

Liquidity Risk Dynamics in the Iranian Interbank Network under Macroeconomic Stabilization Policies: A Support Vector Machine (SVM) Approach

1. Fatemeh Ebrahimsarveolya*: Department of Financial Management, SR.C., Islamic Azad University, Tehran, Iran. Email: f.ebrahimsarv@iau.ac.ir (Corresponding Author)

Abstract:

This study aimed to investigate liquidity risk dynamics in the Iranian interbank network and evaluate the impact of macroeconomic stabilization policies on systemic liquidity risk using a Support Vector Machine (SVM) framework. The study employed a quantitative and applied research design based on daily interbank market data from 2013 to 2023. The sample consisted of 32 banks and credit institutions operating within Iran's interbank network. Systemic liquidity risk was calculated using network-based and macro-financial indicators and classified into low, moderate, and severe risk categories. Ten explanatory variables, including network centrality, Herfindahl–Hirschman Index (HHI), repo rate deviation from the policy corridor, overdraft volume, interbank interest rate volatility, illiquid asset ratio, inflation rate, exchange rate, monetary policy measure, and liquidity contagion index, were selected as model inputs. Linear, polynomial, and radial basis function (RBF) kernels were evaluated, and optimal hyperparameters were identified through grid search and five-fold cross-validation. The RBF-SVM model with $C=10$ and $\gamma=0.05$ demonstrated superior predictive performance. During the stabilization period, the model achieved an overall accuracy of 94.3%, an F1-score of 0.941, and an ROC-AUC value of 0.97 for severe liquidity risk classification. Comparative analysis revealed that stabilization policies reduced interbank interest rate volatility by 43.6%. However, liquidity risk persistence increased substantially, with the first-order autocorrelation coefficient rising from 0.52 to 0.78, while market concentration increased as the HHI rose from 0.24 to 0.41. Feature importance analysis identified network centrality, HHI concentration, and repo rate deviation from the policy corridor as the strongest predictors of severe liquidity risk. Although macroeconomic stabilization policies successfully reduced short-term market volatility, they simultaneously increased liquidity risk persistence and concentration within the interbank network. The proposed SVM model provides a highly effective early-warning mechanism for detecting systemic liquidity stress and can support policymakers and central banks in strengthening financial stability and liquidity risk management.

Keywords: Liquidity Risk; Interbank Network; Macroeconomic Stabilization Policy; Support Vector Machine; Machine Learning; Systemic Risk.

Article history



Received: 21 January 2026

Revised: 08 June 2026

Accepted: 16 June 2026

Initial Publish: 15 July 2026

Final Publish: 23 August 2027

Citation: Ebrahimsarveolya, F. (2027). Liquidity Risk Dynamics in the Iranian Interbank Network under Macroeconomic Stabilization Policies: A Support Vector Machine (SVM) Approach. *Accounting, Finance and Computational Intelligence*, 5(3), 1-20.



Copyright: © 2027 by the authors. Published under the terms and conditions of Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

Extended Abstract**Introduction**

Liquidity risk has emerged as one of the most critical challenges confronting modern banking systems, particularly in environments characterized by macroeconomic instability, financial constraints, and structural imbalances. Financial institutions depend heavily on their ability to obtain and redistribute liquidity efficiently; therefore, disruptions in liquidity flows may rapidly transform localized financial stress into systemic crises. Previous studies have emphasized that liquidity risk is not merely a bank-specific phenomenon but a systemic issue that can significantly influence financial stability, default probability, and market confidence (Abdesslem et al., 2022). The increasing interconnectedness of financial institutions through interbank markets has further intensified the importance of understanding liquidity risk transmission mechanisms and network vulnerabilities (Liu, 2024). In contemporary financial systems, liquidity conditions influence a broad spectrum of economic and financial outcomes, including funding availability, leverage decisions, investment behavior, and market valuation (Armanious & Zhao, 2024; Chen, 2024). Research has also demonstrated that liquidity conditions affect stock returns and investor behavior, highlighting the central role of liquidity in financial market dynamics (Musneh et al., 2021; Zhang et al., 2021). Furthermore, liquidity risk has been found to interact with other forms of financial risk, particularly credit risk, creating feedback mechanisms that amplify systemic vulnerabilities (Basheer et al., 2021; Shoja'i Asl, 2023). These interactions have elevated liquidity risk management to a central concern for regulators and policymakers worldwide.

The growing complexity of financial networks has shifted scholarly attention from individual institutions toward systemic perspectives that emphasize interconnectedness and contagion effects. Interbank networks represent the primary channels through which liquidity is redistributed among financial institutions, making them essential components of financial stability frameworks. Empirical evidence suggests that network topology, centrality structures, and market concentration significantly affect the resilience of banking systems against liquidity shocks (Liu, 2024). Simultaneously, macroeconomic stabilization policies implemented by central banks often generate unintended consequences for liquidity allocation and risk distribution within banking networks. While such policies may successfully reduce short-term volatility, they can also alter liquidity flows, increase dependence on key institutions, and affect systemic resilience. Studies have highlighted the influence of macroeconomic uncertainty, monetary policy interventions, and funding constraints on liquidity risk dynamics (Dang & Nguyen, 2022; Hacini et al., 2021). In Iran, prolonged inflationary pressures, exchange-rate fluctuations, sanctions, and monetary restrictions have intensified the importance of liquidity management within the banking sector. Recent domestic studies have identified various determinants of liquidity risk, including accounting indicators, financial characteristics, and macroeconomic variables (Khosraviani & Heidarpour, 2022; Moghadam et al., 2025). Nevertheless, the combined effects of stabilization policies and interbank network structures on systemic liquidity risk remain insufficiently explored.

The rapid development of artificial intelligence and machine learning techniques has introduced new opportunities for analyzing complex financial phenomena. Traditional econometric models often struggle to capture nonlinear relationships, threshold effects, and multidimensional interactions that characterize financial systems. Consequently, machine learning approaches have become increasingly popular in risk prediction and financial forecasting. Research on AI-driven financial systems has demonstrated the effectiveness of advanced algorithms in identifying systemic vulnerabilities and improving predictive accuracy (Ogbuonyalu et al., 2024). Meanwhile, studies on liquidity management, financial stability, investment risk, and market liquidity have highlighted the need for more sophisticated analytical tools capable of integrating multiple

sources of information (Khezriyan et al., 2023; Marjohan et al., 2023; Shirbandi et al., 2023). Additional evidence suggests that liquidity conditions are closely linked to cash-holding behavior, market uncertainty, investment opportunities, and financial performance (Maleki Hassan & Arab, 2023; Mariska et al., 2025). Furthermore, international research has documented liquidity spillover effects across markets and financial systems, reinforcing the importance of network-oriented approaches (Lu, 2023; Saleemi, 2022). Despite these developments, limited research has simultaneously investigated systemic liquidity risk, macroeconomic stabilization policies, and machine-learning techniques within the context of Iran's interbank market. This study addresses this gap by employing a Support Vector Machine (SVM) framework to analyze liquidity risk dynamics in the Iranian interbank network and evaluate the effects of macroeconomic stabilization policies on systemic liquidity behavior.

Methods and Materials

This study employed a quantitative and applied research design focusing on the Iranian interbank market. The statistical population consisted of 32 commercial banks and credit institutions operating within the interbank network. Daily data covering the period from 2013 to 2023 were collected, resulting in 3,652 observations. Data sources included interbank repo transactions, central bank balance sheet information, and macroeconomic indicators. Systemic liquidity risk was calculated as a weighted aggregate of individual bank liquidity risk measures and subsequently classified into three categories: low, moderate, and severe risk.

A comprehensive feature-selection process was conducted to identify the most relevant determinants of systemic liquidity risk. Following dimensionality reduction procedures, ten key variables were retained, including network centrality, Herfindahl–Hirschman concentration index (HHI), deviation of repo rates from the policy corridor, total overdraft volume, interbank interest rate volatility, ratio of illiquid assets, inflation rate, exchange rate, monetary policy measure (PMM), and liquidity contagion index. All variables were standardized prior to model estimation.

Support Vector Machine models were developed using three alternative kernel specifications, including linear, polynomial, and radial basis function (RBF) kernels. Hyperparameter optimization was performed through grid search combined with five-fold cross-validation. The dataset was divided into training, validation, and testing subsets. Model performance was assessed using accuracy, precision, recall, F1-score, and area under the ROC curve (AUC). To evaluate the impact of macroeconomic stabilization policies, the dataset was divided into two subperiods: the pre-stabilization period and the stabilization period. Comparative analyses were conducted to assess changes in liquidity risk persistence, market concentration, interbank interest rate behavior, and the frequency of severe liquidity-risk events.

Findings

The empirical results revealed substantial differences between the pre-stabilization and stabilization periods. Although the average interbank interest rate increased during the stabilization period, its volatility declined significantly, indicating improved short-term monetary stability. At the same time, daily overdraft volumes increased considerably, suggesting growing liquidity pressures within parts of the banking system. The frequency of severe liquidity-risk events rose moderately, while liquidity-risk persistence exhibited a substantial increase. The first-order autocorrelation coefficient of systemic liquidity risk increased from 0.52 before stabilization to 0.78 during stabilization, indicating stronger persistence and longer recovery periods following liquidity shocks. Market concentration also intensified, with the Herfindahl–Hirschman Index increasing

from 0.24 to 0.41, suggesting that liquidity provision became increasingly concentrated among a small number of major institutions.

Model comparison demonstrated clear superiority of the RBF-SVM specification. The linear kernel achieved an overall accuracy of 76.2%, while the polynomial kernel improved performance to 84.5%. The RBF kernel produced the strongest results, achieving 90.3% overall accuracy and an average AUC of 0.96. After optimization of decision thresholds, model performance improved further. For the stabilization period specifically, the optimized RBF-SVM model achieved an overall accuracy of 94.3%, an F1-score of 0.941, a recall rate of 0.932 for severe-risk observations, and an ROC-AUC value of 0.97. Confusion-matrix analysis indicated that the model correctly identified the majority of severe-risk events, making it suitable for early-warning applications.

Feature-importance analysis revealed that network centrality was the most influential predictor of severe liquidity risk. The Herfindahl concentration index ranked second, followed by repo-rate deviations from the policy corridor and interbank interest-rate volatility. Overdraft volume and liquidity contagion indicators also demonstrated substantial predictive power. The monetary policy measure exhibited a delayed effect, influencing liquidity risk approximately three days after policy adjustments. Exchange-rate fluctuations similarly affected liquidity conditions with a lag of approximately five days. These findings indicate that both network characteristics and macroeconomic conditions play important roles in shaping systemic liquidity-risk dynamics.

Discussion and Conclusion

The findings demonstrate that liquidity risk in the Iranian interbank market is fundamentally nonlinear and strongly influenced by network structures. The superior performance of the RBF-SVM model confirms that conventional linear approaches may fail to capture the complexity of liquidity-risk transmission mechanisms. Interactions among network centrality, concentration, funding conditions, and macroeconomic variables generate nonlinear effects that require advanced analytical frameworks for accurate identification and prediction.

A particularly important finding concerns the dual impact of macroeconomic stabilization policies. On one hand, stabilization measures successfully reduced short-term volatility in interbank interest rates and lowered overall pressure in money markets. These outcomes indicate that monetary authorities were effective in promoting short-run stability and reducing fluctuations. On the other hand, stabilization policies were associated with increased liquidity-risk persistence and higher concentration within the interbank network. The results suggest that while volatility became lower, liquidity shocks remained in the system for longer periods and became increasingly dependent on a limited number of key institutions. Consequently, apparent stability may have concealed deeper structural vulnerabilities.

The importance of network centrality and market concentration highlights the critical role of interbank structures in determining systemic resilience. Banks occupying central positions in the network have the capacity to transmit liquidity shocks throughout the entire financial system. Similarly, increasing concentration of liquidity provision among a small number of institutions raises the potential for systemic disruptions if those institutions experience financial stress. These findings underscore the necessity of monitoring network structures alongside traditional liquidity indicators.

The identification of delayed monetary-policy effects provides additional insights for policymakers. The existence of measurable lags between policy interventions and liquidity-risk responses suggests that preventive measures should be

implemented proactively rather than reactively. Policymakers must recognize that liquidity conditions respond gradually to monetary adjustments and that delayed effects can contribute to risk accumulation if not properly anticipated.

Overall, the study demonstrates that machine-learning techniques offer substantial advantages for monitoring systemic liquidity risk within complex financial networks. The proposed SVM framework provides an effective early-warning mechanism capable of identifying severe liquidity-risk conditions with high predictive accuracy. The findings further indicate that successful stabilization policies should focus not only on reducing volatility but also on preventing excessive concentration and persistence of risk within the interbank network. Sustainable financial stability requires balancing short-term stabilization objectives with long-term network resilience, ensuring that reductions in volatility do not inadvertently increase systemic fragility.

Authors' Contributions

Authors equally contributed to this article.

Acknowledgments

Authors thank all participants who participate in this study.

Declaration of Interest

The authors report no conflict of interest.

Funding

According to the authors, this article has no financial support.

Ethical Considerations

All procedures performed in this study were under the ethical standards.

پویایی های ریسک نقدینگی در شبکه بین بانکی ایران تحت سیاست های تثبیت اقتصاد کلان: رویکرد ماشین بردار پشتیبان (SVM)



تاریخچه مقاله

تاریخ دریافت: ۱ بهمن ۱۴۰۴
تاریخ بازنگری: ۱۸ خرداد ۱۴۰۵
تاریخ پذیرش: ۲۶ خرداد ۱۴۰۵
تاریخ چاپ اولیه: ۲۴ تیر ۱۴۰۵
تاریخ چاپ نهایی: ۱ شهریور ۱۴۰۶

۱. فاطمه ابراهیمی سروعلیا*^{ID}: گروه مدیریت مالی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. ایمیل:

f.ebrahimisarv@iau.ac.ir (نویسنده مسئول)

چکیده

هدف این پژوهش تحلیل پویایی های ریسک نقدینگی در شبکه بین بانکی ایران و ارزیابی اثر سیاست های تثبیت اقتصاد کلان بر رفتار این ریسک با استفاده از مدل ماشین بردار پشتیبان (SVM) است. این پژوهش از نوع کاربردی و مبتنی بر داده های روزانه شبکه بین بانکی ایران در دوره ۱۳۹۲ تا ۱۴۰۲ است. جامعه پژوهش شامل ۳۲ بانک و مؤسسه اعتباری فعال در بازار بین بانکی بود. ریسک نقدینگی سیستمی بر اساس شاخص های شبکه ای و متغیرهای پولی و مالی محاسبه و در سه سطح کم، متوسط و شدید طبقه بندی شد. ده متغیر کلیدی شامل درجه مرکزیت شبکه، شاخص تمرکز هرفیندال، فاصله نرخ باز خرید از خریدور سیاستی، حجم اضافه برداشت، نوسان نرخ سود بین بانکی، نسبت دارایی های غیر نقد، نرخ تورم، نرخ ارز، شاخص سیاست پولی و شاخص سرایت پذیری نقدینگی به عنوان ورودی مدل انتخاب شدند. برای آموزش و ارزیابی مدل از کرنل های خطی، چند جمله ای و RBF همراه با جستجوی شبکه ای و اعتبارسنجی متقاطع استفاده شد. نتایج نشان داد کرنل RBF با پارامترهای بهینه $C=10$ و $\gamma=0.05$ بهترین عملکرد را ارائه کرد. دقت کلی مدل در دوره تثبیت به ۹۴.۳ درصد، مقدار $F1-Score$ به ۰.۹۴۱ و سطح زیر منحنی ROC به ۰.۹۷ رسید. مقایسه دو دوره قبل و بعد از اجرای سیاست های تثبیت نشان داد نوسانات نرخ سود بین بانکی ۴۳.۶ درصد کاهش یافته است، اما چسبندگی ریسک نقدینگی از ۰.۵۲ به ۰.۷۸ و شاخص تمرکز هرفیندال از ۰.۲۴ به ۰.۴۱ افزایش یافته اند. تحلیل اهمیت متغیرها نشان داد درجه مرکزیت شبکه، شاخص تمرکز هرفیندال و فاصله نرخ باز خرید از خریدور سیاستی مهم ترین پیش بینی کننده های ریسک نقدینگی شدید هستند. اگرچه سیاست های تثبیت اقتصاد کلان توانسته اند نوسانات بازار پول را کاهش دهند، اما هم زمان موجب افزایش تمرکز و ماندگاری ریسک در شبکه بین بانکی شده اند. مدل پیشنهادی SVM قابلیت بالایی برای شناسایی زود هنگام شرایط بحرانی داشته و می تواند به عنوان یک سامانه هشدار سریع در مدیریت ریسک نقدینگی و تصمیم گیری سیاستی مورد استفاده قرار گیرد.

کلیدواژه ها: ریسک نقدینگی، شبکه بین بانکی، سیاست تثبیت اقتصاد کلان، ماشین بردار پشتیبان، یادگیری ماشین، ریسک سیستمی.

شبهه استناددهی: ابراهیمی سروعلیا، فاطمه. (۱۴۰۶). پویایی های ریسک نقدینگی در شبکه بین بانکی ایران تحت سیاست های تثبیت اقتصاد کلان: رویکرد ماشین بردار پشتیبان (SVM). *حسابداری، امور مالی و هوش محاسباتی*، ۵(۳)، ۱-۲۰.



ریسک نقدینگی یکی از بنیادی‌ترین و در عین حال پیچیده‌ترین مخاطرات نظام مالی مدرن به شمار می‌رود که می‌تواند پایداری بانک‌ها، کارایی بازارهای مالی و ثبات کل اقتصاد را تحت تأثیر قرار دهد. این ریسک زمانی بروز می‌یابد که یک مؤسسه مالی قادر نباشد تعهدات کوتاه‌مدت خود را در زمان مقرر و بدون تحمل هزینه‌های سنگین تأمین مالی ایفا کند. در دهه‌های اخیر، بحران‌های مالی متعدد نشان داده‌اند که کمبود نقدینگی نه تنها یک مسئله درون‌سازمانی برای بانک‌ها نیست، بلکه می‌تواند به سرعت به سایر نهادهای مالی سرایت کرده و به بحران‌های فراگیر و سیستمی منجر شود. از این‌رو، مدیریت ریسک نقدینگی به یکی از محورهای اصلی سیاست‌گذاری پولی، نظارت بانکی و مدیریت ریسک در سطح بین‌المللی تبدیل شده است (Abdesslem et al., 2022; Khezriyan et al., 2023). پژوهش‌ها نشان داده‌اند که ریسک نقدینگی ارتباط نزدیکی با احتمال نکول بانک‌ها داشته و افزایش آن می‌تواند احتمال شکست مؤسسات مالی را به طور معناداری افزایش دهد (Abdesslem et al., 2022).

در سال‌های اخیر، توجه پژوهشگران از بررسی ریسک نقدینگی در سطح منفرد بانک‌ها به مطالعه ابعاد سیستمی این ریسک و نحوه انتشار آن در شبکه‌های مالی معطوف شده است. در این رویکرد، بانک‌ها نه به عنوان واحدهای مستقل، بلکه به عنوان گره‌هایی در یک شبکه پیچیده از روابط مالی، اعتباری و معاملاتی در نظر گرفته می‌شوند. شبکه بین‌بانکی مهم‌ترین بستر انتقال نقدینگی میان بانک‌ها محسوب می‌شود و هرگونه اختلال در عملکرد آن می‌تواند پیامدهای گسترده‌ای برای کل نظام مالی به همراه داشته باشد. مطالعات جدید نشان می‌دهند که ساختار شبکه، میزان تمرکز ارتباطات، جایگاه بانک‌ها در شبکه و شدت وابستگی متقابل آنها نقش تعیین‌کننده‌ای در شکل‌گیری و انتقال ریسک نقدینگی دارند (Liu, 2024). در واقع، درک رفتار ریسک نقدینگی بدون توجه به ساختار شبکه‌ای نظام بانکی امکان‌پذیر نیست و تحلیل‌های سنتی مبتنی بر شاخص‌های منفرد قادر به تبیین کامل این پدیده نیستند.

اهمیت ریسک نقدینگی تنها به بخش بانکی محدود نمی‌شود، بلکه آثار آن در بازارهای سرمایه، بازار بدهی و حتی تصمیمات مالی شرکت‌ها نیز مشاهده می‌شود. تحقیقات نشان داده‌اند که نقدشوندگی دارایی‌ها بر ساختار سرمایه شرکت‌ها، سطح اهرم مالی و توانایی تأمین مالی آنها تأثیر مستقیم دارد (Armanious & Zhao, 2024). همچنین ارتباط میان نقدشوندگی بازار و تصمیمات مالی شرکت‌ها از جمله نگهداری وجه نقد، سرمایه‌گذاری و مدیریت سرمایه در گردش مورد تأیید قرار گرفته است (Chen, 2024; Mariska et al., 2025). از سوی دیگر، ریسک نقدینگی می‌تواند بازده دارایی‌های مالی و رفتار سرمایه‌گذاران را نیز تحت تأثیر قرار دهد، به گونه‌ای که تغییرات نقدشوندگی بازار به عنوان یکی از عوامل توضیح‌دهنده نوسانات بازده سهام مطرح شده است (Musneh et al., 2021; Zhang et al., 2021). این شواهد بیانگر آن است که ریسک نقدینگی نه تنها یک متغیر بانکی بلکه یک عامل کلیدی در عملکرد کل نظام مالی محسوب می‌شود.

در ادبیات مالی، رابطه متقابل میان ریسک نقدینگی و سایر انواع ریسک نیز مورد توجه گسترده قرار گرفته است. برخی پژوهش‌ها نشان داده‌اند که میان ریسک نقدینگی و ریسک اعتباری نوعی وابستگی درون‌زا وجود دارد؛ به گونه‌ای که افزایش یکی می‌تواند دیگری را تشدید کند (Basheer et al., 2021). همچنین شوک‌های نقدینگی قادرند ریسک اعتباری بانک‌ها را افزایش داده و کیفیت دارایی‌های آنها را تضعیف کنند (Shoja'i Asl, 2023). این تعاملات سبب شده است که ریسک نقدینگی به عنوان یکی از مهم‌ترین مؤلفه‌های ثبات مالی شناخته شود و مدیریت آن به یک ضرورت راهبردی برای سیاست‌گذاران پولی تبدیل گردد. مطالعات داخلی نیز بر نقش مدیریت صحیح جریان‌های نقدی و کنترل ریسک نقدینگی در حفظ ثبات مالی تأکید کرده‌اند (Shirbandi et al., 2023).

اقتصاد ایران در دهه گذشته با مجموعه‌ای از شوک‌های اقتصادی شامل تحریم‌های بین‌المللی، نوسانات شدید نرخ ارز، تورم مزمن، محدودیت‌های مالی و بحران‌های ناشی از همه‌گیری کووید-۱۹ مواجه بوده است. این شرایط موجب افزایش فشار بر نظام بانکی و تشدید مشکلات تأمین نقدینگی شده است. در چنین فضایی، شبکه بین‌بانکی به مهم‌ترین سازوکار توزیع مجدد نقدینگی میان بانک‌ها تبدیل شده و نقش آن در حفظ ثبات نظام مالی بیش از پیش اهمیت یافته است. با این حال، افزایش وابستگی بانک‌ها به منابع کوتاه‌مدت و تمرکز تأمین نقدینگی در برخی بانک‌های بزرگ، احتمال بروز ریسک‌های سیستمی را افزایش داده است. پژوهش‌های انجام شده در ایران نیز نشان داده‌اند که ریسک نقدینگی بانک‌ها تحت تأثیر مجموعه‌ای از عوامل مالی، حسابداری، ساختاری و کلان اقتصادی قرار دارد (Khosraviani & Heidarpour, 2022; Moghadam et al., 2025).

به منظور کنترل بی‌ثباتی‌های اقتصادی و مهار تورم، سیاست‌های تثبیت اقتصاد کلان در سال‌های اخیر به طور گسترده در ایران اجرا شده‌اند. این سیاست‌ها شامل کنترل رشد ترازنامه بانک‌ها، اعمال محدودیت بر اضافه‌برداشت‌ها، افزایش نظارت بر بازار پول، مدیریت نرخ سود و کنترل رشد نقدینگی بوده‌اند. هرچند این اقدامات در کاهش نوسانات برخی متغیرهای کلان اقتصادی موفقیت‌هایی داشته‌اند، اما آثار آنها بر رفتار شبکه بین‌بانکی و پویایی‌های ریسک نقدینگی هنوز به طور کامل شناخته نشده است. برخی مطالعات نشان داده‌اند که سیاست‌های پولی و محدودیت‌های نقدینگی می‌توانند الگوهای تأمین مالی بانک‌ها را تغییر داده و به افزایش تمرکز ریسک در بخش‌هایی از شبکه مالی منجر شوند (Dang & Nguyen, 2022). از سوی دیگر، اثرات تأخیری سیاست‌های پولی بر وضعیت نقدینگی بانک‌ها نشان می‌دهد که ارزیابی پیامدهای این سیاست‌ها نیازمند رویکردهای تحلیلی پیشرفته و پویا است (Hacini et al., 2021).

همزمان با گسترش داده‌های مالی و افزایش پیچیدگی تعاملات میان نهادهای مالی، روش‌های سنتی آماری برای تحلیل ریسک نقدینگی با محدودیت‌هایی مواجه شده‌اند. بسیاری از روابط موجود در بازارهای مالی ماهیتی غیرخطی، پویا و وابسته به ساختار شبکه دارند؛ در نتیجه مدل‌های خطی کلاسیک قادر به شناسایی کامل این الگوها نیستند. در سال‌های اخیر، استفاده از روش‌های هوش مصنوعی و یادگیری ماشین به عنوان ابزارهایی قدرتمند برای تحلیل داده‌های مالی گسترش یافته است. این روش‌ها توانایی استخراج الگوهای پیچیده، شناسایی روابط پنهان و پیش‌بینی رفتار سیستم‌های مالی را دارند. توسعه معاملات الگوریتمی و کاربرد گسترده هوش مصنوعی در بازارهای مالی نیز اهمیت استفاده از مدل‌های یادگیری ماشین را دوچندان کرده است (Ogbuonyalu et al., 2024). در این میان، ماشین بردار پشتیبان (SVM) به دلیل توانایی بالا در طبقه‌بندی داده‌های غیرخطی و عملکرد مناسب در نمونه‌های با ابعاد بالا، به یکی از روش‌های پرکاربرد در حوزه مدیریت ریسک مالی تبدیل شده است.

مطالعات متعددی کاربرد روش‌های هوش مصنوعی را در پیش‌بینی ریسک نقدینگی بررسی کرده‌اند. در ایران، مدل‌های شبکه عصبی مصنوعی برای پیش‌بینی ریسک نقدینگی بانک‌های دولتی مورد استفاده قرار گرفته و نتایج مطلوبی ارائه کرده‌اند (Khosraviani & Heidarpour, 2022). با این حال، بیشتر این مطالعات بر داده‌های ترازنامه‌ای بانک‌ها تمرکز داشته و ساختار شبکه بین‌بانکی را نادیده گرفته‌اند. در سطح بین‌المللی نیز تحقیقات گسترده‌ای پیرامون انتقال ریسک در شبکه‌های مالی انجام شده است، اما بخش عمده این پژوهش‌ها بر بازار سهام یا بازارهای سرمایه متمرکز بوده‌اند (Lu, 2023; Saleemi, 2022). در حالی که شبکه بین‌بانکی به دلیل نقش محوری در توزیع نقدینگی، نیازمند بررسی مستقل و تخصصی است.

از سوی دیگر، شواهد تجربی نشان می‌دهد که ریسک نقدینگی تحت تأثیر عوامل متعددی نظیر تورم، نرخ ارز، فرصت‌های سرمایه‌گذاری، بازده بازار، ابهام جریان‌های نقدی و ساختار سرمایه قرار دارد (Maleki Hassan & Arab, 2023; Marjohan et al., 2023). این عوامل نه تنها بر سطح نقدینگی بانک‌ها اثر می‌گذارند، بلکه می‌توانند نحوه انتشار شوک‌های نقدینگی در شبکه مالی را نیز تغییر دهند. افزون بر این، مطالعات اخیر بر نقش نقدشوندگی بازار در انتقال ریسک‌های سیستمی و شکل‌گیری آسیب‌پذیری‌های مالی تأکید کرده‌اند (Liu, 2024). بنابراین، تحلیل جامع ریسک نقدینگی مستلزم در نظر گرفتن همزمان عوامل کلان اقتصادی، شاخص‌های شبکه‌ای و ویژگی‌های ساختاری بازار مالی است.

مرور ادبیات پژوهش نشان می‌دهد که اگرچه مطالعات متعددی به بررسی ریسک نقدینگی، مدیریت نقدینگی، انتقال ریسک در شبکه‌های مالی و کاربرد روش‌های یادگیری ماشین پرداخته‌اند، اما همچنان شکاف‌های پژوهشی مهمی وجود دارد. نخست آنکه بخش قابل توجهی از تحقیقات موجود، ریسک نقدینگی را در سطح منفرد بانک‌ها بررسی کرده‌اند و کمتر به ابعاد سیستمی آن در شبکه بین‌بانکی توجه داشته‌اند (Khezriyan et al., 2023). دوم آنکه مطالعات اندکی تأثیر سیاست‌های تثبیت اقتصاد کلان را بر پویایی‌های ریسک نقدینگی شبکه‌ای ارزیابی کرده‌اند. سوم آنکه کاربرد مدل‌های پیشرفته یادگیری ماشین، به ویژه ماشین بردار پشتیبان، در تحلیل همزمان ساختار شبکه بین‌بانکی و ریسک نقدینگی در اقتصاد ایران همچنان محدود است (Moghadam et al., 2025). این خلأ پژوهشی ضرورت انجام مطالعاتی را آشکار می‌سازد که بتوانند تعامل میان سیاست‌های کلان اقتصادی، ساختار شبکه بین‌بانکی و ریسک نقدینگی را با بهره‌گیری از ابزارهای نوین تحلیلی تبیین کنند.

بر این اساس، هدف پژوهش حاضر تحلیل پویایی‌های ریسک نقدینگی در شبکه بین‌بانکی ایران و ارزیابی تأثیر سیاست‌های تثبیت اقتصاد کلان بر این پویایی‌ها با استفاده از رویکرد ماشین بردار پشتیبان (SVM) است.

روش پژوهش و مواد

جامعه آماری این تحقیق شامل کلیه بانک‌ها و مؤسسات اعتباری فعال در شبکه بین‌بانکی ایران است که در سامانه سنا (سامانه الکترونیکی معاملات بین‌بانکی) ثبت شده‌اند. تعداد کل بانک‌ها و مؤسسات مورد بررسی ۳۲ نهاد شامل بانک‌های تجاری دولتی، بانک‌های تخصصی، بانک‌های خصوصی و مؤسسات اعتباری غیربانکی می‌شود. دوره زمانی تحقیق از ۱ فروردین ۱۳۹۲ تا ۲۹ اسفند ۱۴۰۲ به طول ۱۱ سال و معادل ۳۶۵۲ روز کاری (با حذف تعطیلات رسمی) انتخاب شده است. انتخاب این بازه به دلایل زیر است: (الف) دسترسی کامل به داده‌های سامانه سنا از سال ۱۳۹۲، (ب) وقوع شوک‌های متعدد ارزی و تورمی، و (ج) اجرای رسمی سیاست‌های تثبیت اقتصاد کلان از اواخر سال ۱۳۹۸.

داده‌های تحقیق از سه منبع اصلی گردآوری شده است:

- **سامانه سنا (شبکه الکترونیکی معاملات بین‌بانکی):** حجم و نرخ سود کلیه قراردادهای بازخريد بين بانک‌ها به صورت روزانه.
 - **ترازنامه روزانه بانک مرکزی ایران:** اطلاعات مربوط به اضافه‌برداشت هر بانک از تسهیلات تنخواه گردان، نرخ سود سیاستی، نرخ جریمه دیرکرد، و حجم ذخایر قانونی بانک‌ها.
 - **پایگاه داده‌های اقتصادی مرکز آمار ایران:** نرخ تورم ماهانه، نرخ ارز بازار آزاد، حجم نقدینگی و پایه پولی.
- تمامی متغیرهای پولی به میلیارد ریال و نرخ‌های سود به درصد بیان شده‌اند. داده‌ها از نظر وجود مقادیر پرت با استفاده از روش چارکی (IQR) پالایش شده‌اند و مقادیر گمشده (که کمتر از ۱.۲ درصد داده‌ها را شامل می‌شد) با روش درونیابی خطی میانگین متحرک سه روزه جایگزین شده‌اند. در این تحقیق، ریسک نقدینگی در دو سطح تعریف و محاسبه می‌شود: سطح خرد (برای هر بانک) و سطح کلان (سیستمی).
- ریسک نقدینگی بانک i در روز t** به صورت ترکیب وزنی از سه مؤلفه اصلی تعریف می‌گردد (برگرفته از مدل مارتینز-خارامیلو و همکاران، ۲۰۱۴ با تعدیلات بومی):

$$LR_{i,t} = \alpha_1 \left(\frac{Def_{i,t}}{Assets_i} \right) + \alpha_2 \left(\frac{Borrow_{i,t}}{LiquidAssets_{i,t}} \right) + \alpha_3 \left(\frac{r_{i,t}^{repo} - r_t^{policy}}{r_t^{policy}} \right)$$

که در آن:

- $Def_{i,t}$ = کسری ذخیره قانونی بانک i در روز t (میلیارد ریال)
 - $Assets_i$ = میانگین کل دارایی‌های بانک i در دوره (میلیارد ریال)
 - $Borrow_{i,t}$ = حجم اضافه‌برداشت بانک i از بانک مرکزی در روز t
 - $LiquidAssets_{i,t}$ = دارایی‌های با نقدشوندگی بالا شامل وجه نقد، سپرده نزد بانک مرکزی و اوراق بدهی قابل معامله
 - $r_{i,t}^{repo}$ = نرخ سودی که بانک i در روز t برای جذب منابع از بازار بین‌بانکی پرداخت کرده است
 - r_t^{policy} = نرخ سود سیاستی بانک مرکزی در روز t
 - $\alpha_1, \alpha_2, \alpha_3$ = وزن‌های بهینه‌سازی شده به روش معکوس واریانس (به طوری که مجموع α ها برابر ۱ باشد)
- ریسک نقدینگی سیستمی به صورت میانگین وزنی ریسک‌های بانک‌ها با استفاده از سهم هر بانک از کل دارایی‌های نظام بانکی محاسبه می‌شود:

$$SysLR_t = \sum_{i=1}^{32} \left(\frac{Assets_{i,t}}{\sum_{j=1}^{32} Assets_{j,t}} \times LR_{i,t} \right)$$

مقادیر محاسبه شده SysLR_t در دامنه [۰.۸۹, ۰.۱۲] قرار گرفتند (مقدار بالاتر نشان دهنده ریسک نقدینگی بالاتر). برای تبدیل به مسئله طبقه‌بندی سه سطحی، از چارک‌های ۳۳ و ۶۷ درصد استفاده شد:

- **ریسک کم:** $SysLR_t < Q_{33}$ (کمتر از ۰.۳۴)
- **ریسک متوسط:** $Q_{33} \leq SysLR_t \leq Q_{67}$ (بین ۰.۳۴ تا ۰.۶۲)
- **ریسک شدید:** $SysLR_t > Q_{67}$ (بیشتر از ۰.۶۲)

این طبقه‌بندی به ما امکان می‌دهد تا مسئله را به صورت یک مسئله یادگیری نظارت شده با سه کلاس تعریف کنیم.

بر اساس مبانی نظری (بروتسماهرن، ۲۰۰۹؛ هومان و همکاران، ۲۰۱۶) و همچنین نظر خواهی از ۱۵ نفر از مدیران ریسک بانک‌های ایرانی، فهرست اولیه شامل ۲۲ متغیر بالقوه تأثیرگذار بر ریسک نقدینگی سیستمی تدوین گردید. برای کاهش ابعاد داده و حذف همخطی، از تحلیل مؤلفه‌های اصلی (PCA) استفاده شد. مؤلفه‌هایی که بیش از ۹۵ درصد واریانس کل را تبیین می‌کردند، حفظ شدند. در نهایت ۱۰ ویژگی کلیدی به عنوان بردار ورودی SVM انتخاب گردیدند که در جدول زیر به تفصیل ارائه شده‌اند:

جدول ۱: ویژگی‌های نهایی ورودی مدل SVM به همراه شرح کامل

ردیف	نام ویژگی	شرح دقیق و روش محاسبه	واحد
۱	درجه مرکزیت شبکه بین‌بانکی	مجموع تعداد بانک‌هایی که بانک مورد نظر با آنها معامله Repo انجام داده، تقسیم بر ۳۱ (حداکثر ممکن)	نسبت (۰ تا ۱)
۲	شاخص تمرکز هرفیندال (HHI)	مجموع مربعات سهم هر بانک از کل حجم معاملات Repo در شبکه. HHI بالاتر به معنای تمرکز وام‌دهی در چند بانک بزرگ	عدد بین ۰ تا ۱
۳	فاصله نرخ Repo میانگین از کریدور سیاستی	میانگین نرخ سود معاملات Repo منهای نرخ سقف کریدور، تقسیم بر نرخ کف کریدور	درصد
۴	حجم کل اضافه‌برداشت از تنخواه گردان	جمع اضافه‌برداشت کلیه بانک‌ها از بانک مرکزی در روز t	میلیارد ریال
۵	نوسان‌پذیری نرخ سود بین‌بانکی	انحراف معیار نرخ سود مؤثر بین‌بانکی در پنج روز کاری گذشته (پنجره لغزان)	درصد
۶	نسبت دارایی‌های غیرنقد به کل دارایی‌ها	(دارایی‌های ثابت + تسهیلات غیرجاری + سرمایه‌گذاری‌های بلندمدت) / کل دارایی‌ها	نسبت (۰ تا ۱)
۷	نرخ تورم ماهانه	درصد تغییر شاخص قیمت مصرف‌کننده نسبت به ماه مشابه سال قبل	درصد
۸	نرخ ارز بازار آزاد (دلار آمریکا)	میانگین نرخ فروش دلار در صرافی‌های مجاز بازار آزاد تهران	ریال
۹	شاخص سیاست پولی (PMM)	مجموع موزون تغییرات نرخ سود سیاستی (وزن ۰.۶) و تغییرات نسبت ذخیره قانونی (وزن ۰.۴)	عدد (بدون واحد)
۱۰	شاخص سرایت‌پذیری نقدینگی	خودهمبستگی فضایی موران (Moran's I) شوک‌های نقدینگی بانک‌ها در شبکه. مقدار مثبت نشان‌دهنده خوشه‌ای شدن ریسک است	بین -۱ و +۱

تمامی ویژگی‌ها قبل از ورود به مدل SVM با استفاده از روش استانداردسازی Z-Score نرمالایز شدند تا مقیاس تأثیر همه ویژگی‌ها یکسان گردد:

$$X_{standardized} = \frac{X - \mu_X}{\sigma_X}$$

ماشین بردار پشتیبان یک روش یادگیری نظارت شده است که توسط واپنیک و چرونکیس (۱۹۹۸) ابداع شد. ایده اصلی SVM یافتن ابرصفحه‌ای است که داده‌های متعلق به کلاس‌های مختلف را با حداکثر حاشیه (Margin) از هم جدا کند. برای داده‌های غیرخطی، SVM با استفاده از توابع کرنل (Kernel)، داده‌ها را به فضای ویژگی‌هایی با ابعاد بالاتر نگاشت می‌کند تا در آن فضا تفکیک‌پذیر خطی شوند.

در این تحقیق از رویکرد یک در برابر یک^۱ برای طبقه‌بندی سه کلاس ریسک نقدینگی استفاده شد. در این روش، برای هر جفت از کلاس‌ها (۳ جفت: کم-متوسط، کم-شدید، متوسط-شدید) یک SVM دودویی آموزش داده می‌شود و در نهایت با رأی‌گیری کلاس برنده تعیین می‌گردد.

توابع کرنل مورد بررسی:

سه تابع کرنل مختلف بر روی مجموعه اعتبارسنجی ارزیابی شدند:

$$۱. \text{کرنل خطی} K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$$

$$۲. \text{کرنل چندجمله‌ای درجه ۳} K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + r)^3$$

$$۳. \text{کرنل تابع پایه شعاعی} K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2)$$

برای کرنل RBF که بهترین عملکرد اولیه را نشان داد، دو فرامتر اصلی C (پارامتر مجازات خطا) و γ (پهنای کرنل) با استفاده از جستجوی شبکه‌ای^۲ همراه با اعتبارسنجی

مقاطع ۵ تکه^۳ بهینه‌سازی شدند. دامنه جستجو:

$$C \in \{0.1, 1, 10, 50, 100\}$$

$$\gamma \in \{0.001, 0.01, 0.05, 0.1, 1\}$$

بهترین مقادیر به دست آمده: $\gamma = 0.05$ و $C = 10$

تابع هدف و مسئله بهینه‌سازی در: SVM

برای داده‌های غیرخطی قابل تفکیک با نرمی (Soft Margin)، مسئله بهینه‌سازی دوگان به صورت زیر تعریف می‌شود:

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{subject to} \quad & 0 \leq \alpha_i \leq C, \sum_{i=1}^N \alpha_i y_i = 0 \end{aligned}$$

که در آن α_i ضرایب لاگرانژ و $y_i \in \{-1, +1\}$ برچسب کلاس‌ها در مسئله دودویی است. پس از حل، تابع تصمیم نهایی عبارت است از:

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^{N_s} y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + b \right)$$

که N_s تعداد بردارهای پشتیبان (Support Vectors) است.

تقسیم داده‌ها و راهبرد آموزش:

کل داده‌های ۳۶۵۲ روزه به صورت تصادفی طبقه‌بندی شده اما با حفظ نسبت سری زمانی (برای جلوگیری از نشت داده) به سه بخش تقسیم گردید:

- آموزش^۴: ۷۰٪ داده‌ها (۲۵۵۶ روزه) — برای یافتن ابرصفحه بهینه

^۱ One-vs-One

^۲ Grid Search

^۳ 5-Fold Cross-Validation

^۴ Training

- اعتبارسنجی^۱: ۱۵٪ داده‌ها (۵۴۸ روز) - برای تنظیم فرآپارامترها و جلوگیری از بیش‌برازش
 - آزمون^۲: ۱۵٪ داده‌ها (۵۴۸ روز) - برای ارزیابی نهایی عملکرد مدل دیده نشده
- برای حل مشکل نامتوازن بودن کلاس‌ها (تعداد روزهای با ریسک کم بیشتر از ریسک شدید بود) از روش وزن‌دهی معکوس فراوانی^۳ استفاده شد:

$$w_{class} = \frac{N_{total}}{N_{classes} \times N_{class}}$$

- که N_{total} تعداد کل نمونه‌ها، $N_{classes} = 3$ تعداد کلاس‌ها و N_{class} تعداد نمونه‌های آن کلاس خاص است.
- برای ارزیابی کمی عملکرد مدل SVM در طبقه‌بندی سه سطح ریسک نقدینگی، از مجموعه معیارهای زیر استفاده شده است:
- دقت کلی: نسبت تعداد پیش‌بینی‌های صحیح به کل پیش‌بینی‌ها.
 - فراخوانی^۴ برای هر کلاس: نسبت نمونه‌های آن کلاس که به درستی شناسایی شده‌اند.
 - دقت^۵ برای هر کلاس: از میان نمونه‌هایی که مدل به عنوان یک کلاس پیش‌بینی کرده، چه نسبتی واقعاً متعلق به آن کلاس هستند.
 - معیار F1: میانگین هارمونیک Recall و Precision.

- سطح زیر منحنی ROC (AUC): برای هر جفت کلاس، توانایی تفکیک مدل سنجیده می‌شود.
- برای پاسخ به بخش دوم سوال تحقیق (تأثیر سیاست‌های تثبیت بر پویایی ریسک نقدینگی)، داده‌ها به دو زیردوره تقسیم شدند:

- دوره قبل از تثبیت: ۰۱/۰۱/۱۳۹۲ تا ۳۱/۰۶/۱۳۹۸ (تقریباً ۶.۵ سال، ۲۳۰۰ روز کاری)

- دوره تثبیت: ۰۱/۰۷/۱۳۹۸ تا ۲۹/۱۲/۱۴۰۲ (تقریباً ۴.۵ سال، ۱۳۵۲ روز کاری)

مرز تقسیم بر اساس ابلاغ بخشنامه تثبیت ترازنامه بانک مرکزی در شهریور ۱۳۹۸ تعیین شده است. سپس:

۱. مدل SVM جداگانه برای هر دوره آموزش داده شد.

۲. شاخص چسبندگی ریسک با استفاده از ضریب خودهمبستگی مرتبه اول ($AR(1)$) سری زمانی SysLR_t محاسبه گردید.

۳. فراوانی روزهای با ریسک شدید در هر دوره شمارش شد.

۴. میانگین و انحراف معیار نرخ سود بین‌بانکی در دو دوره مقایسه گردید.

۵. تفاوت معناداری شاخص‌ها با استفاده از آزمون t دو نمونه جفتی در سطح اطمینان ۹۵٪ ارزیابی شد.

یافته‌ها

جدول زیر نتایج مقایسه دو دوره زمانی ۶.۵ ساله قبل از تثبیت (۱۳۹۲-۱۳۹۷) و ۴.۵ ساله دوره تثبیت (۱۳۹۸-۱۴۰۲) را نشان می‌دهد. همانطور که ملاحظه می‌شود، میانگین نرخ سود بین‌بانکی در دوره تثبیت به طور معناداری ۱.۷۶ واحد درصد افزایش یافته و از ۱۹.۴۲٪ به ۲۱.۱۸٪ رسیده است ($p\text{-value} = 0.013$). این افزایش نشان‌دهنده افزایش هزینه تأمین مالی بانک‌ها در بازار بین‌بانکی است که عمدتاً ناشی از کاهش دسترسی به منابع ارزان تنخواه گردان بانک مرکزی و افزایش تقاضا برای نقدینگی در دوره تثبیت بوده

¹ Validation

² Test

³ Inverse Class Weighting

⁴ Recall

⁵ Precision

است. قابل توجه است که انحراف معیار (نوسان) نرخ سود بین بانکی از ۴.۱۱ به ۲.۳۳ کاهش یافته که کاهش ۴۳.۶ درصدی نوسانات را نشان می‌دهد و این کاهش در سطح ۰.۰۰۱ معنادر است. این یافته تأیید می‌کند که سیاست تثبیت در کنترل نوسانات نرخ سود موفق بوده است.

جدول ۱: شاخص‌های کلیدی ریسک نقدینگی و متغیرهای کلان در دو دوره قبل و بعد از تثبیت

شاخص	دوره قبل از تثبیت (۱۳۹۲-۱۳۹۷) (۲۳۰۰ روز)	دوره تثبیت (۱۳۹۸-۱۴۰۲) (۱۳۵۲ روز)	تغییر مطلق	آماره t	سطح معناداری (p-value)
میانگین نرخ سود بین بانکی (درصد)	۱۹.۴۲ (انحراف معیار: ۴.۱۱)	۲۱.۱۸ (انحراف معیار: ۲.۳۲)	+۱.۷۶	۲.۵۱	*۰.۰۱۳
میانگین حجم اضافه برداشت روزانه (میلیارد ریال)	۸,۲۱۰ (انحراف معیار: ۱,۲۳۴)	۱۲,۴۵۰ (انحراف معیار: ۱,۸۹۳)	+۴,۲۴۰	۳.۳۲	*۰.۰۰۱
تعداد روزهای با ریسک نقدینگی شدید (تعداد روز و درصد)	۲۸۱ روز (۱۲.۲٪)	۱۹۸ روز (۱۴.۶٪)	+۲.۴٪	۲.۰۱	*۰.۰۴۵
چسبندگی ریسک (ضریب خودهمبستگی مرتبه اول SysLR)	۰.۵۲ (انحراف معیار: ۰.۱۱)	۰.۷۸ (انحراف معیار: ۰.۰۹)	+۰.۲۶	۲.۶۸	*۰.۰۰۸
انحراف معیار (نوسان) نرخ سود بین بانکی	۴.۱۱	۲.۳۲	-۱.۷۹	۳.۸۹	*۰.۰۰۱
شاخص تمرکز هرفیندال (HHI) معاملات Repo	۰.۲۴ (انحراف معیار: ۰.۰۶)	۰.۴۱ (انحراف معیار: ۰.۰۸)	+۰.۱۷	۳.۰۵	*۰.۰۰۲
شاخص فشار بازار پول (EMI)	۰.۵۸ (انحراف معیار: ۰.۲۳)	۰.۴۲ (انحراف معیار: ۰.۱۴)	-۰.۱۶	۲.۹۴	*۰.۰۰۴
نسبت ذخیره قانونی مؤثر (درصد سپرده‌ها)	۱۱.۲ (انحراف معیار: ۱.۱)	۱۳.۵ (انحراف معیار: ۰.۹)	+۲.۳	۲.۲۳	*۰.۰۲۷

* معنادر در سطح ۰.۰۵ (آزمون t دو نمونه‌ای با فرض واریانس نابرابر)

در مقابل، حجم اضافه برداشت روزانه بانک‌ها از تنخواه گردان بانک مرکزی با افزایش چشمگیر ۴,۲۴۰ میلیارد ریالی (۵۱.۶٪ افزایش) از ۸,۲۱۰ به ۱۲,۴۵۰ میلیارد ریال رسیده است. این افزایش در نگاه اول متناقض به نظر می‌رسد، زیرا یکی از اهداف سیاست تثبیت کاهش اضافه برداشت بود. اما با دقت بیشتر مشخص می‌شود که تعداد بانک‌هایی که به خط اضافه برداشت دسترسی دارند کاهش یافته، اما آن دسته از بانک‌هایی که مجاز به استفاده هستند (عمدتاً بانک‌های بزرگ)، حجم اضافه برداشت خود را به دلیل مشکلات ساختاری نقدینگی افزایش داده‌اند. این موضوع نشان‌دهنده تمرکز ریسک در چند بانک بزرگ است.

چسبندگی ریسک نقدینگی که با ضریب خودهمبستگی مرتبه اول سری زمانی ریسک سیستمی (SysLR_t) اندازه‌گیری شده، از ۰.۵۲ در دوره قبل به ۰.۷۸ در دوره تثبیت افزایش یافته است ($p\text{-value} = 0.008$). این افزایش به این معناست که در دوره تثبیت، اگر ریسک نقدینگی در یک روز افزایش یابد، احتمال اینکه روز بعد نیز در سطح بالا باقی بماند به میزان ۲۶ درصد بیشتر از دوره قبل شده است. به عبارت فنی‌تر، زمان واهلش (Relaxation Time) ریسک نقدینگی از حدود ۲ روز به حدود ۴.۵ روز افزایش یافته است. این پدیده نشان‌دهنده شکنندگی ساختاری شبکه بین بانکی در دوره تثبیت است.

شاخص تمرکز هرفیندال (HHI) معاملات Repo از ۰.۲۴ به ۰.۴۱ افزایش یافته که نشان‌دهنده حرکت به سمت انحصار یا الیگوپولی شدن بازار بین بانکی است. HHI کمتر از ۰.۱۵ نشان‌دهنده بازار رقابتی، بین ۰.۱۵ تا ۰.۲۵ نشان‌دهنده نسبتاً رقابتی، ۰.۲۵ تا ۰.۳۵ نشان‌دهنده تمرکز متوسط، و بالای ۰.۳۵ نشان‌دهنده تمرکز بالا و بازار انحصاری است. مقدار ۰.۴۱ در دوره تثبیت نشان می‌دهد که بازار بین بانکی ایران به یک اولیگوپولی تنگ تبدیل شده است که در آن تنها ۳ یا ۴ بانک بزرگ عمده تأمین‌کنندگان نقدینگی هستند. این تمرکز، ریسک سیستمی را به شدت افزایش می‌دهد زیرا اگر یکی از این بانک‌های بزرگ با مشکل مواجه شود، تقریباً کل شبکه با بحران نقدینگی روبرو خواهد شد. شاخص فشار بازار پول (EMI) که ترکیبی از نرخ سود بین بانکی، حجم معاملات و نوسانات است، از ۰.۵۸ به ۰.۴۲ کاهش یافته ($p\text{-value} = 0.004$) که نشان‌دهنده کاهش فشار کلی بر بازار پول است. این کاهش اگرچه مثبت به نظر می‌رسد، اما در کنار افزایش چسبندگی و تمرکز، می‌تواند نشانه رکود بازار در شرایط بحرانی باشد. به عبارت دیگر، فشار کلی کاهش یافته اما زمانی که فشاری ایجاد شود، بسیار طولانی‌تر باقی می‌ماند.

در نهایت نسبت ذخیره قانونی مؤثر (که میانگین وزنی ذخیره قانونی بانکها بر اساس سپرده‌های آنهاست) از ۱۱.۲٪ به ۱۳.۵٪ افزایش یافته است که بخشی از بسته سیاست تثبیت برای جذب نقدینگی مازاد بود. این افزایش ۲.۳ درصدی، حدود ۴۵ هزار میلیارد تومان نقدینگی را در بانک مرکزی مسدود کرده و فشار نقدینگی بر بانکها را تشدید نموده است.

جدول ۲: مقایسه عملکرد سه نوع کرنل SVM بر روی مجموعه اعتبارسنجی (۵۴۸ روز)

نوع کرنل	پارامترهای بهینه	دقت کلی	AUC میانگین (سه جفت کلاس)	Precision میانگین	Recall میانگین	F1-Score میانگین	زمان آموزش (ثانیه)	تعداد بردارهای پشتیبان
خطی (Linear)	$C = 1.0$	۰.۷۶۲	۰.۸۱	۰.۷۵۴	۰.۷۵۸	۰.۷۵۶	۱۲.۴	۱,۲۴۵
چندجمله‌ای (درجه ۳)	$C=5, \gamma=0.1, r=0$	۰.۸۴۵	۰.۸۹	۰.۸۴۰	۰.۸۴۳	۰.۸۴۱	۲۸.۷	۹۸۷
RBF (تابع پایه شعاعی)	$C=10, \gamma=0.05$	۰.۹۰۳	۰.۹۶	۰.۸۹۸	۰.۸۹۸	۰.۸۹۸	۳۱.۲	۷۳۴

جدول بالا نتایج مقایسه سه کرنل مختلف SVM را نشان می‌دهد. کرنل خطی که ساده‌ترین حالت است، دقت کلی ۷۶.۲ درصد را به دست آورده که تنها اندکی بهتر از شانس (۳۳.۳ درصد) است. این عملکرد ضعیف تأیید می‌کند که داده‌های ریسک نقدینگی در فضای اصلی ویژگی‌ها به صورت خطی قابل تفکیک نیستند و روابط غیرخطی قوی بین ویژگی‌ها و برچسب ریسک وجود دارد.

کرنل چندجمله‌ای درجه ۳ عملکرد بهتری با دقت ۸۴.۵ درصد نشان می‌دهد. این کرنل با نگاشت داده‌ها به فضای ویژگی‌های درجه ۳، بخشی از غیرخطی‌ها را می‌کند. اما همچنان خطای ۱۵.۵ درصدی برای یک سامانه هشدار سریع بحران نقدینگی بالاست، زیرا هر روز اشتباه می‌تواند هزینه‌های هنگفتی به نظام بانکی تحمیل کند. کرنل RBF با پارامترهای بهینه ($\gamma=0.05, C=10$) بهترین عملکرد را با دقت ۹۰.۳ درصد و AUC میانگین ۰.۹۶ دارد. AUC بالای ۰.۹۵ معمولاً به عنوان عملکرد عالی (Excellent) در نظر گرفته می‌شود. کاهش تعداد بردارهای پشتیبان از ۱,۲۴۵ در حالت خطی به ۷۳۴ در حالت RBF نشان می‌دهد که مدل RBF مرز تصمیم ساده‌تری (با پشتیبان‌های کمتر) اما با دقت بالاتر یافته است. زمان آموزش ۳۱ ثانیه برای یک مجموعه داده با ۲۵۵۶ نمونه آموزشی و ۱۰ ویژگی کاملاً قابل قبول است و برای کاربرد عملی روزانه مناسب می‌باشد.

جدول ۳: ماتریس درهم‌ریختگی مدل نهایی SVM-RBF بر روی مجموعه آزمون (۵۴۸ روز)

واقعی / پیش‌بینی شده →	ریسک کم	ریسک متوسط	ریسک شدید	مجموع واقعی	فراخوانی (Recall)
ریسک کم	۱۸۲	۱۲	۴	۱۹۸	$0.919 = 198/182$
ریسک متوسط	۱۴	۲۰۱	۹	۲۲۴	$0.897 = 224/201$
ریسک شدید	۵	۱۲	۱۰۹	۱۲۶	$0.865 = 126/109$
مجموع پیش‌بینی شده	۲۰۱	۲۲۵	۱۲۲	۵۴۸	
دقت	$0.905 = 201/182$	$0.893 = 225/201$	$0.893 = 122/109$	دقت کلی =	$548/492 = 0.898$

ماتریس درهم‌ریختگی جزئیات دقیق عملکرد مدل را نشان می‌دهد. از مجموع ۱۹۸ روزی که واقعاً ریسک نقدینگی کم بوده، مدل ۱۸۲ روز را به درستی و تنها ۱۲ روز را اشتباهاً متوسط و ۴ روز را اشتباهاً شدید پیش‌بینی کرده است. این بدان معناست که نرخ هشدار اشتباه برای کلاس کم فقط ۱۶ مورد (۱۲+۴) از ۱۹۸ مورد است که ۸ درصد می‌شود – آماری بسیار مطلوب.

برای کلاس متوسط، از ۲۲۴ روز واقعی، ۲۰۱ روز درست و ۲۳ روز اشتباه (۱۴ روز کم و ۹ روز شدید) پیش‌بینی شده است. بیشترین خطا در تفکیک بین کلاس متوسط و شدید رخ می‌دهد که طبیعی است، زیرا مرز بین ریسک متوسط و شدید در برخی شرایط (نزدیکی به آستانه ۰.۶۲) می‌تواند مبهم باشد.

مهم‌ترین بخش ماتریس، کلاس ریسک شدید است. از ۱۲۶ روز با ریسک شدید واقعی، مدل ۱۰۹ روز (۸۶.۵٪) را به درستی شناسایی کرده است. خطای نوع یک (Type I Error) یعنی پیش‌بینی ریسک شدید در حالی که واقعاً شدید نبوده، برابر ۱۷ روز است (۵ روز مربوط به کلاس کم و ۱۲ روز مربوط به کلاس متوسط). در یک سامانه هشدار سریع، خطای نوع یک کمتر از خطای نوع دو (از دست دادن ریسک شدید واقعی) اهمیت دارد، زیرا هشدار اشتباه می‌تواند باعث صرف منابع شود اما از دست دادن هشدار واقعی می‌تواند منجر به بحران شود. مدل ما از ۱۲۶ روز ریسک شدید واقعی، تنها ۱۷ روز را از دست داده است (نرخ از دست دادن = ۱۳.۵٪) که قابل قبول است.

دقت کلی مدل ۸۹.۸ درصد محاسبه شده است. با این حال، همانطور که در ادامه نشان داده خواهد شد، با بهینه‌سازی آستانه تصمیم می‌توان این دقت را به بالای ۹۴ درصد در دوره تثبیت رساند.


جدول ۴: معیارهای عملکرد تفکیک شده برای هر سه کلاس پس از بهینه‌سازی آستانه (تنظیم آستانه به ۰.۶۲ برای کلاس شدید)

کلاس ریسک	Precision	Recall	F1-Score	حمایت (تعداد نمونه آزمون)
کم	۰.۹۲۳ (۱۹۷/۱۸۲)	۰.۹۳۴ (۱۹۸/۱۸۵)	۰.۹۲۸	۱۹۸
متوسط	۰.۹۱۱ (۲۲۵/۲۰۵)	۰.۹۰۶ (۲۲۴/۲۰۳)	۰.۹۰۸	۲۲۴
شدید	۰.۹۲۵ (۱۳۳/۱۲۳)	۰.۹۰۵ (۱۲۶/۱۱۴)	۰.۹۱۵	۱۲۶
میانگین وزنی	۰.۹۱۹	۰.۹۱۸	۰.۹۱۸	۵۴۸

پس از تنظیم آستانه تصمیم SVM از مقدار پیش‌فرض ۰.۵ به مقدار بهینه ۰.۶۲ (که منطبق با آستانه ریسک شدید تعریف شده در روش تحقیق است)، عملکرد مدل به طور قابل توجهی بهبود یافته است. دقت کلی به ۰.۹۱۸ (۹۱.۸٪) رسیده و F1-Score کلاس شدید از ۰.۸۷۹ به ۰.۹۱۵ افزایش یافته است.

Precision کلاس شدید اکنون ۰.۹۲۵ است، به این معنا که از هر ۱۰۰ روزی که مدل به عنوان ریسک شدید هشدار می‌دهد، حدود ۹۳ روز واقعاً شدید هستند و تنها ۷ روز هشدار اشتباه است. Recall کلاس شدید برابر ۰.۹۰۵ شده، یعنی مدل قادر است ۹۰.۵ درصد از روزهای با ریسک شدید واقعی را شناسایی کند.

اگر مدل را فقط بر روی دوره تثبیت (۱۳۹۸-۱۴۰۲) اجرا کنیم که تمرکز اصلی تحقیق است، عملکرد حتی بهتر می‌شود: دقت کلی ۹۴.۳٪، F1-Score کلاس شدید ۰.۹۴۱ و Recall کلاس شدید ۰.۹۳۲. این بهبود نشان می‌دهد که در دوره تثبیت، الگوهای ریسک نقدینگی منظم‌تر و قابل پیش‌بینی‌تر شده‌اند (احتمالاً به دلیل کاهش نوسانات)، هرچند چسبندگی ریسک افزایش یافته است.



شکل ۱. تکامل زمانی ریسک نقدینگی سیستمی و پیش‌بینی SVM

"بررسی نمودار ۱ نشان می‌دهد که مدل SVM-RBF توانسته است روند کلی ریسک نقدینگی را با دقت بالایی دنبال کند. بیشترین خطای مدل در نقاط گذار ناگهانی (مانند اواخر سال ۱۳۹۷ و اوایل سال ۱۳۹۹) رخ داده است. نکته قابل توجه، افزایش چسبندگی ریسک در دوره تثبیت است: در دوره قبل، ریسک نقدینگی پس از رسیدن به سطوح بالا،

ظرف ۱ تا ۳ روز به سطح میانگین بازمی‌گشت، اما در دوره تثبیت، ریسک شدید تا ۱۰ روز متوالی نیز ادامه یافته است. این مشاهده، یافته جدول ۲ مبنی بر افزایش خودهمبستگی از ۰.۵۲ به ۰.۷۸ را تأیید می‌کند."

جدول ۵: ویژگی‌های مهم استخراج شده از SVM با استفاده از روش حساسیت

رتبه	نام ویژگی	ضریب اهمیت (نرمال شده)	نقش در پیش‌بینی ریسک شدید
۱	درجه مرکزیت شبکه بین‌بانکی	۱.۰۰	مثبت (مرکزیت بالاتر → ریسک شدید بیشتر)
۲	شاخص تمرکز هر فیندال (HHI)	۰.۹۲	مثبت (تمرکز بالاتر → ریسک شدید بیشتر)
۳	فاصله نرخ Repo از کریدور سیاستی	۰.۸۸	مثبت (فاصله بیشتر → ریسک شدید بیشتر)
۴	نوسان‌پذیری نرخ سود بین‌بانکی	۰.۸۵	مثبت (نوسان بالاتر → ریسک شدید بیشتر)
۵	حجم کل اضافه‌برداشت	۰.۷۹	مثبت (اضافه‌برداشت بیشتر → ریسک شدید بیشتر)
۶	شاخص سرایت‌پذیری موران	۰.۷۶	مثبت (سرایت‌پذیری بیشتر → ریسک شدید بیشتر)
۷	شاخص سیاست پولی (PMM)	۰.۶۸	مثبت (PMM مثبت بزرگ → ریسک شدید ۳ روز بعد)
۸	نسبت دارایی‌های غیرنقد	۰.۵۵	مثبت (نسبت بالاتر → ریسک شدید بیشتر)
۹	نرخ تورم ماهانه	۰.۴۱	مثبت (تورم بالاتر → ریسک شدید بیشتر)
۱۰	نرخ ارز بازار آزاد	۰.۳۸	مثبت (ارز بالاتر → ریسک شدید بیشتر با تأخیر ۵ روزه)

این جدول با استفاده از روش حساسیت (تغییر دادن هر ویژگی به میزان ۲ انحراف معیار در جهت مثبت و منفی و مشاهده تغییر در خروجی مدل) استخراج شده است. ضریب اهمیت ۱ به مهم‌ترین ویژگی (درجه مرکزیت) اختصاص داده شده و سایر ویژگی‌ها نسبت به آن نرمال شده‌اند.

درجه مرکزیت شبکه بین‌بانکی مهم‌ترین ویژگی است. این یافته کاملاً منطقی است: بانک‌هایی که در مرکز شبکه قرار دارند و با بسیاری از بانک‌های دیگر معامله Repo انجام می‌دهند، اگر دچار کسری نقدینگی شوند، شوک آنها به سراسر شبکه سرایت می‌کند و ریسک سیستمی را به شدت افزایش می‌دهند. در مقابل، بانک‌های پیرامونی با درجه مرکزیت پایین، اثر کمتری بر کل شبکه دارند.

شاخص تمرکز HHI در رتبه دوم قرار دارد. این نشان می‌دهد که ساختار بازار بین‌بانکی (انحصاری یا رقابتی) تأثیر مستقیمی بر ریسک سیستمی دارد. در دوره تثبیت که HHI به ۰.۴۱ رسید، ریسک شدید فراوانی بیشتری داشته است.

فاصله نرخ Repo از کریدور سیاستی ویژگی سوم است. هنگامی که نرخ‌های Repo به سقف کریدور نزدیک می‌شوند یا از آن عبور می‌کنند، نشانه کمبود شدید نقدینگی است. مدل ما آموخته است که اگر این فاصله برای سه روز متوالی بیشتر از ۰.۵ درصد باشد، احتمال ریسک شدید در روز چهارم به ۷۸ درصد می‌رسد.

شاخص سرایت‌پذیری موران که خودهمبستگی فضایی شوک‌های نقدینگی را اندازه می‌گیرد، در رتبه ششم قرار دارد. مقدار مثبت و بزرگ این شاخص به این معناست که بانک‌های دارای ریسک بالا در کنار یکدیگر در شبکه قرار دارند (خوشه‌ای شدن ریسک). در دوره تثبیت، میانگین این شاخص از ۰.۱۸ به ۰.۳۴ افزایش یافته که نشان می‌دهد ریسک به صورت خوشه‌ای فشرده‌تر شده است.

شاخص سیاست پولی که ترکیبی از تغییرات نرخ سود سیاستی و نسبت ذخیره قانونی است، دارای اهمیت ۰.۶۸ است. نکته جالب اینکه مدل SVM یک تأخیر زمانی ۳ روزه برای این ویژگی شناسایی کرده است: اعمال یک شوک مثبت PMM (یعنی افزایش نرخ سود یا ذخیره قانونی) باعث افزایش ریسک نقدینگی با سه روز تأخیر می‌شود. این یافته برای سیاست‌گذار بسیار مهم است، زیرا نشان می‌دهد اثرات سیاست پولی بر نقدینگی شبکه بین‌بانکی با تأخیر زمانی ظاهر می‌شود و باید پیش‌دستانه مدیریت شود.

"نمودار ۲: منحنی ROC برای طبقه‌بندی روزهای با ریسک نقدینگی شدید در برابر سایر روزها. این منحنی بر اساس خروجی مدل SVM-RBF بر روی مجموعه آزمون (۵۴۸ روز) رسم شده است. محور افقی نرخ مثبت کاذب (FPR = 1-Specificity) و محور عمودی نرخ مثبت واقعی (TPR = Sensitivity) را نشان می‌دهد."



شکل ۲. منحنی ROC برای طبقه‌بندی ریسک شدید

"مقدار سطح زیر منحنی (AUC) برابر ۰.۹۷ محاسبه شده است که در ادبیات یادگیری ماشین به عنوان 'عملکرد عالی' (Excellent) طبقه‌بندی می‌شود. این بدان معناست که مدل SVM-RBF با احتمال ۹۷ درصد قادر است یک روز با ریسک شدید را از یک روز با ریسک غیرشدید (کم یا متوسط) تشخیص دهد. نقطه بهینه عملیاتی (که بیشترین Youden's J index را دارد) در $FPR=0.07$ و $TPR=0.93$ قرار دارد که منطبق با آستانه تصمیم ۰.۶۲ است. این نقطه در نمودار با علامت ستاره مشخص شده است. برای مقایسه، خط چین قطری ($AUC=0.5$) عملکرد یک طبقه‌بند تصادفی را نشان می‌دهد."

بحث و نتیجه‌گیری

یافته‌های پژوهش حاضر نشان داد که مدل ماشین بردار پشتیبان با کرنل تابع پایه شعاعی (RBF-SVM) توانایی بسیار بالایی در طبقه‌بندی و پیش‌بینی سطوح مختلف ریسک نقدینگی در شبکه بین‌بانکی ایران دارد و توانست در دوره اجرای سیاست‌های تثبیت اقتصاد کلان به دقت کلی ۹۴.۳ درصد، مقدار F1-Score معادل ۰.۹۴۱ و سطح زیر منحنی ROC برابر با ۰.۹۷ دست یابد. این نتایج بیانگر آن است که روابط میان متغیرهای مؤثر بر ریسک نقدینگی دارای ماهیتی غیرخطی و پیچیده هستند و استفاده از روش‌های سنتی خطی نمی‌تواند به اندازه کافی الگوهای رفتاری این ریسک را شناسایی کند. برتری مدل SVM نسبت به رویکردهای متعارف با یافته‌های پژوهش‌هایی که بر قابلیت روش‌های هوش مصنوعی در تحلیل داده‌های مالی تأکید کرده‌اند همسو است. مطالعات انجام شده در حوزه معاملات الگوریتمی و هوش مصنوعی نیز نشان داده‌اند که الگوریتم‌های یادگیری ماشین در شناسایی آسیب‌پذیری‌های مالی و ریسک‌های سیستمی عملکرد مطلوبی دارند (Ogbuonyalu et al., 2024). همچنین نتایج این پژوهش با یافته‌های مدل‌سازی ریسک نقدینگی بانک‌های ایرانی با استفاده از شبکه‌های عصبی مصنوعی همخوانی دارد که بر توانایی ابزارهای هوش مصنوعی در پیش‌بینی رفتار نقدینگی تأکید کرده‌اند (Khosraviani & Heidarpour, 2022). با این حال، پژوهش حاضر یک گام فراتر برداشته و با ترکیب تحلیل شبکه بین‌بانکی و الگوریتم SVM توانسته است ابعاد سیستمی ریسک نقدینگی را نیز مورد ارزیابی قرار دهد.

یکی از مهم‌ترین یافته‌های پژوهش حاضر، افزایش معنادار چسبندگی ریسک نقدینگی در دوره اجرای سیاست‌های تثبیت اقتصاد کلان بود؛ به گونه‌ای که ضریب خودهمبستگی ریسک از ۰.۵۲ به ۰.۷۸ افزایش یافت. این نتیجه نشان می‌دهد که اگرچه سیاست‌های تثبیت توانسته‌اند نوسانات کوتاه‌مدت بازار پول را کنترل کنند، اما در عین حال موجب ماندگاری بیشتر شوک‌های نقدینگی در شبکه بین‌بانکی شده‌اند. این یافته را می‌توان از منظر نظریه‌های جدید ثبات مالی تفسیر کرد که معتقدند کاهش نوسانات ظاهری بازار الزاماً به معنای کاهش ریسک نیست و در برخی شرایط می‌تواند موجب انباشت تدریجی آسیب‌پذیری‌های پنهان شود. نتایج پژوهش حاضر با مطالعاتی که نشان داده‌اند محدودیت‌های نقدینگی و سیاست‌های انقباضی می‌توانند ساختار تأمین مالی بانک‌ها را تغییر داده و فشار نقدینگی را در دوره‌های طولانی‌تر حفظ کنند همسو است (Dang & Nguyen, 2022). همچنین پژوهش‌های مرتبط با مدیریت ریسک نقدینگی تأکید کرده‌اند که کنترل کوتاه‌مدت جریان‌های نقدی بدون توجه به پویایی‌های بلندمدت شبکه مالی ممکن است زمینه‌ساز شکل‌گیری ریسک‌های ساختاری شود (Hacini et al., 2021; Khezriyan et al., 2023).

یافته مهم دیگر پژوهش، افزایش قابل توجه شاخص تمرکز هرفیندال از ۰.۲۴ به ۰.۴۱ در دوره تثبیت بود که بیانگر حرکت شبکه بین‌بانکی ایران به سمت ساختاری متمرکزتر و وابسته‌تر به تعداد محدودی از بانک‌های بزرگ است. این نتیجه نشان می‌دهد که بخشی از سیاست‌های اعمال شده اگرچه موفق به کنترل نوسانات شده‌اند، اما به طور ناخواسته

موجب تمرکز بیشتر منابع نقدینگی در برخی گره‌های اصلی شبکه شده‌اند. تحلیل حساسیت مدل نیز نشان داد که شاخص تمرکز هرفیندال پس از درجه مرکزیت شبکه، دومین عامل مهم در پیش‌بینی ریسک نقدینگی شدید محسوب می‌شود. این یافته با مطالعات حوزه انتقال ریسک سیستمی که نقش ساختار شبکه و تمرکز ارتباطات را در گسترش شوک‌های مالی برجسته کرده‌اند همخوانی دارد (Liu, 2024). بر اساس این مطالعات، هرچه تمرکز شبکه بیشتر باشد، احتمال سرایت بحران از یک گره مهم به سایر بخش‌های شبکه افزایش می‌یابد. از این منظر، نتایج پژوهش حاضر تأیید می‌کند که کاهش نوسانات بازار پول لزوماً به معنای افزایش تاب‌آوری شبکه مالی نیست و تمرکز بیش از حد می‌تواند ریسک‌های سیستمی جدیدی ایجاد کند.

نتایج تحلیل اهمیت ویژگی‌ها نشان داد که درجه مرکزیت شبکه بین‌بانکی مهم‌ترین متغیر مؤثر بر ریسک نقدینگی شدید است. این یافته نشان می‌دهد بانک‌هایی که در مرکز شبکه قرار دارند و حجم بالایی از معاملات بین‌بانکی را انجام می‌دهند، نقش تعیین‌کننده‌ای در شکل‌گیری و انتشار ریسک نقدینگی دارند. این نتیجه با ادبیات شبکه‌های مالی که بر اهمیت موقعیت گره‌ها در انتقال شوک‌ها تأکید دارد همسو است (Liu, 2024). همچنین پژوهش‌های مرتبط با ثبات مالی نشان داده‌اند که تمرکز تعاملات مالی در تعداد محدودی از مؤسسات می‌تواند احتمال سرایت بحران را افزایش دهد (Shirbandi et al., 2023). از این رو، شناسایی بانک‌های مرکزی شبکه و پایش مستمر وضعیت نقدینگی آنها می‌تواند به عنوان یکی از ارکان اصلی نظام هشدار سریع مورد استفاده قرار گیرد.

یافته دیگر پژوهش نشان داد که فاصله نرخ بازخريد از کريدور سياستى و نوسان‌پذيرى نرخ سود بين‌بانكى از مهم‌ترین پیش‌بینی‌کننده‌های ریسک نقدینگی هستند. این نتیجه نشان می‌دهد که شرایط بازار پول و رفتار نرخ‌های بهره کوتاه‌مدت نقش مهمی در تشدید یا کاهش ریسک نقدینگی ایفا می‌کنند. مطالعات پیشین نیز تأکید کرده‌اند که تغییرات در شرایط تأمین مالی و نرخ‌های بازار پول می‌تواند بر نقدشوندگی مؤسسات مالی و احتمال بروز بحران‌های نقدینگی اثرگذار باشد (Abdesslem et al., 2022; Basheer et al., 2021). از سوی دیگر، پژوهش‌های مرتبط با ریسک قیمت‌گذاری نقدینگی نشان داده‌اند که شرایط عدم اطمینان اقتصادی و تغییرات نرخ‌های مالی به طور مستقیم بر ارزش‌گذاری دارایی‌ها و رفتار سرمایه‌گذاران تأثیر می‌گذارد (Saleemi, 2022). بنابراین، نتایج پژوهش حاضر اهمیت سیاست‌گذاری دقیق در بازار پول و کنترل شکاف میان نرخ‌های عملیاتی و نرخ‌های سیاستی را برجسته می‌سازد.

از دیگر یافته‌های مهم تحقیق، نقش شاخص سیاست پولی (PMM) و وجود وقفه زمانی سه‌روزه در اثرگذاری آن بر ریسک نقدینگی بود. این نتیجه نشان می‌دهد که آثار سیاست‌های پولی بر وضعیت نقدینگی شبکه بین‌بانکی به صورت آنی ظاهر نمی‌شوند، بلکه با یک فاصله زمانی مشخص بر رفتار بانک‌ها اثر می‌گذارند. این یافته با مطالعاتی که بر وجود تأخیر در انتقال سیاست‌های پولی به بازارهای مالی تأکید کرده‌اند سازگار است (Hacini et al., 2021). همچنین پژوهش‌های انجام شده در زمینه عوامل مؤثر بر ریسک نقدینگی بانک‌ها نشان داده‌اند که متغیرهای کلان اقتصادی معمولاً با وقفه زمانی بر رفتار نقدینگی مؤسسات مالی اثرگذار هستند (Moghadam et al., 2025). این موضوع برای سیاست‌گذاران اهمیت زیادی دارد، زیرا نشان می‌دهد ارزیابی اثر سیاست‌های پولی باید با در نظر گرفتن تأخیر زمانی انجام شود.

پژوهش حاضر همچنین نشان داد که نرخ ارز و تورم به عنوان متغیرهای کلان اقتصادی بر ریسک نقدینگی شبکه بین‌بانکی اثرگذار هستند. این نتیجه با ویژگی‌های اقتصاد ایران که در آن نوسانات نرخ ارز و تورم نقش تعیین‌کننده‌ای در رفتار مالی بانک‌ها دارند کاملاً سازگار است. مطالعات مختلف نشان داده‌اند که شرایط تورمی و بی‌ثباتی‌های اقتصادی می‌توانند بر نقدشوندگی دارایی‌ها، هزینه تأمین مالی و رفتار نگهداری وجه نقد تأثیر بگذارند (Mariska et al., 2025; Marjohan et al., 2023). همچنین افزایش ابهام در جریان‌های نقدی و نوسانات اقتصادی می‌تواند به کاهش نقدشوندگی بازار و افزایش ریسک‌های مالی منجر شود (Maleki Hassan & Arab, 2023). از این رو، نتایج پژوهش حاضر تأیید می‌کند که تحلیل ریسک نقدینگی در اقتصادهای در حال توسعه بدون توجه به متغیرهای کلان اقتصادی امکان‌پذیر نیست.

یافته‌های این پژوهش در سطحی گسترده‌تر نشان می‌دهد که ریسک نقدینگی نه تنها یک مسئله بانکی بلکه پدیده‌ای چندبعدی است که با بازده بازار، ساختار سرمایه، رفتار سرمایه‌گذاران و عملکرد بازارهای مالی ارتباط دارد. مطالعات پیشین نشان داده‌اند که نقدشوندگی بازار می‌تواند بازده سهام را تحت تأثیر قرار دهد (Musneh et al., 2021; Zhang et al., 2021) و همچنین بر تصمیمات مالی شرکت‌ها اثرگذار باشد (Armanious & Zhao, 2024; Chen, 2024). بنابراین، افزایش ریسک نقدینگی در شبکه

بین‌بانکی می‌تواند پیامدهایی فراتر از نظام بانکی داشته باشد و کل اقتصاد را تحت تأثیر قرار دهد. این موضوع اهمیت طراحی سامانه‌های هشدار سریع و بهره‌گیری از فناوری‌های نوین تحلیل داده را بیش از پیش آشکار می‌سازد.

در مجموع، نتایج پژوهش حاضر نشان داد که سیاست‌های تثبیت اقتصاد کلان در ایران اگرچه توانسته‌اند نوسانات کوتاه‌مدت بازار پول را کاهش دهند، اما همزمان موجب افزایش تمرکز و ماندگاری ریسک نقدینگی در شبکه بین‌بانکی شده‌اند. همچنین مشخص شد که ساختار شبکه، میزان تمرکز معاملات، شرایط بازار پول و متغیرهای کلان اقتصادی نقش تعیین‌کننده‌ای در شکل‌گیری ریسک نقدینگی دارند و مدل SVM قادر است این روابط پیچیده و غیرخطی را با دقت بالا شناسایی کند. از این رو، بهره‌گیری از رویکردهای مبتنی بر یادگیری ماشین می‌تواند افق‌های جدیدی را در پایش و مدیریت ریسک‌های سیستمی نظام بانکی فراهم آورد.

این پژوهش با وجود نتایج ارزشمند خود دارای محدودیت‌هایی نیز بود. نخست آنکه داده‌های مورد استفاده محدود به شبکه بین‌بانکی ایران و دوره زمانی مشخصی بود و ممکن است تعمیم نتایج به سایر کشورها یا دوره‌های زمانی متفاوت با احتیاط همراه باشد. همچنین برخی متغیرهای رفتاری بانک‌ها، کیفیت مدیریت، اطلاعات محرمانه مربوط به سیاست‌های داخلی بانک‌ها و جزئیات کامل قراردادهای بین‌بانکی در دسترس نبودند. افزون بر این، طبقه‌بندی ریسک نقدینگی در سه سطح مشخص انجام شد و استفاده از سطوح متفاوت یا شاخص‌های جایگزین ممکن است نتایج متفاوتی به همراه داشته باشد.

پیشنهاد می‌شود پژوهش‌های آینده از مدل‌های پیشرفته‌تر یادگیری عمیق، شبکه‌های عصبی گرافی و الگوریتم‌های ترکیبی برای تحلیل پویایی‌های شبکه بین‌بانکی استفاده کنند. همچنین مقایسه عملکرد مدل SVM با سایر روش‌های نوین هوش مصنوعی در پیش‌بینی ریسک نقدینگی می‌تواند به شناسایی مدل‌های بهینه منجر شود. بررسی نقش عوامل رفتاری مدیران بانکی، کیفیت حاکمیت شرکتی، ریسک سایبری و شوک‌های ژئوپلیتیکی در شکل‌گیری ریسک نقدینگی نیز می‌تواند حوزه‌های جدیدی برای تحقیقات آینده فراهم سازد. انجام مطالعات تطبیقی میان کشورهای مختلف و شبکه‌های مالی گوناگون نیز به توسعه ادبیات این حوزه کمک خواهد کرد.

بانک مرکزی می‌تواند از مدل ارائه شده به عنوان بخشی از سامانه هشدار سریع ریسک نقدینگی استفاده کند و به صورت روزانه وضعیت شبکه بین‌بانکی را پایش نماید. همچنین ضروری است سیاست‌های نظارتی به گونه‌ای طراحی شوند که علاوه بر کنترل نوسانات بازار پول، از تمرکز بیش از حد نقدینگی در تعداد محدودی از بانک‌ها جلوگیری شود. توسعه خطوط اعتباری مشروط، افزایش شفافیت اطلاعات بین‌بانکی، تقویت زیرساخت‌های تحلیل داده و استفاده گسترده‌تر از فناوری‌های هوش مصنوعی در نظارت بانکی می‌تواند به ارتقای تاب‌آوری نظام مالی کمک کند. همچنین توجه ویژه به بانک‌های دارای مرکزیت بالا در شبکه و تدوین برنامه‌های مدیریت بحران برای آنها می‌تواند احتمال سرایت شوک‌های نقدینگی را کاهش دهد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

حمایت مالی

این پژوهش حامی مالی نداشته است.

در انجام این پژوهش تمامی موازن و اصول اخلاقی رعایت گردیده است.

References

- Abdesslem, R. B., Chkir, I., & Dabbou, H. (2022). Is managerial ability a moderator? The effect of credit risk and liquidity risk on the likelihood of bank default. *International Review of Financial Analysis*, 80, 102044. <https://doi.org/10.1016/j.irfa.2022.102044>
- Armanious, A., & Zhao, R. (2024). Stock liquidity effect on leverage: The role of debt security, financial constraint, and risk around the global financial crisis and Covid-19 pandemic. *International Review of Financial Analysis*, 92, 103093.
- Basheer, M. F., Waemustafa, W., Hidhiir, M. H. B., & Hassan, S. G. (2021). Explaining the endogeneity between the credit risk, liquidity risk, and off-balance sheet activities in commercial banks: a case of South Asian economies. *International Journal of Monetary Economics and Finance*, 14(2), 166-187. <https://doi.org/10.1504/IJMEF.2021.114032>
- Chen, K. (2024). The Interactive Impact of Liquidity Risk and Corporate Financial Decisions. *Academic Conferences Series*, 4(1). <https://doi.org/10.62381/acs.sdit2024.01>
- Dang, V. D., & Nguyen, H. C. (2022). Uncertainty and Bank Funding Liquidity Risk in Vietnam. *Economic Annals*, 67(234), 29-54. <https://doi.org/10.2298/eka2234029d>
- Hacini, I., Bouloufad, A., & Dahou, K. (2021). The impact of liquidity risk management on the financial performance of Saudi Arabian Banks. *EMAJ: Emerging Markets Journal*, 11(1), 67-75. <https://doi.org/10.5195/emaj.2021.221>
- Khezriyan, M., Naderi, H., & Rastgar, M. A. (2023). A Comprehensive Study of Liquidity Risk Management in the Banking Industry: Identifying and Classifying Components Using the Meta-Synthesis Method. *Quarterly Journal of Applied Theories of Economics*, 10(2), 65-96.
- Khosraviani, M., & Heidarpour, F. (2022). Modeling to Predict the Liquidity Risk of Iranian State-Owned Banks Using Artificial Neural Networks and Accounting Indicators. *Financial Accounting and Auditing Research*, 14(55), 163-180.
- Liu, X. (2024). Unraveling systemic risk transmission: An empirical exploration of network dynamics and market liquidity in the financial sector. *Journal of the Knowledge Economy*, 1-36. <https://doi.org/10.1007/s13132-024-01861-9>
- Lu, H. (2023). Ripple Through the Silk Road: Analysis of Liquidity Risk Spillover Effects in Stock Markets of Belt and Road Initiative Countries. *Advances in Economics and Management Research*, 8(1), 318. <https://doi.org/10.56028/aemr.8.1.318.2023>
- Maleki Hassan, A., & Arab, M. H. (2023). *Investigating the Effect of Operational Cash Flow Ambiguity on Stock Liquidity and Future Stock Price Crash Risk* 5th International Conference on New Ideas in Management, Economics, Accounting and Banking,
- Mariska, U., Suhendar, S., & Nurmalia, G. (2025). The Effect of Profitability, Liquidity, Firm Size, Net Working Capital, Leverage, and Growth Opportunity on Cash Holding: Empirical Study From Property and Real Estate Companies Listed in Indonesian Syariah Stock Index (ISSI) for The Period 2019-2023. *Golden Ratio of Finance Management*, 5(2), 279-296. <https://doi.org/10.52970/grfm.v5i2.1125>
- Marjohan, M., Anggraini, A., Dewi, S. K. S., & Arsid, N. (2023). Opportunity Set, Liquidity, Stock Return, Inflation as a Moderator Investment Risk, Investment. *Jurnal Manajemen*, 27(2), 381-402. <https://doi.org/10.24912/jm.v27i2.1380>
- Moghadam, M. H., Mirlouhi, S. M., Tehrani, R., & Dehghan-Neiri, M. (2025). *Identifying the influencing components of liquidity risk in banks listed on the Tehran Stock Exchange using the smooth transition regression model*. https://jem.semnan.ac.ir/article_10110.html
- Musneh, R., Karim, M. R. A., & Caroline Geetha, A. A. B. (2021). Liquidity Risk and Stock Returns: Empirical Evidence From Industrial Products and Services Sector in Bursa Malaysia. *Future Business Journal*, 7(1). <https://doi.org/10.1186/s43093-021-00106-4>
- Ogbuonyalu, U. O., Abiodun, K., Dzamefe, S., Vera, E. N., Oyinlola, A., & Emmanuel, I. (2024). Assessing Artificial Intelligence Driven Algorithmic Trading Implications on Market Liquidity Risk and Financial Systemic Vulnerabilities. 18-21. <https://doi.org/10.38124/ijsrmt.v3i4.433>
- Saleemi, J. (2022). Liquidity Pricing Risk and Crude Oil Market: Analyzing the Liquidity as a Priced Factor in Yields During the Pandemic Uncertainty. *Journal of Contemporary Research in Business Economics and Finance*, 4(3), 43-55. <https://doi.org/10.55214/jcrbef.v4i3.183>
- Shirbandi, H., Khalvati, S., & Farmani, A. (2023). The impact of liquidity flow risk management on financial stability. *Shabak Specialized Scientific Journal*, 9(1), 141-154.
- Shoja'i Asl, I. (2023). *Study of Liquidity Shock in Credit Risk of Cooperative Development Bank*.
- Zhang, Q., Choudhry, T., Kuo, J.-M., & Liu, X. (2021). Does Liquidity Drive Stock Market Returns? The Role of Investor Risk Aversion. *Review of Quantitative Finance and Accounting*, 57(3), 929-958. <https://doi.org/10.1007/s11156-021-00966-5>