
DỰ BÁO RỦI RO THANH KHOẢN TẠI CÁC NGÂN HÀNG THƯƠNG MẠI: TIẾP CẬN HỌC MÁY

Nguyễn Anh Tú

Trường Đại học Ngân hàng Thành phố Hồ Chí Minh

Email: tuna@hub.edu.vn

Nguyễn Minh Nhật*

Trường Đại học Ngân hàng Thành phố Hồ Chí Minh

Email: nhatnm@hub.edu.vn

Mã bài báo: JED-3118

Ngày nhận: 07/05/2026

Ngày nhận bản sửa: 15/06/2026

Ngày duyệt đăng: 02/07/2026

DOI: 10.33301/JED.VI.3118

Tóm tắt

Nghiên cứu này áp dụng các thuật toán hồi quy học máy (Mạng nơ-ron nhân tạo, Rừng Ngẫu nhiên, và XGBoost) nhằm dự báo rủi ro thanh khoản tại 26 ngân hàng thương mại Việt Nam giai đoạn 2010-2023. Các mô hình được đánh giá thông qua hai chỉ số RMSE và MAE. Kết quả chỉ ra XGBoost cho sai số dự báo thấp nhất trên tập kiểm tra, tiếp đến là RF trong khi ANN cho sai số cao nhất. Những kết quả cho thấy thuật toán họ cây tăng cường vượt trội trong dự báo thanh khoản. Nghiên cứu cũng gợi ý các phương pháp áp dụng trong tương lai nhằm nâng cao chất lượng dự báo và tăng tính giải thích của kết quả.

Từ khóa: ANN, thanh khoản, học máy, rừng ngẫu nhiên, hồi quy, XGBoost.

Mã JEL: C44, C61, G21, G33.

Liquidity risk prediction in commercial banks: A machine learning approach

Abstract

This research adopts machine learning regression algorithms - Artificial Neural Networks (ANN), Random Forest (RF), and XGBoost - to predict liquidity risk in 26 Vietnamese commercial banks from 2010 to 2023. The algorithms are evaluated using RMSE and MAE. The results reveal that XGBoost achieves the lowest prediction error on the test set, followed by RF, while ANN records the highest error. These findings suggest that tree-based boosting methods perform better in liquidity risk prediction. The study also suggests future approaches to improve predictive performance and enhance the interpretability of the results.

Keywords: ANN, liquidity, machine learning, random forest, regression, XGBoost.

JEL Codes: C44, C61, G21, G33.

1. Giới thiệu

Dự báo rủi ro thanh khoản (RRTK) của ngân hàng thương mại (NHTM) là một chủ đề có ý nghĩa đặc biệt quan trọng trong nghiên cứu tài chính ngân hàng, bởi ngân hàng đồng thời thực hiện chức năng chuyển hóa kỳ hạn và đối mặt với áp lực rút vốn rất lớn từ phía người gửi tiền cũng như các chủ nợ ngắn hạn. Khi tỷ lệ tài sản kém thanh khoản so với nghĩa vụ ngắn hạn gia tăng, ngân hàng có thể rơi vào tình trạng mất khả năng đáp ứng thanh khoản, từ đó làm suy giảm niềm tin của thị trường và khuếch đại rủi ro lan truyền trong toàn hệ thống (Davis & Karim, 2008). Thực tiễn từ cuộc khủng hoảng tài chính toàn cầu năm 2007 cho thấy ngay cả những ngân hàng có mức vốn tương đối an toàn vẫn có thể đối mặt với căng thẳng nghiêm trọng nếu quản trị thanh khoản thiếu thận trọng (Hartlage, 2012). Bên cạnh đó, RRTK không chỉ ảnh hưởng đến sự ổn định

riêng lẻ của từng ngân hàng mà còn tác động đến khả năng cung ứng tín dụng cho nền kinh tế thực. Điều này làm gia tăng rủi ro thắt chặt tín dụng và suy giảm tăng trưởng kinh tế khi các ngân hàng có cấu trúc huy động ổn định hơn tiếp tục cho vay tốt hơn. Trong khi, các ngân hàng nắm giữ nhiều tài sản kém thanh khoản phải tăng thanh khoản tài sản và thu hẹp tín dụng (Chen & cộng sự, 2021). Điều này cho thấy RRTK có thể khuếch đại vòng xoáy thắt chặt tín dụng đối với nền kinh tế thực (Cornett & cộng sự, 2011). Vì vậy, việc dự báo sớm RRTK có ý nghĩa cấp thiết cả ở cấp độ vĩ mô lẫn vi mô, đặc biệt trong bối cảnh áp lực cạnh tranh, biến động thị trường và yêu cầu an toàn hệ thống ngày càng cao.

Về lý thuyết và thực nghiệm, các công trình trước cho thấy RRTK chịu tác động đồng thời của nhiều nhóm nhân tố, bao gồm đặc điểm nội tại của ngân hàng, cấu trúc tài trợ, cơ chế quản trị và các yếu tố vĩ mô. Những kết quả này hàm ý rằng RRTK là một hiện tượng mang tính hệ thống nhưng vẫn chịu điều kiện chi phối bởi bối cảnh thể chế và mô hình hoạt động của từng ngân hàng. Tuy nhiên, hướng nghiên cứu dựa trên các mô hình hồi quy tuyến tính truyền thống vẫn còn hạn chế trong việc nắm bắt các quan hệ phi tuyến và tương tác phức tạp giữa các biến giải thích. Trong bối cảnh đó, học máy đang nổi lên như một hướng tiếp cận đầy triển vọng trong dự báo RRTK. Guerra & cộng sự (2022) nhấn mạnh rằng sự biến động nhanh của môi trường tài chính đòi hỏi các công cụ dự báo có độ chính xác cao hơn và có khả năng sử dụng trong giám sát sớm. Các nghiên cứu gần đây cũng cho thấy học máy có thể nâng cao năng lực phát hiện tín hiệu rủi ro và hỗ trợ thiết kế hệ thống cảnh báo sớm, đặc biệt trong những trường hợp dữ liệu có tính phi tuyến và mất cân bằng cao (Barongo & Mbelwa, 2024). Hơn nữa, Heß & Damásio (2025) chỉ ra rằng mặc dù học máy đã được áp dụng rộng hơn trong quản trị rủi ro ngân hàng, nhưng nghiên cứu chuyên sâu về RRTK vẫn còn tương đối hạn chế. Do đó, vẫn tồn tại khoảng trống về mặt thực nghiệm trong việc so sánh hiệu năng của các thuật toán học máy khác nhau trong dự báo RRTK tại các NHTM, nhất là trong bối cảnh Việt Nam.

Từ khoảng trống đó, nghiên cứu này được thực hiện nhằm đánh giá và so sánh hiệu năng dự báo RRTK của ba mô hình học máy gồm Mạng nơ-ron nhân tạo (ANN), Rừng ngẫu nhiên (RF) và XGBoost trên mẫu gồm 26 NHTM Việt Nam trong giai đoạn 2010-2023. Biến phụ thuộc là khe hở tài trợ (FGAP), trong khi các biến giải thích phản ánh khả năng sinh lời, cấu trúc thanh khoản, chất lượng tài sản, quy mô vốn chủ sở hữu, quy mô ngân hàng và các yếu tố vĩ mô. Bằng cách so sánh sai số dự báo giữa các mô hình, nghiên cứu kỳ vọng cung cấp thêm bằng chứng thực nghiệm về phương pháp dự báo phù hợp hơn đối với RRTK. Đồng thời, nghiên cứu xác định các nhân tố có vai trò quan trọng nhất trong dự báo FGAP nhằm hỗ trợ xây dựng mô hình nhân tố rủi ro thanh khoản tại các NHTM và giám sát ngân hàng trong thực tiễn.

2. Tổng quan nghiên cứu

Các nghiên cứu về RRTK thường tiếp cận vấn đề này như kết quả của sự tương tác giữa đặc điểm nội tại của ngân hàng và điều kiện vĩ mô. Berger & Bouwman (2009) cho thấy quy mô tạo thanh khoản tăng mạnh theo thời gian, chủ yếu ở các ngân hàng lớn và ngân hàng bán lẻ. Đồng thời, mối quan hệ giữa vốn và hoạt động tạo thanh khoản không đồng nhất theo quy mô ngân hàng. Kết quả này hàm ý rằng vốn hóa cao không tự động đồng nghĩa với thanh khoản thấp hay cao, mà tác động của vốn phụ thuộc vào mô hình kinh doanh, quy mô và cấu trúc hoạt động của ngân hàng. Trong một nghiên cứu trên các NHTM Ấn Độ, Singh & Sharma (2016) cho thấy quy mô ngân hàng, tiền gửi, khả năng sinh lời, hệ số an toàn vốn, GDP và lạm phát đều có ảnh hưởng có ý nghĩa đến thanh khoản ngân hàng; trong đó tiền gửi, lợi nhuận, vốn và lạm phát có tác động dương. Kết quả này hàm ý rằng thanh khoản phản ánh đồng thời cấu trúc bảng cân đối, khả năng huy động vốn và môi trường kinh tế vĩ mô. Từ đó, nghiên cứu này nhấn mạnh vai trò của các biến nội tại và biến vĩ mô như những nhân tố nền tảng trong mô hình giải thích RRTK. Một hướng nghiên cứu khác tập trung vào cấu trúc tài trợ của ngân hàng. Abdul-Rahman & cộng sự (2018) kiểm định mối quan hệ giữa cấu trúc tài trợ và RRTK tại hệ thống NHTM Malaysia và nhận thấy cấu trúc tài trợ có liên hệ đáng kể với RRTK. Trong đó, tài trợ ngắn hạn làm gia tăng cả RRTK ngắn hạn lẫn dài hạn của hệ thống NHTM Hồi giáo, trong khi biến này ảnh hưởng mạnh hơn đến RRTK dài hạn của hệ thống NHTM truyền thống. Kết quả này cho thấy cùng một biến giải thích nhưng tác động có thể thay đổi theo mô hình kinh doanh, hàm ý rằng các nghiên cứu về thanh khoản cần phân biệt theo đặc thù thể chế và cấu trúc hoạt động của ngân hàng. Mdaghri &

Oubdi (2022) phát hiện trong khu vực MENA rằng vốn, quy mô, rủi ro ngân hàng, tiền gửi và khả năng sinh lời đều liên quan đến tạo thanh khoản, còn lạm phát, thất nghiệp, tiết kiệm và chính sách tiền tệ giải thích biến thiên thanh khoản giữa các ngân hàng. Những khác biệt này cho thấy tác động của các biến ngân hàng không mang tính phổ quát tuyệt đối, mà phụ thuộc mạnh vào mô hình ngân hàng, thể chế, chế độ giám sát và cách đo lường thanh khoản. Từ các nghiên cứu trên có thể thấy các nhân tố tác động đến RRTK thường được phân thành bốn cụm lớn: nhân tố ngân hàng, cấu trúc tài trợ, quản trị và điều kiện vĩ mô. Tuy nhiên, hướng tác động của từng biến không hoàn toàn đồng nhất giữa các quốc gia và vẫn cần được nghiên cứu. Trong bài viết này, RRTK được đo lường bởi khe hở tài trợ (FGAP) phản ánh mức độ mất cân đối giữa nhu cầu tài trợ và nguồn vốn ổn định. Giá trị FGAP càng lớn cho thấy ngân hàng phụ thuộc nhiều hơn vào nguồn tài trợ bên ngoài và đối mặt với áp lực thanh khoản cao hơn. Vì vậy, bên cạnh giá trị dự báo chính xác, việc xác định các yếu tố ảnh hưởng mạnh đến FGAP cũng mang ý nghĩa quan trọng đối với quản trị thanh khoản.

So với nhánh nghiên cứu về RRTK theo các mô hình hồi quy tuyến tính truyền thống, sử dụng học máy cho dự báo RRTK còn nhiều khoảng trống. Một tổng quan gần đây của Heß & Damásio (2025) về học máy trong quản trị rủi ro NHTM cho thấy các nghiên cứu về thanh khoản vẫn còn hạn chế. Nghiên cứu nhấn mạnh thuật toán đóng vai trò quyết định đối với năng lực dự báo và xử lý rủi ro, và việc tích hợp học máy vào khung quản trị RRTK vẫn là một khoảng trống đáng kể. Trước đó, khi đề cập tới mô hình hóa RRTK dưới góc nhìn giám sát, Guerra & cộng sự (2022) lập luận rằng tốc độ thay đổi của thị trường và yêu cầu giám sát ngày càng cao đòi hỏi một phương pháp đánh giá rủi ro chính xác hơn, có khả năng mô phỏng các kịch bản thay thế khi đưa vào các biến rủi ro chính. Từ đó, nghiên cứu xem học máy như một công cụ cảnh báo sớm thay vì chỉ là công cụ phân loại đơn thuần và chuyển trọng tâm từ các mô hình tuyến tính truyền thống sang cách tiếp cận phi tuyến, có khả năng khai thác tương tác phức tạp giữa các chỉ báo thanh khoản. Taviana & cộng sự (2018) là một trong những nghiên cứu tiên phong sử dụng ANN và Bayesian Network để đánh giá RRTK, nhấn mạnh rằng mối quan hệ giữa các biến ngân hàng và thanh khoản thường phi tuyến, khó mô tả bằng mô hình tuyến tính đơn giản. Nghiên cứu cho thấy ANN có tiềm năng dự báo thanh khoản và có thể hỗ trợ phát hiện tín hiệu trong dữ liệu ngân hàng. Các kết quả này hàm ý rằng học máy đặc biệt phù hợp khi mục tiêu là khai thác quan hệ phi tuyến, tương tác bậc cao và dữ liệu nhiều chiều.

Barongo & Mbelwa (2024) phát triển thêm hướng tiếp cận này bằng một mô hình học máy để phát hiện RRTK của 38 NHTM Tanzania giai đoạn 2010-2021. Nghiên cứu xây dựng mô hình lai RF-MLP nhằm cải thiện độ nhạy phát hiện RRTK và cho hiệu năng cao hơn các mô hình đối sánh, với các chỉ tiêu thực nghiệm được báo cáo ở mức khá tốt cho bài toán phân loại mất cân bằng. Đáng chú ý, các nghiên cứu trong tài liệu cũng cho thấy RF có thể đạt kết quả tốt trong dự báo RRTK và cảnh báo sớm RRTK, nhưng hiệu năng phụ thuộc mạnh vào chọn biến, đặc tả mục tiêu và xử lý tương quan giữa các biến đầu vào. Đồng thời, các mô hình họ cây quyết định có thể dự báo trạng thái căng thẳng thị trường theo thời gian thực, nhưng vẫn chủ yếu sử dụng tín hiệu thị trường hơn là dữ liệu ngân hàng thuần túy (Tanaka & cộng sự, 2016). Taviana & cộng sự (2018) phát triển hệ thống cảnh báo sớm sử dụng các thuật toán tăng cường, trong đó nhấn mạnh vai trò của việc xử lý mất cân bằng dữ liệu và lựa chọn đặc trưng trong việc cải thiện hiệu năng dự báo. Nghiên cứu tiếp cận dữ liệu thị trường thay vì dữ liệu bảng cân đối ngân hàng, do đó vẫn để ngỏ không gian nghiên cứu cho các mô hình dự báo định lượng RRTK dựa trên dữ liệu vĩ mô ngân hàng.

Từ đó, có thể xác định ba khoảng trống nổi bật. Thứ nhất, nhiều công trình về yếu tố tác động tập trung vào giải thích thanh khoản hơn là dự báo thanh khoản. Trong khi, các nghiên cứu ML lại thường chuyển sang phá sản ngân hàng hoặc khó khăn tài chính hơn là trực tiếp dự báo RRTK của ngân hàng. Thứ hai, rất ít nghiên cứu so sánh có hệ thống giữa ANN, Random Forest và XGBoost trên cùng một bộ dữ liệu thanh khoản, cùng một định nghĩa biến phụ thuộc, và cùng một quy trình kiểm định ngoài mẫu. Điểm mới của nghiên cứu này là việc thiết lập một quy trình đánh giá kết hợp giữa ba họ thuật toán có nguyên lý học tập khác nhau: học dựa trên lan truyền ngược (ANN), học dựa trên lấy mẫu ngẫu nhiên (RF) và học dựa trên tối ưu hóa lỗi tuần tự (XGBoost) trên cùng một cấu trúc dữ liệu bảng. Thứ ba, các nghiên cứu trước còn thiếu các bằng chứng từ bối cảnh ngân hàng thương mại Việt Nam, nơi đặc trưng thị trường mới nổi, cấu trúc sở hữu đa dạng và môi trường vĩ mô biến động có thể làm thay đổi đáng kể mối quan hệ giữa các biến ngân

hàng với thanh khoản. Do đó, một nghiên cứu kết hợp phân tích nhân tố, dự báo học máy và so sánh mô hình trên dữ liệu Việt Nam có ý nghĩa cả về mặt học thuật lẫn thực tiễn giám sát ngân hàng.

3. Phương pháp nghiên cứu

Dựa vào các mô hình thực nghiệm từ các nghiên cứu trước (Abdul-Rahman & cộng sự, 2018; Mdaghri & Oubdi, 2022; Singh & Sharma, 2016), nghiên cứu này đề xuất một mô hình tổng quát của các thuật toán ANN, RF và XGBoost, hàm mô hình hồi quy phi tuyến giữa RRTK (FGAP) và 7 biến độc lập sau:

$$FGAP_{ANN/FR/XGBoost} = f(ROE, LIA, NPL, ETA, SIZE, GDP, INF) \quad (1)$$

Trong đó: Biến phụ thuộc là khe hở tài trợ (FGAP). Biến độc lập bao gồm: tỷ suất sinh lời (ROE), cấu trúc thanh khoản (LIA), nợ xấu (NPL), quy mô vốn chủ sở hữu (ETA), quy mô ngân hàng (SIZE), tăng trưởng GDP (GDP) và tỷ lệ lạm phát (INF).

Bảng 1. Mô tả các biến có trong mô hình nghiên cứu

Ký hiệu	Diễn giải	Đo lường	Kỳ vọng	Nguồn
<i>Biến phụ thuộc đại diện cho RRTK</i>				
FGAP	Khe hở tài trợ	$\frac{\text{(Dư nợ cho vay - Tiền gửi khách hàng)}}{\text{Tổng tài sản}}$	(+)	Mdaghri & Oubdi (2022)
<i>Các biến độc lập đặc thù ngân hàng</i>				
ROE	Tỷ suất sinh lời trên vốn chủ sở hữu	$\frac{\text{Lợi nhuận sau thuế}}{\text{Vốn chủ sở hữu}}$	(+)	Arif & Anees (2012)
LIA	Cấu trúc thanh khoản	$\frac{\text{Tài sản thanh khoản}}{\text{Tổng tài sản}}$	(+)	Nguyễn Anh Tú & cộng sự (2025)
NPL	Tỷ lệ nợ xấu	$\frac{\text{Nợ xấu (tổng nợ thuộc nhóm 3, 4, 5)}}{\text{Tổng dư nợ tín dụng}}$	(-)	Arif & Anees (2012)
ETA	Quy mô vốn chủ sở hữu	$\frac{\text{Vốn chủ sở hữu}}{\text{Tổng tài sản}}$	(+)	Saleh & Abu Afifa (2020)
SIZE	Quy mô ngân hàng	Logarit cơ số e của tổng tài sản $= \ln(\text{Tổng tài sản})$	(+)	Saleh & Abu Afifa (2020)
<i>Các biến kiểm soát vĩ mô</i>				
GDP	Tốc độ tăng trưởng kinh tế	$\frac{GDP_t - GDP_{t-1}}{GDP_{t-1}}$	(+)	Nguyễn Anh Tú & cộng sự (2025)
INF	Tỷ lệ lạm phát	$\frac{CPI_t - CPI_{t-1}}{CPI_{t-1}}$	(-)	Tu & cộng sự (2024)

Nguồn: Nhóm tác giả tổng hợp.

Nghiên cứu này sử dụng 3 mô hình học máy bao gồm Mạng nơ-ron nhân tạo (ANN), Rừng ngẫu nhiên (RF) và XGBoost. Trong đó, ANN đưa ra giá trị dự báo tốt nhất bằng cách cập nhật ma trận trọng số của các yếu tố đầu vào làm cho giá trị sai số dự báo nhỏ nhất. RF lựa chọn phương án tốt nhất bằng cách bầu chọn đa số, và XGBoost lựa chọn phương án tốt nhất bằng cách cập nhật lỗi từ các quyết định trước. Cách thức hoạt động chi tiết như sau:

3.1. Mạng nơ-ron nhân tạo

Một mạng ANN cơ bản bao gồm 3 lớp: lớp đầu vào, lớp ẩn (giữa) và lớp đầu ra (Rosenblatt, 1958). Lớp đầu vào là nơi nhận các dữ liệu đầu vào với mỗi nút là một đầu vào để huấn luyện mô hình. Trong nghiên cứu này, số nút lớp đầu vào là số biến độc lập trong mô hình phương trình (1). Lớp ẩn dùng để xử lý thông tin và truyền các kết quả đến các lớp tiếp theo. Số lượng lớp ẩn tùy thuộc vào độ phức tạp của mô hình và kỳ vọng về sự đánh đổi giữa thời gian đào tạo mô hình với độ chính xác của mô hình. Do tính chất của bộ dữ liệu không phức tạp, nghiên cứu này sử dụng một lớp ẩn và số lượng nơ-ron trong lớp ẩn là 8. Lớp đầu

ra cung cấp kết quả dự báo cuối cùng. Trong nghiên cứu này, đầu ra chỉ có 1 biến là biến phụ thuộc FGAP. Hàm kích hoạt giữa các lớp được thử nghiệm với hàm Sigmoid: $f(x) = \frac{1}{1+e^{-x}}$

3.2. Rừng ngẫu nhiên

Rừng ngẫu nhiên (RF) là một tập hợp các cây quyết định được xây dựng ngẫu nhiên, mỗi cây được huấn luyện trên một tập dữ liệu con và một tập hợp tính năng con được lấy từ một bộ dữ liệu chung. Mỗi cây sẽ đưa ra quyết định (hay dự đoán) và tạo ra các kết quả dựa trên việc bỏ phiếu của đa số quyết định giống nhau từ các cây (Breiman, 2001). Nói cách khác, RF tạo ra các cây quyết định khác nhau trong giai đoạn đào tạo và quyết định đầu ra với đa số phiếu bầu (Breiman, 2001).

Về bản chất, RF cải thiện độ chính xác dự đoán tổng thể và độ mạnh mẽ của quy trình phân loại nhị phân bằng cách tận dụng khả năng ra quyết định tập thể của nhiều cây huấn luyện trên các tập hợp con dữ liệu và bộ dự đoán khác nhau. Trong nghiên cứu này, các tham số được điều chỉnh là “max_depth” và “max_feature”, trong đó “max_depth” xem xét vấn đề khớp quá mức (overfitting) và “max_feature” tìm kiếm sự phân chia tốt nhất để cải thiện kết quả (Sameen & cộng sự, 2019). Nghiên cứu trình bày kết quả tốt nhất của tất cả cài đặt trong mô hình RF.

3.3. XGBoost

XGBoost là một thuật toán học máy có giám sát thuộc nhóm học liên kết nhằm cải thiện tốc độ, hiệu suất và khả năng khái quát hóa so với Gradient Boosting (Chen & Guestrin, 2016). XGBoost xây dựng mô hình như một sự tổng hợp tuần tự của nhiều cây quyết định. Trong mỗi lần lặp, XGBoost thêm một cây để giảm thiểu lỗi của các cây trước đó thông qua tối ưu hóa giảm độ dốc. Mô hình tối ưu hóa cho một hàm mục tiêu bao gồm: (i) Một hàm mất mát để đo lỗi dự đoán giữa các giá trị thực tế và giá trị ước tính; và (ii) một nhân tố điều chỉnh để kiểm soát độ phức tạp của mô hình và giảm hiện tượng quá khớp.

3.4. Các chỉ số đo lường chất lượng mô hình

Nghiên cứu này sử dụng 2 thông số để đo lường chất lượng dự báo là Sai số bình phương nhỏ nhất (Root Mean Square Error - RMSE) và Sai số tuyệt đối (Mean Absolute Error - MAE) nhằm đo lường sai số dự báo giữa giá trị thực (Y) và giá trị dự báo ($\hat{Y}$) theo công thức như sau:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y - \hat{Y})^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y - \hat{Y}| \quad (3)$$

Các giá trị RMSE và MAE càng nhỏ thì mô hình càng đạt chất lượng dự báo tốt (Lu & cộng sự, 2024; Nguyen & cộng sự, 2021; Tu & cộng sự, 2024). Để các kết quả dự báo thu được mang ý nghĩa thống kê, các thuật toán được thiết kế để chạy và ghi nhận giá trị của từng vòng lặp, sau đó lấy giá trị trung bình của 30 vòng lặp cho RMSE và MAE của từng thuật toán ANN, RF và XGBoost.

3.5. Thu thập dữ liệu

Mẫu nghiên cứu được thu thập từ 26 NHTM tại Việt Nam trong giai đoạn 2010-2023, với tổng số 364 quan sát. Toàn bộ dữ liệu được trích xuất từ nghiên cứu về thanh khoản NHTM Việt Nam của Tú & cộng sự (2025) tại website: <https://data.mendeley.com/datasets/pmkb8jzfz73/1>.

Dữ liệu nghiên cứu được chia thành 2 tập, bao gồm tập huấn luyện và tập kiểm tra, với tỷ lệ lần lượt là 79% và 21%, tương ứng với 286 và 78 quan sát. Tỷ lệ này đảm bảo mô hình có đủ dữ liệu để học, đồng thời duy trì tập kiểm tra ở mức tối ưu. Cụ thể, mỗi NHTM đều có 11 năm dữ liệu cho tập huấn luyện và 3 năm dữ liệu cho tập kiểm tra. Các thuật toán được viết bằng ngôn ngữ lập trình Python trên nền Google Colab.

4. Kết quả nghiên cứu và thảo luận

4.1. Thống kê mô tả

Bảng 2 cho thấy bộ dữ liệu gồm 364 quan sát cân bằng. Biến phụ thuộc FGAP có giá trị trung bình (-0,0741) và trung vị (-0,0695) mang dấu âm, phản ánh xu hướng thiếu hụt thanh khoản, phù hợp với các bằng chứng trước đây về chức năng chuyển hóa kỳ hạn của NHTM (Berger & Bouwman, 2009). Mức độ

phân tán của FGAP (từ -0,3857 đến 0,2865) cho thấy sự khác biệt đáng kể về trạng thái thanh khoản giữa các NHTM. Mặt khác, độ phân tán rộng cũng cho thấy nhu cầu xây dựng các công cụ dự báo sớm nhằm nhận diện các giai đoạn thanh khoản suy giảm trước khi rủi ro trở nên nghiêm trọng.

Bảng 2. Thống kê mô tả các biến trong mô hình

	FGAP	ROE	LIA	NPL	ETA	SIZE	GDP	INF
Số quan sát	364	364	364	364	364	364	364	364
Trung bình	-0,0741	0,1126	0,1873	0,022	0,0934	18,682	0,0602	0,0516
Độ lệch	0,1136	0,0845	0,0807	0,0204	0,0386	1,2001	0,0156	0,0446
Nhỏ nhất	-0,3857	-0,563	0,0452	0,0002	0,0406	15,923	0,0256	0,0063
25%	-0,1453	0,0539	0,1317	0,0133	0,0664	17,831	0,055	0,0279
50%	-0,0695	0,1042	0,175	0,0193	0,0832	18,674	0,0642	0,0339
75%	0,0021	0,1683	0,2337	0,0257	0,1073	19,546	0,0699	0,0659
Lớn nhất	0,2865	0,3033	0,611	0,2976	0,2564	21,557	0,0802	0,1867


Nguồn: Tính toán của nhóm tác giả.

Trong các biến giải thích, ROE có xu hướng trung tâm dương nhưng biến động lớn, trong khi LIA và NPL có phân phối lệch phải, hàm ý mức độ rủi ro không đồng đều giữa các NHTM. Phân tích boxplot cũng cho thấy sự xuất hiện của nhiều giá trị ngoại lai, đặc biệt đối với NPL và INF, phản ánh các quan sát cực trị thường thấy trong dữ liệu ngân hàng. Các kết quả này hàm ý khả năng dữ liệu vượt ra giả định phân phối chuẩn, từ đó ủng hộ việc sử dụng các phương pháp ước lượng phi tuyến của học máy.

4.2. Ma trận tương quan

Ma trận tương quan tại Hình 1 cho thấy phần lớn các biến độc lập có mức tương quan thấp với biến phụ thuộc FGAP, phản ánh bản chất phi tuyến giữa các biến. Vì vậy, các mô hình học máy phi tuyến tính như ANN, RF và XGBoost được kỳ vọng phù hợp hơn so với các mô hình tuyến tính truyền thống vì chúng có khả năng học các mối quan hệ phức tạp và đa chiều giữa các đặc trưng. Các mô hình học máy có khả năng kiểm chứng năng lực xử lý các mối quan hệ phi tuyến và tương tác đa chiều giữa các đặc trưng tài chính (như ROE, ETA, SIZE) mà các mô hình truyền thống thường bỏ qua. Ngoài ra, không có cặp biến nào có hệ số tương quan $|\text{corr}| > 0,8$, cho thấy không tồn tại hiện tượng đa cộng tuyến (Gujarati, 2004).

Hình 1. Ma trận tương quan giữa các biến trong mô hình



Nguồn: Tính toán của nhóm tác giả.

4.3. Kết quả hồi quy dự báo

Kết quả thực nghiệm cho thấy sự khác biệt rõ rệt về hiệu năng giữa ba mô hình. ANN ghi nhận sai số cao nhất trên cả tập huấn luyện và kiểm tra (RMSE/MAE lần lượt là 0,1105/0,0877 và 0,1141/0,0896), cho thấy hạn chế trong khả năng khái quát hóa khi áp dụng cho dữ liệu tài chính có quy mô nhỏ và nhiễu cao. Điều này phù hợp với lập luận rằng ANN dễ bị quá khớp trong bối cảnh dữ liệu hạn chế và cấu trúc bảng. Ngược lại, Random Forest cải thiện đáng kể hiệu năng dự báo, với RMSE/MAE trên tập kiểm tra là 0,0881/0,0693, phản ánh khả năng giảm phương sai và tăng tính ổn định nhờ cơ chế tạo ra nhiều tập con từ dữ liệu huấn luyện thông qua lấy mẫu ngẫu nhiên có hoàn lại (Breiman, 2001). XGBoost đạt kết quả tốt nhất trên tập kiểm tra (RMSE/MAE lần lượt là 0,0856; 0,0675), đồng thời có sai số huấn luyện thấp nhất, cho thấy khả năng nắm bắt các quan hệ phi tuyến phức tạp giữa các biến (Chen & Guestrin, 2016). Kết quả này phản ánh sự kết hợp nhiều mô hình học riêng lẻ thành một mô hình học mạnh duy nhất, giúp tăng cường đáng kể hiệu suất tổng thể của mô hình, đặc biệt với dữ liệu cấu trúc (Liu & cộng sự, 2022). Do đó, XGBoost là lựa chọn tối ưu về độ chính xác dự báo, trong khi RF thể hiện sự cân bằng tốt hơn giữa độ chính xác và khả năng tổng quát hóa. Kết quả này nhất quán với các công trình gần đây cho thấy học máy có thể nâng cao năng lực phát hiện tín hiệu rủi ro trong môi trường tài chính biến động và phi tuyến (Barongo & Mbelwa, 2024; Guerra & cộng sự, 2022; Heß & Damásio, 2025).

Bảng 3. Kết quả dự báo từ các thuật toán đề xuất


Thuật toán	Tập huấn luyện		Tập kiểm tra	
Giá trị	RMSE	MAE	RMSE	MAE
ANN	0,1105	0,0877	0,1141	0,0896
RF	0,0671	0,0523	0,0881	0,0693
XGBoost	0.0394	0.0307	0.0856	0.0675

Nguồn: Tổng hợp từ kết quả nghiên cứu.

4.4. Tầm quan trọng các biến và hàm ý

Hình 2 trình bày kết quả đánh giá mức độ quan trọng của các biến. Đây là cơ sở để giải thích các biến tác động tới rủi ro thanh khoản trong mô hình (1). Biến ROE có mức độ quan trọng cao nhất trong mô hình. Điều này cho thấy khả năng sinh lời của NHTM đóng vai trò then chốt trong việc quyết định mức độ RRTK. Các NHTM có ROE cao thường có dòng tiền ổn định hơn, khả năng huy động vốn tốt hơn và do đó ít phải đối mặt với áp lực thanh khoản. Tiếp theo, biến ETA, đại diện cho mức độ an toàn vốn của NHTM cũng có mức độ quan trọng cao trong mô hình. Điều này có thể được lý giải bởi tỷ lệ vốn chủ sở hữu trên tổng tài sản cao giúp NHTM có bộ đệm tài chính vững chắc hơn trước các cú sốc thanh khoản, qua đó giảm rủi ro mất cân đối nguồn vốn. Biến SIZE cũng có mức độ quan trọng, phản ánh rằng các NHTM có quy mô lớn thường có lợi thế về đa dạng hóa nguồn vốn, khả năng tiếp cận thị trường liên ngân hàng và uy tín cao hơn, từ đó kiểm soát RRTK hiệu quả hơn so với các NHTM có quy mô nhỏ. Phát hiện này nhìn chung phù hợp với các nghiên cứu trước đây nhấn mạnh vai trò của đặc điểm ngân hàng và cấu trúc tài trợ trong quản trị thanh khoản (Berger & Bouwman, 2009; Mdaghri & Oubdi, 2022; Singh & Sharma, 2016). Kết quả này bổ sung hàm ý quản trị khi chỉ ra rõ các động lực để kiểm soát RRTK, điều mà các mô hình học máy không giải thích được. Theo đó, NHTM cần theo đuổi các chiến lược phù hợp để kiểm soát ROE, ETA và SIZE cho phù hợp với khả năng bù đắp RRTK. Cụ thể, các NHTM có thể xây dựng hệ thống cảnh báo sớm dựa trên XGBoost nhằm theo dõi biến động FGAP theo thời gian thực. Thứ nhất, duy trì khả năng sinh lời ổn định vì ROE là biến có sức ảnh hưởng lớn nhất tới dự báo thanh khoản. Thứ hai, việc nâng cao tỷ lệ vốn chủ sở hữu giúp tăng khả năng hấp thụ các cú sốc thanh khoản. Thứ ba, các ngân hàng quy mô nhỏ cần đặc biệt chú ý tới đa dạng hóa nguồn vốn và khả năng tiếp cận thị trường liên ngân hàng nhằm giảm áp lực thanh khoản trong các giai đoạn căng thẳng thị trường.

Hình 2. Tầm quan trọng của các biến độc lập trong mô hình



Nguồn: Tính toán của nhóm tác giả.

5. Kết luận

Nghiên cứu này được thực hiện nhằm đánh giá khả năng dự báo RRTK của các NHTM Việt Nam thông qua ba thuật toán học máy gồm Mạng nơ-ron nhân tạo (ANN), Rừng ngẫu nhiên (RF) và XGBoost trên bộ dữ liệu gồm 26 NHTM giai đoạn 2010-2023. Kết quả cho thấy XGBoost đạt hiệu năng dự báo tốt nhất trên tập kiểm tra, tiếp đến là RF, trong khi ANN cho sai số lớn nhất. Cụ thể, xét đồng thời 2 chỉ tiêu RMSE và MAE, XGBoost thể hiện ưu thế rõ rệt trong việc nắm bắt các quan hệ phi tuyến giữa các biến giải thích và biến phụ thuộc FGAP. Kết quả này khẳng định rằng trong bối cảnh dữ liệu ngân hàng có tính cấu trúc bảng, quy mô mẫu chưa lớn, các mô hình thuộc lớp cây tăng cường thường phù hợp hơn so với ANN vốn dễ bị quá khớp khi dữ liệu không đủ nhiều.

Từ kết quả trên, nghiên cứu đóng góp trước hết ở phương diện phương pháp luận khi so sánh trực tiếp 3 thuật toán đại diện cho 3 họ mô hình khác nhau, qua đó cung cấp bằng chứng thực nghiệm rằng các mô hình thuộc lớp cây tăng cường, đặc biệt là XGBoost, có ưu thế hơn trong dự báo RRTK. Nghiên cứu đóng góp một lộ trình thực thi cho việc ứng dụng ML trong giám sát ngân hàng tại các thị trường mới nổi, từ khâu lựa chọn biến dựa trên khung lý thuyết thực nghiệm từ các nghiên cứu truyền thống đến việc tìm ra công cụ dự báo rủi ro thanh khoản hiệu quả nhất. Đây là sự kết hợp ưu điểm của kinh tế lượng mang tính giải thích và học máy mang tính dự báo (Nguyễn Anh Tú, 2024). Thứ hai, nghiên cứu đóng góp ở phương diện thực tiễn khi chỉ ra rằng các chỉ tiêu phản ánh khả năng sinh lời, an toàn vốn và quy mô ngân hàng cần được theo dõi chặt chẽ trong hệ thống cảnh báo sớm thanh khoản. Thứ ba, nghiên cứu mở rộng bằng chứng thực nghiệm cho bối cảnh Việt Nam, nơi các nghiên cứu ứng dụng học máy cho RRTK còn tương đối hạn chế. Theo đó, bài viết này không chỉ cho thấy XGBoost là lựa chọn phù hợp hơn trong bối cảnh hiện tại mà còn gợi mở các nghiên cứu tiếp theo theo hướng kết hợp giữa dự báo chính xác, giải thích được và có giá trị ứng dụng cao trong giám sát an toàn thanh khoản ngân hàng.

Tuy nhiên, nghiên cứu vẫn tồn tại một số hạn chế. Thứ nhất, mẫu nghiên cứu mới dừng ở 26 NHTM trong một giai đoạn nhất định, nên khả năng khái quát hóa ra ngoài mẫu còn cần được kiểm định thêm. Thứ hai, việc tối ưu hóa tham số bằng các kỹ thuật tối ưu hóa tự động (như Grid Search hoặc Bayesian Optimization) cho các tham số trong các mô hình học máy để tăng tính khách quan thay vì cài đặt thủ công. Trên cơ sở đó, các nghiên cứu tiếp theo có thể mở rộng theo hướng tích hợp thêm các kỹ thuật giải thích mô hình và tối ưu hóa mô hình để làm rõ hơn cơ chế tác động của biến đầu vào và gia tăng chất lượng dự báo.

Tài liệu tham khảo

- Abdul-Rahman, A., Sulaiman, A.A. & Mohd Said, N.L.H. (2018). Does financing structure affects bank liquidity risk?. *Pacific-Basin Finance Journal*, 52, 26-39. <https://doi.org/10.1016/j.pacfin.2017.04.004>
- Arif, A. & Anees, N.A. (2012). Liquidity risk and performance of banking system. *Journal of Financial Regulation and Compliance*, 20(2), 182-195. <https://doi.org/10.1108/13581981211218342>
- Barongo, R.I. & Mbelwa, J.T. (2024). Using machine learning for detecting liquidity risk in banks. *Machine Learning with Applications*, 15, 100511. <https://doi.org/10.1016/j.mlwa.2023.100511>
- Berger, A.N. & Bouwman, C.H. (2009). Bank liquidity creation. *The Review of Financial Studies*, 22(9), 3779-3837. <https://doi.org/10.1093/rfs/hhn104>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chen, T. & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International conference on knowledge discovery and data mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Chen, W.D., Chen, Y. & Huang, S.C. (2021). Liquidity risk and bank performance during financial crises. *Journal of Financial Stability*, 56, 100906. <https://doi.org/10.1016/j.jfs.2021.100906>
- Cornett, M.M., McNutt, J.J., Strahan, P.E. & Tehranian, H. (2011). Liquidity risk management and credit supply in the financial crisis. *Journal of Financial Economics*, 101(2), 297-312. <https://doi.org/10.1016/j.jfineco.2011.03.001>
- Davis, E.P. & Karim, D. (2008). Comparing early warning systems for banking crises. *Journal of Financial Stability*, 4(2), 89-120. <https://doi.org/10.1016/j.jfs.2007.12.004>
- Guerra, P., Castelli, M. & Côte-Real, N. (2022). Machine learning for liquidity risk modelling: A supervisory perspective. *Economic Analysis and Policy*, 74, 175-187. <https://doi.org/10.1016/j.eap.2022.02.001>
- Gujarati, D.N. (2004). *Basic econometrics* (4th ed.). McGraw-Hill.
- Hartlage, A.W. (2012). The Basel III liquidity coverage ratio and financial stability. *Michigan Law Review*, 111, 453-484.
- Heß, V.L. & Damásio, B. (2025). Machine learning in banking risk management: Mapping a decade of evolution. *International Journal of Information Management Data Insights*, 5(1), 100324. <https://doi.org/10.1016/j.jjime.2025.100324>
- Liu, W., Fan, H., Xia, M. & Pang, C. (2022). Predicting and interpreting financial distress using a weighted boosted tree-based tree. *Engineering Applications of Artificial Intelligence*, 116, 105466. <https://doi.org/10.1016/j.engappai.2022.105466>
- Lu, S.H., Wang, H.J. & Nguyen, A.T. (2024). Machine learning applications on box-office revenue forecasting: The Taiwanese film market case study. In Ngoc Thach, N., Kreinovich, V., Ha, D.T. & Trung, N.D. (eds). *Optimal Transport Statistics for Economics and Related Topics* (pp. 384-402). Springer. https://doi.org/10.1007/978-3-031-35763-3_49
- Mdaghi, A.A. & Oubdi, L. (2022). Bank-specific and macroeconomic determinants of bank liquidity creation: Evidence from MENA countries. *Journal of Central Banking Theory and Practice*, 11(2), 55-76. <https://doi.org/10.2478/jcbtp-2022-0013>
- Nguyen, A.T., Lu, S.H. & Nguyen, P.T.T. (2021). Validating and forecasting carbon emissions in the framework of the environmental Kuznets curve: the case of Vietnam. *Energies*, 14(11), 3144. <https://doi.org/10.3390/en14113144>
- Nguyễn Anh Tú (2024). Động lực thu hút vốn đầu tư trực tiếp nước ngoài tại các quốc gia đang phát triển: Bằng chứng thực nghiệm từ tiếp cận học máy. *Tạp chí Nghiên cứu Kinh tế và Kinh doanh Châu Á*, 35(5), 119-134. <https://doi.org/10.24311/jabes/2024.35.5.6>
- Nguyễn Anh Tú, Trần Phú Thịnh & Đào Lê Kiều Oanh (2025). Tác động của rủi ro thanh khoản đến khả năng sinh

lời trong đại dịch COVID-19: Trường hợp các ngân hàng thương mại Việt Nam. *Tạp chí Kinh tế và Phát triển*, 334(2), 124-134. <https://doi.org/10.33301/JED.VI.2119>

- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>
- Saleh, I. & Abu Afifa, M. (2020). The effect of credit risk, liquidity risk and bank capital on bank profitability: Evidence from an emerging market. *Cogent Economics & Finance*, 8(1), 1814509. <https://doi.org/10.1080/23322039.2020.1814509>
- Sameen, M.I., Pradhan, B. & Lee, S. (2019). Self-Learning Random Forests Model for Mapping Groundwater Yield in Data-Scarce Areas. *Natural Resources Research*, 28(3), 757-775. <https://doi.org/10.1007/s11053-018-9416-1>
- Singh, A. & Sharma, A.K. (2016). An empirical analysis of macroeconomic and bank-specific factors affecting liquidity of Indian banks. *Future Business Journal*, 2(1), 40-53. <https://doi.org/10.1016/j.fbj.2016.01.001>
- Tanaka, K., Kinkyo, T. & Hamori, S. (2016). Random forests-based early warning system for bank failures. *Economics Letters*, 148, 118-121. <https://doi.org/10.1016/j.econlet.2016.09.024>
- Tavana, M., Abtahi, A.R., Di Caprio, D. & Poortarigh, M. (2018). An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking. *Neurocomputing*, 275, 2525-2554. <https://doi.org/10.1016/j.neucom.2017.11.034>
- Tu, N.A., Khoa, D.D., Nhan, N.C.T. & Le Kieu Oanh, D. (2024). Hybrid ARIMA and machine learning approach for the VND/USD exchange rate prediction in Vietnam: A comparative analysis. In: Ngoc Thach, N., Trung, N.D., Ha, D.T. & Kreinovich, V. (eds). *Partial Identification in Econometrics and Related Topics* (pp. 587-604). Springer. https://doi.org/10.1007/978-3-031-59110-5_39

***Tác giả liên hệ: Nguyễn Minh Nhật. Email: nhatnm@hub.edu.vn**