و از نظر رویکرد، کیفی است. این مطالعه با هدف طراحی مدل مفهومی پیش‌بینی بحران‌های مالی انجام شد و برای تحلیل داده‌ها از تحلیل مضمون استفاده گردید. انتخاب رویکرد کیفی از آن جهت مناسب بود که موضوع پژوهش، علاوه بر ابعاد فنی و الگوریتمی، دارای ابعاد نهادی، تفسیری، سیاستی و زمینه‌ای است. در چنین موضوعاتی، اتکا به داده‌های عددی بدون فهم تجربه خبرگان ممکن است به مدلی منجر شود که از نظر محاسباتی پیچیده، اما از نظر اجرایی و تصمیم‌گیری کم‌اثر باشد. بنابراین، در این پژوهش تلاش شد تجربه خبرگان بازار سرمایه، اقتصاد کلان، مدیریت ریسک، فناوری مالی و علم داده در قالب یک مدل مفهومی منسجم سازمان‌دهی شود.

جامعه مشارکت‌کنندگان شامل خبرگان مستقر در شهر تهران بود که در حوزه‌های بازار سرمایه، اقتصاد کلان، ریسک مالی، بانکداری، فناوری مالی، یادگیری ماشین و سیاست‌گذاری مالی تجربه تخصصی داشتند. نمونه‌گیری به‌صورت هدفمند آغاز شد و سپس برای دستیابی به افراد مطلع‌تر از روش گلوله‌برفی استفاده شد. معیارهای ورود به پژوهش شامل داشتن حداقل پنج سال سابقه حرفه‌ای یا پژوهشی مرتبط، آشنایی با بازار سرمایه یا نظام مالی، آشنایی نسبی با شاخص‌های کلان اقتصادی یا مدل‌های داده‌محور، و آمادگی برای مشارکت در مصاحبه بود. مشارکت‌کنندگانی که تجربه کافی در حوزه پیش‌بینی، تحلیل ریسک یا سیاست‌گذاری مالی نداشتند یا تمایل به ضبط مصاحبه نداشتند، وارد مطالعه نشدند. در مجموع، ۱۸ نفر در پژوهش مشارکت کردند. اشباع نظری در مصاحبه شانزدهم حاصل شد، اما دو مصاحبه دیگر نیز برای

اطمینان از کفایت داده‌ها انجام گرفت. این منطق با ادبیات اشباع در پژوهش کیفی سازگار است که میان اشباع کدها و اشباع معنایی تمایز قائل می‌شود.(Hennink et al., ۲۰۱۷)

ابزار گردآوری داده‌ها مصاحبه نیمه‌ساختاریافته بود. راهنمای مصاحبه بر اساس مرور ادبیات و هدف پژوهش طراحی شد و شامل محورهایی مانند نشانه‌های پیشابحران مالی، شاخص‌های کلان اقتصادی مؤثر، داده‌های بازار سرمایه، قابلیت‌های یادگیری عمیق، چالش‌های داده، اعتبارسنجی مدل، تبیین‌پذیری، کاربرد سیاستی هشدارها و موانع پیاده‌سازی سامانه پیش‌بینی بود. نمونه پرسش‌های مصاحبه عبارت بودند از: «به نظر شما مهم‌ترین نشانه‌های پیش از وقوع بحران مالی در بازار سرمایه چیست؟»، «کدام شاخص‌های کلان اقتصادی باید در مدل پیش‌بینی بحران وارد شوند؟»، «یادگیری عمیق در چه بخشی از پیش‌بینی بحران مالی ارزش افزوده ایجاد می‌کند؟»، «چه موانعی برای پیاده‌سازی مدل در نهادهای مالی وجود دارد؟» و «خروجی مدل باید چگونه طراحی شود تا برای تصمیم‌گیران قابل استفاده باشد؟«

مصاحبه‌ها به‌صورت حضوری و آنلاین انجام شد. مدت هر مصاحبه بین ۴۵ تا ۷۵ دقیقه بود. پیش از آغاز مصاحبه، هدف پژوهش برای مشارکت‌کنندگان توضیح داده شد و رضایت آگاهانه آنان اخذ گردید. به مشارکت‌کنندگان اطمینان داده شد که نام و مشخصات فردی آنان محرمانه باقی می‌ماند و نقل‌قول‌ها بدون ذکر هویت استفاده می‌شود. همه مصاحبه‌ها با اجازه مشارکت‌کنندگان ضبط و سپس کلمه‌به‌کلمه پیاده‌سازی شد. برای حفظ محرمانگی، هر مشارکت‌کننده با کدهایی مانند P۱ تا P۱۸ مشخص شد.

تحلیل داده‌ها با استفاده از نرم‌افزار NVivo انجام شد. ابتدا متن مصاحبه‌ها چندین بار خوانده شد تا پژوهشگر با کلیت داده‌ها آشنا شود. سپس کدگذاری اولیه انجام گرفت و گزاره‌های معنادار مربوط به پیش‌بینی بحران، شاخص‌ها، داده‌ها، مدل‌ها و الزامات اجرایی استخراج شد. در مرحله بعد، کدهای مشابه ادغام و در قالب زیرمقوله‌ها سازمان‌دهی شدند. سپس زیرمقوله‌ها در سطحی انتزاعی‌تر به مقوله‌های اصلی تبدیل شدند. در نهایت، بر اساس روابط میان مقوله‌ها، مدل مفهومی پژوهش تدوین شد. فرایند تحلیل مضمون با منطق شش‌مرحله‌ای Braun و Clarke همسو بود که شامل آشنایی با داده‌ها، تولید کدهای اولیه، جست‌وجوی مضامین، بازبینی مضامین، تعریف و نام‌گذاری مضامین و تدوین گزارش است.(Braun & Clarke, ۲۰۰۶)

برای افزایش اعتبار و قابلیت اعتماد یافته‌ها از چند راهبرد استفاده شد. نخست، خلاصه یافته‌ها در اختیار تعدادی از مشارکت‌کنندگان قرار گرفت و نظرات آنان درباره دقت برداشت‌ها دریافت شد. دوم، بخشی از فرایند کدگذاری توسط یک پژوهشگر آشنا با روش کیفی بازبینی شد. سوم، مسیر تحلیل شامل تصمیم‌های کدگذاری، ادغام کدها و شکل‌گیری مقوله‌ها ثبت شد. چهارم، نقل‌قول‌های مستقیم برای نشان دادن پیوند میان داده خام و مقوله‌های استخراج‌شده استفاده گردید. همچنین برای افزایش انتقال‌پذیری، ویژگی‌های مشارکت‌کنندگان و زمینه پژوهش به‌صورت روشن گزارش شد. این اقدامات با معیارهای اعتمادپذیری در پژوهش کیفی، شامل اعتبار، انتقال‌پذیری، وابستگی و تأییدپذیری همسو است.(Lincoln & Guba, ۱۹۸۵)

یافته‌ها

در این پژوهش ۱۸ نفر از خبرگان مالی، اقتصادی، بازار سرمایه و فناوری داده در شهر تهران مشارکت داشتند. از نظر جنسیت، ۱۳ نفر مرد و ۵ نفر زن بودند. از نظر تحصیلات، ۴ نفر دارای مدرک کارشناسی ارشد و ۱۴ نفر دارای مدرک دکتری یا دانشجوی دکتری تخصصی بودند. از نظر حوزه تخصصی، ۵ نفر تحلیلگر یا مدیر سرمایه‌گذاری در بازار سرمایه، ۴ نفر اقتصاددان یا عضو هیئت علمی اقتصاد، ۳ نفر مدیر یا کارشناس ارشد ریسک بانکی، ۳ نفر متخصص علم داده و یادگیری ماشین، ۲ نفر فعال حوزه فناوری مالی و ۱ نفر سیاست‌گذار یا کارشناس ارشد نهاد ناظر مالی بودند. سابقه کاری مشارکت‌کنندگان بین ۶ تا ۲۴ سال متغیر بود؛ ۶ نفر سابقه ۶ تا ۱۰ سال، ۷ نفر سابقه ۱۱ تا ۱۵ سال و ۵ نفر سابقه بیش از ۱۵ سال داشتند.

تحلیل مصاحبه‌ها به استخراج پنج مقوله اصلی، چهارده زیرمقوله و مجموعه‌ای از کدهای مفهومی منجر شد. مقوله‌های اصلی شامل «یکپارچه‌سازی داده‌های کلان اقتصادی و بازار سرمایه»، «معماری یادگیری عمیق و شناسایی الگوهای پیشابحران»، «تبیین‌پذیری، اعتبارسنجی و اعتماد به مدل»، «حکمرانی داده و مدیریت ریسک مدل» و «کاربست نهادی سامانه هشدار زودهنگام» بود.

۱ مقوله اول: یکپارچه‌سازی داده‌های کلان اقتصادی و بازار سرمایه

نخستین مقوله استخراج‌شده نشان داد که مشارکت‌کنندگان، بحران مالی را حاصل برهم‌کنش هم‌زمان متغیرهای کلان اقتصادی و رفتار بازار سرمایه می‌دانستند. از دید آنان، شاخص‌هایی مانند تورم، نرخ ارز، رشد نقدینگی، نرخ بهره، کسری بودجه، رشد اقتصادی، بدهی دولت، وضعیت تراز پرداخت‌ها و حجم اعتبارات بانکی، زمینه ساختاری بحران را نشان می‌دهند؛ درحالی‌که داده‌های بازار سرمایه مانند بازده شاخص، نوسان‌پذیری، ارزش معاملات، ورود و خروج نقدینگی، نسبت قیمت به سود، رفتار صنایع پیشرو، صف‌های خرید و فروش، افت نقدشوندگی و همبستگی غیرعادی بین دارایی‌ها می‌توانند سیگنال‌های سریع‌تری از فشار مالی ارائه دهند. یکی از مشارکت‌کنندگان بیان کرد: «بحران اول در نمودار شاخص دیده نمی‌شود؛ اول در نسبت‌های نقدینگی، نرخ ارز، رفتار پول هوشمند و افت کیفیت معاملات ظاهر می‌شود .(P۴) « مشارکت‌کننده دیگری تأکید داشت: «اگر فقط داده‌های بورس را ببینیم، زمینه کلان بحران را نمی‌فهمیم؛ اگر فقط داده‌های کلان را ببینیم، سرعت واکنش بازار را از دست می‌دهیم .(P۱۱) «بر این اساس، مدل پیشنهادی باید دارای لایه ورودی چندمنبعی باشد که داده‌های کلان، بانکی، ارزی و بازار سرمایه را در تناوب‌های زمانی متفاوت دریافت، پاک‌سازی، هم‌تراز و استانداردسازی کند.

۲ مقوله دوم: معماری یادگیری عمیق و شناسایی الگوهای پیشابحران

دومین مقوله به طراحی معماری یادگیری عمیق اختصاص داشت. مشارکت‌کنندگان بر این باور بودند که بحران مالی معمولاً با یک علامت منفرد قابل شناسایی نیست، بلکه از ترکیب تغییرات تدریجی، جهش‌های ناگهانی، واگرایی شاخص‌ها و رفتارهای غیرعادی در دوره‌های متوالی شکل می‌گیرد. از این منظر، مدل‌هایی مانندLSTM ، GRU، شبکه‌های ترکیبی CNN-LSTM و سازوکارهای توجه می‌توانند برای شناسایی وابستگی‌های زمانی و الگوهای پنهان پیشابحران مناسب باشند. یکی از متخصصان علم داده گفت: «مسئله بحران مالی، مسئله توالی است؛ باید فهمید سه ماه قبل چه اتفاقی افتاده، یک ماه قبل چه تغییری رخ داده و امروز کدام متغیر از روند عادی خارج شده است .(P۷) «مشارکت‌کننده‌ای

از حوزه بازار سرمایه نیز اظهار داشت: «مدلی که فقط سطح شاخص را پیش‌بینی کند کافی نیست؛ مدل باید تغییر رژیم را بفهمد، یعنی تشخیص دهد بازار از فاز نوسان عادی وارد فاز شکنندگی شده است .(P۲) «در مدل مفهومی پژوهش، معماری یادگیری عمیق شامل سه بخش اصلی است: مهندسی ویژگی و ساخت متغیرهای تأخیری، پردازش توالی‌های زمانی چندمتغیره، و تولید احتمال بحران در افق‌های زمانی کوتاه‌مدت، میان‌مدت و بلندمدت.

۳ مقوله سوم: تبیین‌پذیری، اعتبارسنجی و اعتماد به مدل

سومین مقوله نشان داد که دقت پیش‌بینی به‌تنهایی برای پذیرش مدل کافی نیست. مشارکت‌کنندگان تأکید داشتند که اگر خروجی مدل برای مدیران مالی و سیاست‌گذاران قابل توضیح نباشد، در عمل استفاده نخواهد شد. از دید آنان، مدل باید علاوه بر اعلام احتمال بحران، نشان دهد که کدام متغیرها در افزایش ریسک نقش داشته‌اند، سهم هر شاخص در هشدار چقدر بوده و آیا هشدار با منطق اقتصادی سازگار است یا خیر. یکی از مدیران ریسک بانکی گفت: «هیچ مدیر ارشدی فقط به‌خاطر اینکه یک شبکه عصبی عدد ۸۰ درصد داده تصمیم نمی‌گیرد؛ باید بداند پشت این عدد چیست .(P۹) «مشارکت‌کننده دیگری بیان کرد: «اگر مدل نتواند بگوید افزایش ریسک از نرخ ارز آمده یا از افت نقدشوندگی بازار، هشدار آن برای سیاست‌گذار مبهم است .(P۱۵) «بر این اساس، مدل پیشنهادی باید دارای لایه تبیین‌پذیری باشد که از ابزارهایی مانند اهمیت ویژگی‌ها، تحلیل حساسیت، سناریوسازی، آزمون تنش و روش‌های توضیح‌پذیری پس از آموزش استفاده کند. همچنین اعتبارسنجی مدل باید بر اساس داده‌های برون‌نمونه‌ای، آزمون در دوره‌های بحران واقعی، سنجش نرخ هشدار غلط و نرخ بحران‌های ازدست‌رفته انجام شود.

٤ مقوله چهارم: حکمرانی داده و مدیریت ریسک مدل

چهارمین مقوله به زیرساخت نهادی و حکمرانی داده مربوط بود. مشارکت‌کنندگان معتقد بودند که ضعف کیفیت داده، نبود دسترسی یکپارچه، تأخیر انتشار شاخص‌های کلان، تغییرات تعاریف آماری، داده‌های ناقص و نبود استاندارد مشترک میان نهادها، از مهم‌ترین موانع پیاده‌سازی مدل پیش‌بینی بحران مالی است. یکی از فعالان فناوری مالی اظهار داشت: «در ایران قبل از اینکه درباره مدل عمیق حرف بزنیم، باید درباره داده عمیق حرف بزنیم؛ داده پراکنده و ناسازگار، مدل هوشمند تولید نمی‌کند .(P۱۳) «یکی از اقتصاددانان نیز گفت: «اگر سری زمانی تورم، ارز، نقدینگی و شاخص بازار با تأخیر و شکست ساختاری وارد مدل شود، خروجی مدل بیشتر بازتاب آشفتگی داده است تا ریسک واقعی « .(P۶)یافته‌ها نشان داد که مدل پیش‌بینی بحران باید با چارچوب حکمرانی داده همراه باشد؛ شامل مالکیت داده، استانداردسازی، کنترل کیفیت، مستندسازی، امنیت، محرمانگی، به‌روزرسانی مستمر و مسئولیت‌پذیری در استفاده از خروجی مدل. افزون بر این، مدیریت ریسک مدل باید شامل پایش خطا، بازآموزی دوره‌ای، کنترل بیش‌برازش، ارزیابی پایداری و بررسی سوگیری‌های احتمالی باشد.

٥ مقوله پنجم: کاربست نهادی سامانه هشدار زودهنگام

پنجمین مقوله نشان داد که ارزش مدل پیش‌بینی بحران زمانی آشکار می‌شود که به سازوکار تصمیم‌گیری نهادی متصل شود. مشارکت‌کنندگان تأکید داشتند که خروجی مدل باید به‌صورت هشدارهای سطح‌بندی‌شده طراحی شود؛ برای مثال وضعیت سبز، زرد، نارنجی و قرمز که هرکدام

به مجموعه‌ای از اقدامات سیاستی، نظارتی یا مدیریتی متصل باشند. یکی از کارشناسان نهاد ناظر گفت: «هشدار بدون پروتکل اقدام، فقط یک گزارش تحلیلی است؛ سامانه هشدار باید بگوید وقتی ریسک از سطح مشخصی عبور کرد، چه نهادی چه کاری انجام دهد .(P۱۸) «مشارکت‌کننده دیگری بیان کرد: «مدل باید زبان مشترک میان تحلیلگر، مدیر ریسک، مقام ناظر و سیاست‌گذار بسازد؛ نه اینکه فقط یک داشبورد پیچیده برای متخصص داده باشد .(P۱) «بر این اساس، مدل نهایی پژوهش شامل پنج لایه است: لایه داده، لایه پردازش و مهندسی ویژگی، لایه یادگیری عمیق، لایه تبیین و اعتبارسنجی، و لایه تصمیم‌یار نهادی. در این مدل، خروجی نهایی فقط احتمال بحران نیست، بلکه بسته‌ای از هشدار، توضیح، سناریو، سطح ریسک و پیشنهاد اقدام است.

بحث

یافته نخست پژوهش نشان داد که پیش‌بینی بحران مالی مستلزم یکپارچه‌سازی داده‌های کلان اقتصادی و داده‌های بازار سرمایه است. این یافته با ادبیات سامانه‌های هشدار زودهنگام همسو است؛ زیرا مطالعات کلاسیک نشان داده‌اند که بحران‌ها معمولاً پیش از وقوع، در رفتار شاخص‌هایی مانند نرخ ارز، ذخایر، اعتبارات، قیمت دارایی‌ها، تولید و بازار سهام نشانه‌هایی از خود بروز می‌دهند (Kaminsky et al., ۱۹۹۸; Berg & Pattillo, ۱۹۹۹). همچنین یافته حاضر با پژوهش Lo Duca و (۲۰۱۳) Peltonen سازگار است که بر اهمیت شاخص‌های کلان مالی و فشار مالی در پیش‌بینی رویدادهای سیستمی تأکید کرده‌اند. از دیدگاه نظری، این نتیجه نشان می‌دهد که بحران مالی را نباید صرفاً به‌عنوان یک رویداد بازارمحور یا صرفاً کلان‌اقتصادی در نظر گرفت؛ بلکه بحران حاصل اتصال میان چرخه اعتبارات، قیمت دارایی‌ها، نقدشوندگی بازار، انتظارات سرمایه‌گذاران و سیاست‌های اقتصادی است. بنابراین، مدلی که تنها بر داده‌های بورس متکی باشد، ممکن است زمینه‌های ساختاری بحران را نادیده بگیرد و مدلی که تنها بر داده‌های کلان تکیه کند، ممکن است از سرعت واکنش بازار عقب بماند. این نتیجه همچنین با شواهد مربوط به پایگاه داده بحران‌های بانکی سازگار است که نشان می‌دهد بحران‌ها اغلب با هزینه‌های واقعی و سیاستی قابل توجه همراه هستند و باید پیش از تبدیل شدن به رخداد آشکار شناسایی شوند.(Laeven & Valencia, ۲۰۱۸)

یافته دوم پژوهش بر ضرورت استفاده از معماری‌های یادگیری عمیق برای شناسایی الگوهای پیشابحران تأکید داشت. مشارکت‌کنندگان معتقد بودند که بحران مالی یک پدیده توالی‌مند است و در آن، روندهای تاریخی، تغییرات تأخیری و وابستگی‌های زمانی نقش تعیین‌کننده دارند. این یافته با مبانی یادگیری عمیق سازگار است؛ زیرا شبکه‌های عمیق توانایی استخراج الگوهای پیچیده و غیرخطی از داده‌ها را دارند (LeCun et al., ۲۰۱۵). به‌طور خاص، شبکه‌های LSTM برای تحلیل سری‌های زمانی طراحی شده‌اند و می‌توانند بخشی از مشکل وابستگی‌های بلندمدت را در داده‌های متوالی مدیریت کنند .(Hochreiter & Schmidhuber, ۱۹۹۷) در حوزه مالی نیز Fischer و (۲۰۱۸) Krauss نشان دادند که LSTM در پیش‌بینی حرکت‌های بازار سهام می‌تواند کارکرد مناسبی داشته باشد، و Nabipour و همکاران (۲۰۲۰) نیز در زمینه بازار سرمایه تهران، کاربرد مدل‌های یادگیری ماشین و عمیق را در پیش‌بینی روندهای بازار بررسی کرده‌اند. بنابراین، یافته حاضر نشان می‌دهد که در طراحی مدل پیش‌بینی بحران، استفاده از مدل‌های توالی‌محور نه یک انتخاب تزئینی، بلکه پاسخی به ماهیت زمانی و پویا بودن

بحران است. بااین‌حال، باید توجه داشت که دقت بالای مدل در داده‌های تاریخی الزاماً به معنای کارآمدی آن در شرایط بحران آینده نیست؛ زیرا بحران‌ها معمولاً با شکست ساختاری، تغییر رژیم و رفتارهای خارج از نمونه همراه‌اند.

یافته سوم پژوهش نشان داد که تبیین‌پذیری و اعتبارسنجی، شرط پذیرش مدل توسط تصمیم‌گیران است. این یافته با ادبیات هوش مصنوعی توضیح‌پذیر هم‌راستاست که تأکید می‌کند مدل‌های پیچیده، اگرچه ممکن است دقت بالایی داشته باشند، اما در حوزه‌های حساس مانند مالی، سلامت و سیاست‌گذاری بدون توضیح قابل اتکا نیستند Lundberg .و (۲۰۱۷) Lee با معرفی چارچوب SHAP نشان دادند که امکان اختصاص سهم اهمیت به ویژگی‌های مدل وجود دارد و این امر می‌تواند فاصله میان دقت الگوریتمی و فهم انسانی را کاهش دهد. در زمینه پیش‌بینی بحران مالی، این موضوع اهمیت مضاعف دارد؛ زیرا هشدار مدل ممکن است به تصمیم‌هایی مانند محدودسازی اعتبارات، تغییر الزامات نظارتی، افزایش کنترل ریسک، مداخله در بازار یا اطلاع‌رسانی عمومی منجر شود. بنابراین، خروجی مدل باید به زبان قابل فهم برای مدیران ریسک و سیاست‌گذاران تبدیل شود. یافته حاضر نشان می‌دهد که تبیین‌پذیری فقط ویژگی فنی مدل نیست، بلکه بخشی از مشروعیت نهادی و اعتماد تصمیم‌گیری است. اگر مدل نتواند نشان دهد که هشدار ناشی از کدام متغیرها و کدام سازوکار اقتصادی است، احتمال استفاده عملی از آن کاهش می‌یابد؛ حتی اگر از نظر آماری عملکرد مناسبی داشته باشد.

یافته چهارم پژوهش به اهمیت حکمرانی داده و مدیریت ریسک مدل اشاره داشت. این یافته نشان می‌دهد که شکست سامانه‌های پیش‌بینی بحران الزاماً از ضعف الگوریتم ناشی نمی‌شود، بلکه ممکن است ریشه در داده‌های ناقص، ناسازگار، دیرهنگام، غیرقابل اعتماد یا فاقد استاندارد داشته باشد. این نتیجه با ادبیات مدیریت ریسک مالی و هوش مصنوعی همسو است که کیفیت داده، مستندسازی، اعتبارسنجی، پایش عملکرد و کنترل بیش‌برازش را از پیش‌شرط‌های کاربرد مدل‌های هوشمند می‌داند. مرور Fethi و (۲۰۱۰) Pasiouras نیز نشان داده است که کاربرد روش‌های هوش مصنوعی در ارزیابی عملکرد بانکی و مالی زمانی ارزشمند است که با فهم روش‌شناختی و داده‌ای همراه باشد. در زمینه بازارهای نوظهور، اهمیت حکمرانی داده بیشتر است؛ زیرا تغییرات مقرراتی، محدودیت‌های معاملاتی، وقفه انتشار داده‌ها و شوک‌های سیاسی و ارزی می‌تواند کیفیت یادگیری مدل را تحت تأثیر قرار دهد. بنابراین، مدل پیشنهادی پژوهش نباید به‌صورت یک الگوریتم مستقل دیده شود، بلکه باید به‌عنوان بخشی از معماری نهادی داده‌محور طراحی شود. این معماری باید شامل استانداردهای داده، مسئولیت نگهداری، کنترل دسترسی، امنیت اطلاعات، بازآموزی مدل و سازوکار حسابرسی الگوریتمی باشد.

یافته پنجم پژوهش نشان داد که سامانه پیش‌بینی بحران زمانی اثربخش است که به پروتکل‌های تصمیم‌گیری و اقدام نهادی متصل شود. این یافته با فلسفه سامانه‌های هشدار زودهنگام همسو است؛ زیرا هدف چنین سامانه‌هایی صرفاً پیش‌بینی نیست، بلکه فراهم کردن فرصت مداخله پیشگیرانه است. در مطالعه Sevim و همکاران (۲۰۱۴)، توسعه سامانه هشدار زودهنگام برای بحران ارزی با استفاده از مدل‌های مختلف نشان داد که مدل‌های پیش‌بینی باید در خدمت هشدار عملیاتی قرار گیرند، نه صرفاً تولید خروجی آماری. بر اساس یافته حاضر، مدل پیشنهادی باید خروجی‌های سطح‌بندی‌شده تولید کند و هر سطح هشدار به اقدام مشخصی متصل باشد؛ برای مثال افزایش پایش نقدشوندگی، بررسی

تمرکز ریسک، محدودسازی اهرم، تعدیل سیاست اعتباری، اطلاع‌رسانی به نهادهای ذی‌ربط یا اجرای آزمون تنش. از نظر کاربردی، این یافته نشان می‌دهد که مدل‌های یادگیری عمیق در صورتی می‌توانند به تاب‌آوری مالی کمک کنند که با ظرفیت نهادی، فرایند پاسخ‌گویی، ساختار تصمیم‌گیری و فرهنگ استفاده از داده همراه شوند. در غیر این صورت، حتی مدل دقیق نیز ممکن است به گزارشی تبدیل شود که پس از وقوع بحران مورد توجه قرار می‌گیرد، نه ابزاری برای پیشگیری از آن.

این پژوهش با وجود ارائه بینش‌های مفهومی و کاربردی، دارای محدودیت‌هایی است. نخست، داده‌های پژوهش بر مصاحبه با خبرگان شهر تهران متکی است؛ بنابراین، ممکن است دیدگاه خبرگان سایر شهرها، نهادهای مالی منطقه‌ای یا فعالان بازارهای بین‌المللی به‌طور کامل بازتاب نیافته باشد. دوم، پژوهش ماهیت کیفی دارد و هدف آن طراحی مدل مفهومی بوده است؛ ازاین‌رو، عملکرد کمی مدل پیشنهادی بر اساس داده‌های واقعی سری زمانی آزمون نشده است. سوم، برخی مشارکت‌کنندگان به‌دلیل حساسیت موضوع بحران مالی و محدودیت‌های سازمانی، ممکن است در بیان برخی تجربه‌ها محافظه‌کارانه عمل کرده باشند. چهارم، بخش‌هایی از مدل، مانند معماری دقیق یادگیری عمیق، انتخاب پنجره زمانی، وزن‌دهی متغیرها و معیارهای ارزیابی، نیازمند پژوهش‌های کمی تکمیلی است.

پیشنهاد می‌شود پژوهش‌های آینده مدل مفهومی ارائه‌شده را با استفاده از داده‌های واقعی بازار سرمایه، شاخص‌های کلان اقتصادی، داده‌های بانکی و شاخص‌های فشار مالی آزمون کنند. همچنین می‌توان عملکرد مدل‌های مختلف مانندLSTM ، GRU، Transformer، CNN-LSTM، XGBoostو مدل‌های ترکیبی را در افق‌های پیش‌بینی متفاوت مقایسه کرد. پژوهش‌های آینده بهتر است تعریف‌های مختلف بحران، از جمله افت شدید شاخص، جهش نوسان‌پذیری، بحران نقدشوندگی، بحران بانکی و بحران ارزی را به‌صورت جداگانه و ترکیبی بررسی کنند. افزون بر این، استفاده از داده‌های جایگزین مانند اخبار اقتصادی، احساسات شبکه‌های اجتماعی، داده‌های معاملات حقیقی و حقوقی، و شاخص‌های انتظارات تورمی می‌تواند به توسعه مدل‌های دقیق‌تر کمک کند. انجام مطالعات تطبیقی میان بازارهای نوظهور نیز می‌تواند اعتبار بیرونی مدل را افزایش دهد.

نهادهای مالی و سیاست‌گذار می‌توانند بر اساس مدل پیشنهادی، یک سامانه هشدار زودهنگام چندلایه طراحی کنند که داده‌های کلان اقتصادی، بازار سرمایه، بانکی و ارزی را به‌صورت مستمر پایش کند. سازمان بورس، بانک مرکزی، بانک‌ها، صندوق‌های سرمایه‌گذاری و نهادهای مدیریت ریسک بهتر است استانداردهای مشترک داده، داشبوردهای هشدار سطح‌بندی‌شده و پروتکل‌های اقدام پیشگیرانه تدوین کنند. همچنین لازم است خروجی مدل برای کاربران غیرفنی قابل فهم باشد و در کنار احتمال بحران، توضیح متغیرهای اثرگذار، سناریوهای محتمل و توصیه‌های عملیاتی ارائه شود. آموزش مدیران مالی و سیاست‌گذاران در زمینه تفسیر خروجی مدل‌های هوشمند، ایجاد تیم‌های بین‌رشته‌ای و استقرار حسابرسی الگوریتمی می‌تواند اثربخشی چنین سامانه‌ای را افزایش دهد.

نتیجه‌گیری

پژوهش حاضر با هدف ارائه مدل پیش‌بینی بحران‌های مالی مبتنی بر یادگیری عمیق، شاخص‌های کلان اقتصادی و داده‌های بازار سرمایه انجام شد. یافته‌های کیفی نشان داد که پیش‌بینی بحران مالی نیازمند نگاهی یکپارچه به داده، الگوریتم، تبیین‌پذیری، حکمرانی و تصمیم‌گیری نهادی است. مدل پیشنهادی پژوهش از پنج لایه اصلی تشکیل می‌شود: لایه داده‌های کلان و بازار سرمایه، لایه پردازش و مهندسی ویژگی، لایه یادگیری عمیق، لایه تبیین‌پذیری و اعتبارسنجی، و لایه تصمیم‌یار نهادی. این مدل نشان می‌دهد که ارزش یادگیری عمیق در پیش‌بینی بحران مالی زمانی تحقق می‌یابد که داده‌های معتبر و چندمنبعی در دسترس باشد، خروجی مدل قابل توضیح باشد، هشدارها به اقدامات مشخص متصل شوند و نهادهای مالی توان استفاده از مدل را داشته باشند. بر این اساس، بحران مالی نه فقط با الگوریتم، بلکه با ترکیب هوشمندانه داده، تخصص انسانی، نظارت نهادی و تصمیم‌گیری پیشگیرانه قابل مدیریت است.

تشکر و قدردانی

از تمامی کسانی که در انجام این پژوهش ما را همراهی کردند تشکر و قدردانی به عمل می‌آید.

موازین اخلاقی

در این پژوهش اصول اخلاقی مرتبط با نشر و انجام پژوهش رعایت گردیده است.

مشارکت نویسندگان

تمامی نویسندگان نقش یکسانی ایفا کردند.

تعارض منافع

بر اساس اظهار نویسندگان، در این مقاله هیچ‌گونه تضاد منافعی وجود ندارد.

فهرست منابع

Berg, A., & Pattillo, C. (1999). Are currency crises predictable? A test. *IMF Staff Papers, 46*(2), 107–138.

Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology, 3*(2), 77–101. https://doi.org/10.1191/1478088706qp063oa

Creswell, J. W., & Poth, C. N. (2018). *Qualitative inquiry and research design: Choosing among five approaches* (4th ed.). SAGE Publications.

Demirgüç-Kunt, A., & Detragiache, E. (1998). The determinants of banking crises in developing and developed countries. *IMF Staff Papers, 45*(1), 81–109.

Fethi, M. D., & Pasiouras, F. (2010). Assessing bank efficiency and performance with operational research and artificial intelligence techniques: A survey. *European Journal of Operational Research, 204*(2), 189–198.

Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research, 270*(2), 654–669. https://doi.org/10.1016/j.ejor.2017.11.054

Hennink, M. M., Kaiser, B. N., & Marconi, V. C. (2017). Code saturation versus meaning saturation: How many interviews are enough? *Qualitative Health Research, 27*(4), 591–608. https://doi.org/10.1177/1049732316665344

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation, 9*(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735

Kaminsky, G. L., Lizondo, S., & Reinhart, C. M. (1998). Leading indicators of currency crises. *IMF Staff Papers, 45*(1), 1–48. https://doi.org/10.2307/3867328

Laeven, L., & Valencia, F. (2018). *Systemic banking crises revisited* (IMF Working Paper No. 18/206). International Monetary Fund. https://doi.org/10.5089/9781484376379.001

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*(7553), 436–444. https://doi.org/10.1038/nature14539

Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. SAGE Publications.

Lo Duca, M., & Peltonen, T. A. (2013). Assessing systemic risks and predicting systemic events. *Journal of Banking & Finance, 37*(7), 2183–2195.

Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems*.

Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data: A comparative analysis. *IEEE Access, 8*, 150199–150212. https://doi.org/10.1109/ACCESS.2020.3015966

Sevim, C., Oztekin, A., Bali, O., Gumus, S., & Guresen, E. (2014). Developing an early warning system to predict currency crises. *European Journal of Operational Research, 237*(3), 1095–1104.