

Dự báo khả năng vỡ nợ của doanh nghiệp nhỏ và vừa tại Việt Nam: Nghiên cứu trên các mô hình học máy

Nguyễn Minh Nhật¹, Ngô Hoàng Khánh Duy²

Trường Đại học Ngân hàng TP.HCM, Việt Nam

Ngày nhận: 06/06/2024

Ngày nhận bản sửa: 18/06/2024

Ngày duyệt đăng: 01/07/2024

Tóm tắt: Nghiên cứu này xây dựng mô hình dự báo rủi ro vỡ nợ cho doanh nghiệp nhỏ và vừa (SMEs) tại Việt Nam bằng cách sử dụng các phương pháp học máy như hồi quy Logistic (LR), Cây quyết định, XGBoost và Mạng nơ-ron nhân tạo (ANN). Dữ liệu được thu thập từ báo cáo tài chính của các doanh nghiệp vay vốn tại các ngân hàng thương mại và các công ty niêm yết trên thị trường tài chính Việt Nam trong giai đoạn 2010-2022. Hiệu suất của các mô hình được đánh giá qua các chỉ số như điểm F1 và độ chính xác (ACC). Kết quả cho thấy Cây quyết định, XGBoost và ANN vượt trội hơn so với LR. Đặc biệt, ANN đạt điểm F1 là 0,756 và ACC là 0,9345 trên bộ dữ liệu xác thực, chứng minh khả năng dự báo xuất sắc. Phương pháp ANN có tiềm năng lớn trong việc nhận diện khách hàng có rủi ro vỡ nợ cao, giúp tối ưu hóa quy trình quản

Predicting default risk for small and medium enterprises in Vietnam using machine learning models

Abstract: This study develops a model for predicting default risk (DR) for small and medium-sized enterprises (SMEs) in Vietnam using machine learning methods such as Logistic Regression (LR), Decision Trees, XGBoost, and Artificial Neural Networks (ANN). The data is collected from the financial statements of enterprises borrowing from commercial banks and companies listed on the Vietnamese financial market from 2010 to 2022. The performance of the models is evaluated using metrics such as the F1 score and accuracy (ACC). Results show that Decision Trees, XGBoost, and ANN outperform LR. Specifically, ANN achieves an F1 score of 0.756 and an ACC of 0.9345 on the validation dataset, demonstrating excellent predictive capability. The ANN method has significant potential in identifying high-risk customers, thereby optimizing the credit risk management process. The study also identifies key predictive variables, providing insights for developing more effective DR models. Future research could apply advanced hyperparameter tuning techniques and expand the feature set to optimize the model further.

Keywords: Default risk, Decision tree, XGBoost, Artificial Neural Networks (ANN)

DOI: 10.59276/JELB.2024.07CD.2762

Nguyen, Minh Nhat¹, Ngo, Hoang Khanh Duy²

Organization of all: Ho Chi Minh University of Banking, Vietnam

Email: nhatnm@hub.edu.vn¹, ngohoangkhanhduy.work@gmail.com²

lý rủi ro tín dụng. Nghiên cứu cũng xác định được các biến dự báo chính, cung cấp cái nhìn sâu sắc để phát triển mô hình RRVN hiệu quả hơn. Tương lai, các nghiên cứu có thể áp dụng kỹ thuật điều chỉnh hyperparameter tiên tiến và mở rộng bộ đặc trưng để tối ưu hóa mô hình.

Từ khóa: Rủi ro vỡ nợ, Cây quyết định, XGBoost, Mạng Nơ-ron nhân tạo

1. Đặt vấn đề

Trong lĩnh vực quản lý rủi ro tín dụng hiện đại, dự báo rủi ro vỡ nợ (RRVN) là yếu tố thiết yếu đối với các tổ chức tài chính và ngân hàng để phân tích và đánh giá năng lực tài chính của khách hàng vay. Việc này không chỉ giúp ước lượng mức lãi suất thích hợp mà còn trong việc thiết lập điều kiện cho vay và quản lý danh mục đầu tư một cách hiệu quả. Rủi ro vỡ nợ còn là yếu tố quan trọng trong đánh giá chất lượng tín dụng và là cơ sở cho các hoạt động định giá và xây dựng danh mục. Với bối cảnh kinh tế toàn cầu không ngừng biến động, việc dự báo chính xác rủi ro vỡ nợ của doanh nghiệp, đặc biệt là các doanh nghiệp nhỏ và vừa (SMEs) trở nên cấp thiết. Điều này giúp các ngân hàng thương mại tối ưu hóa quy trình quản lý rủi ro, giảm thiểu tổn thất và nâng cao hiệu quả hoạt động.

Hiện nay, mặc dù các phương pháp truyền thống như Phân tích Phân biệt Tuyến tính (LDA) và Hồi quy Logistic (LR) vẫn được sử dụng rộng rãi do tính khả thi và độ tin cậy của chúng. Tuy nhiên, các phương pháp này có thể gặp hạn chế trong việc mô hình hóa các hệ thống tài chính phức tạp, khi các giả định thống kê có thể không hoàn toàn phù hợp với bối cảnh phát triển mạnh mẽ của khoa học dữ liệu. Ngược lại, học máy đã được chứng minh là công cụ hiệu quả hơn trong phân tích và đánh giá tín dụng (Cowden & cộng sự, 2019). Các phương pháp như Kỹ thuật Láng Giềng Gần Nhất (KNN), Máy Vector Hỗ Trợ (SVM), Cây

Quyết Định (DT), và Mạng Nơ-ron Nhân Tạo (ANN) đã được áp dụng để nâng cao độ chính xác trong dự đoán rủi ro vỡ nợ. Các mạng nơ-ron này, với khả năng trích xuất đặc trưng và thu thập thông tin phức tạp từ các lớp ẩn, đã chứng minh hiệu quả vượt trội so với các kiến trúc máy học truyền thống trong việc đánh giá rủi ro tín dụng. Nghiên cứu gần đây cũng chỉ ra rằng phân loại tập hợp, một kỹ thuật học máy kết hợp nhiều bộ phân loại, cung cấp cải tiến đáng kể về độ chính xác và ổn định so với việc sử dụng một bộ phân loại duy nhất trong dự báo RRVN (Song & cộng sự, 2023).

Tại Việt Nam, ứng dụng của học máy trong dự báo rủi ro vỡ nợ doanh nghiệp còn gặp nhiều thách thức do sự hạn chế về mặt dữ liệu cũng như phương pháp nghiên cứu. Nghiên cứu này khám phá tiềm năng của các mô hình học máy, đặc biệt là Mạng Nơ-ron Nhân Tạo và các thuật toán tăng cường, trong việc cải thiện khả năng dự báo rủi ro tín dụng của các doanh nghiệp SMEs vay vốn tại các ngân hàng thương mại (NHTM) ở Việt Nam. Nghiên cứu cũng so sánh hiệu quả dự báo vỡ nợ giữa các thuật toán học máy hiện đại và mô hình thống kê truyền thống, từ đó đề xuất bộ đặc trưng quan trọng và hướng tiếp cận mới trong phân tích và đánh giá rủi ro tín dụng. Các mô hình dự báo được xây dựng và kiểm định trên bộ dữ liệu được thu thập từ báo cáo tài chính của các doanh nghiệp SMEs vay vốn tại các NHTM và các công ty niêm yết trên thị trường tài chính Việt Nam trong giai đoạn 2010-2022.

Cấu trúc của bài nghiên cứu được trình bày như sau: Phần 2 cung cấp một cái nhìn tổng quan lý thuyết về các phương pháp dự báo rủi ro vỡ nợ; Phần 3 mô tả phương pháp nghiên cứu và bộ dữ liệu được sử dụng; Phần 4 trình bày chi tiết kết quả thu được từ nghiên cứu; và phần 5 đưa ra kết luận và góp ý dựa trên kết quả nghiên cứu.

2. Khảo lược lý thuyết về các phương pháp dự báo rủi ro vỡ nợ

Sự phát triển nhanh chóng trong lĩnh vực quản lý rủi ro tín dụng đã thu hút sự quan tâm đáng kể từ cộng đồng nghiên cứu và các nhà quản lý. Nhiều nghiên cứu so sánh các công nghệ tiên tiến như mạng nơ-ron, thuật toán di truyền với các kỹ thuật thống kê truyền thống, nhấn mạnh tầm quan trọng của việc tích hợp các công cụ đánh giá tín dụng hiện đại vào thực tiễn (Chang & Yeh, 2012; Crook, Edelman, & Thomas, 2007; Kumar & Ravi, 2007). Các phát hiện này cung cấp bằng chứng cho sự cần thiết phải cập nhật các phương pháp đánh giá tín dụng trong ngành ngân hàng và tài chính.

Oreski và cộng sự (2012) đã kết hợp thuật toán di truyền với mạng nơ-ron để cải thiện độ chính xác trong đánh giá điểm tín dụng, cho thấy hiệu quả đáng kể trong việc xác định các đặc trưng quan trọng liên quan đến rủi ro mặc định. Wang & cộng sự (2018) đề xuất một phương pháp lai hai giai đoạn, kết hợp phương pháp lọc và thuật toán di truyền đa quần thể (HMPGA), chứng minh khả năng cải thiện việc xác định các yếu tố ảnh hưởng đến điểm tín dụng. He & cộng sự (2018) trình bày kỹ thuật lựa chọn bộ phân loại dựa trên thuật toán di truyền, tích hợp kỹ thuật phân cụm không giám sát và thủ tục gán mờ, nâng cao hiệu quả phân loại.

Trong nghiên cứu về mạng nơ-ron nhân tạo (ANN), Teles & cộng sự (2020) so sánh hiệu quả của ANN và mạng Bayesian trong

dự đoán rủi ro tín dụng, với ANN vượt trội hơn với độ chính xác trung bình 85%. Ayed & Bougatef (2023) so sánh hiệu suất của bốn mô hình xếp hạng tín dụng gồm hồi quy logistic (LR), mạng nơ-ron nhân tạo (ANN), hệ thống suy diễn mờ (FIS), và hệ thống suy diễn mờ thích ứng thần kinh (ANFIS), cho thấy ANFIS và LR có khả năng phân biệt cao nhất với AUC đạt 0,9.

Các nghiên cứu áp dụng nhóm mô hình học máy Cây quyết định cũng đạt được kết quả tích cực. Chang & cộng sự (2016) đề xuất mô hình đánh giá rủi ro tín dụng ngắn hạn dựa trên Cây quyết định, sử dụng phương pháp tổng hợp bootstrap (Bagging) và kỹ thuật lấy mẫu quá mức của thiểu số tổng hợp (SMOTE), cho thấy tỷ lệ nhận dạng và độ chính xác vượt trội. Sigrist & Hirschall (2019) giới thiệu mô hình Grabit, kết hợp kỹ thuật tăng cường cây Gradient vào mô hình Tobit, cải thiện hiệu suất dự đoán vỡ nợ của SMEs. Madaan và cộng sự (2021) so sánh giữa Rừng Ngẫu nhiên và Cây Quyết định, kết luận rằng Rừng Ngẫu nhiên có độ chính xác cao hơn. Guo & Zhou (2022) áp dụng các thuật toán cây quyết định như RF, XGBoost, AdaBoost, CatBoost, và LightGBM để chọn lọc thuộc tính và dự đoán vỡ nợ, với XGBoost, AdaBoost, và CatBoost thể hiện tốt nhất.

Trong nhóm các mô hình dựa trên cây quyết định, XGBoost đang nổi lên như một công cụ hiệu quả với tốc độ xử lý nhanh chóng và độ chính xác cao. Theo nghiên cứu của Memon & cộng sự (2019), XGBoost có tốc độ xử lý nhanh hơn và hiệu quả tương đương với ANN, với độ chính xác cao trên cả dữ liệu huấn luyện và kiểm thử. XGBoost tự động xử lý các tham số điều chỉnh, giảm thiểu nhu cầu can thiệp của người dùng và hoạt động dựa trên nguyên tắc tập hợp các cây tăng cường. Phương pháp này tương tự như Rừng Ngẫu nhiên nhưng áp dụng Gradient descent để tối ưu

hóa quá trình học. Các nghiên cứu của Muslim & Dasril (2021) và Dalal & cộng sự (2022) cũng có những kết luận tương tự.

Mô hình ANN và nhóm các mô hình dựa trên cây quyết định, điển hình là XGBoost, đều chứng minh tính hiệu quả trong việc phát hiện các khoản nợ có vấn đề. Tuy nhiên, việc so sánh giữa các phương pháp này vẫn còn nhiều hạn chế, cần có những nghiên cứu sâu hơn về mức độ hiệu quả giữa các phương pháp này.

3. Phương pháp nghiên cứu

3.1. Dữ liệu nghiên cứu

Trong khuôn khổ bài nghiên cứu nhằm phát triển mô hình đánh giá rủi ro vỡ nợ cho các doanh nghiệp SMEs tại Việt Nam, nhóm nghiên cứu đã thực hiện việc lựa chọn và thu thập dữ liệu tài chính của các doanh nghiệp SMEs có quy mô doanh thu trong năm không vượt quá 300 tỷ đồng. Các nguồn dữ liệu bao gồm báo cáo tài chính từ doanh nghiệp SMEs vay vốn tại các NHTM Việt Nam cũng như từ các công ty có quy mô phù hợp như trên đang hoạt động và niêm yết trên thị trường tài chính Việt Nam. Quá trình thu thập dữ liệu được thực hiện từ năm 2010 đến 2022, và tất cả thông tin liên quan đến các doanh nghiệp đã được mã hóa để đảm bảo tính bảo mật và tuân thủ đạo đức nghiên cứu.

Bên cạnh đó, nhóm nghiên cứu đã áp dụng khái niệm "phá sản kỹ thuật" để phân biệt giữa các doanh nghiệp có sức khỏe tài chính ổn định và các doanh nghiệp đang trong tình trạng rủi ro cao về tài chính trong dữ liệu nghiên cứu. "Phá sản kỹ thuật" được định nghĩa là tình trạng doanh nghiệp đối mặt với khó khăn trong việc thanh toán nợ hoặc gặp vấn đề tài chính nghiêm trọng mà chưa chính thức được tuyên bố phá sản bởi cơ quan pháp lý. Các tiêu chuẩn để xác định doanh nghiệp ở trạng thái phá sản kỹ thuật bao gồm có: vốn chủ sở hữu âm, tỷ lệ lợi nhuận trước lãi vay, thuế và khấu hao so với chi phí lãi vay (tỷ lệ EBITDA/I) nhỏ hơn một trong hai

Bảng 1. Bảng mô tả thống kê dữ liệu nghiên cứu

Thông tin mô tả	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_10	X_11	X_12	X_13	Biến mục tiêu
Số quan sát	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0	1200,0
Giá trị trung bình	0,2	-0,0	0,1	0,1	0,6	2,1	1,5	334,4	74,9	0,2	21,0	183,2	1,2	0,1
Độ lệch chuẩn	0,5	1,7	0,1	1,6	0,2	3,9	3,9	2900,4	1047,3	0,5	188,9	790,5	1,2	0,3
Giá trị nhỏ nhất	-1,3	-34,1	-0,8	-33,2	0,0	0,2	0,1	-140,9	-3042,9	0,0	0,0	-3847,2	-0,0	0,0
Tứ phân vị thứ nhất (25%)	0,1	0,0	0,0	0,0	0,4	1,1	0,5	1,4	0,1	0,0	1,8	31,9	0,4	0,0
Trung vị (50%)	0,1	0,0	0,0	0,1	0,6	1,3	0,8	3,7	0,4	0,1	3,8	69,6	0,9	0,0
Tứ phân vị thứ ba (75%)	0,2	0,1	0,1	0,2	0,7	2,1	1,4	18,2	1,1	0,3	8,8	159,6	1,5	0,0
Giá trị lớn nhất	18,2	40,8	0,9	16,7	1,8	67,1	67,1	77002,7	29094,3	4,3	5986,7	22564,7	10,6	1,0

Nguồn: Tính toán của nhóm tác giả

năm liên tục, lợi nhuận hoạt động âm liên tiếp ba năm và báo cáo từ công ty kiểm toán độc lập. Các doanh nghiệp thỏa mãn các điều kiện này được xem là có nguy cơ vỡ nợ và được gán nhãn là 1 trong khi các trường hợp khác được gán nhãn là 0. Bộ dữ liệu nghiên cứu với 13 biến đặc trưng được mô tả thống kê như Bảng 1.

Bộ dữ liệu gồm có 1.200 quan sát, trong đó 141 quan sát bị nghi ngờ vỡ nợ theo tiêu chuẩn phá sản kỹ thuật hoặc bị tuyên bố vỡ nợ sẽ được gán nhãn 1 và 1.059 quan sát nằm trong nhóm không bị vỡ nợ được gán nhãn 0. Dữ liệu được chia thành hai tập là tập huấn luyện (training data) và tập kiểm tra (testing data), với tỷ lệ lần lượt là 80% và 20%. Tỷ lệ này được lựa chọn để phù hợp với kích thước nhỏ của bộ dữ liệu. Tập huấn luyện được nhóm tác giả sử dụng để huấn luyện và tối ưu các tham số trong mô hình, trong khi đó tập kiểm tra được sử dụng để kiểm tra mức độ hiệu quả của các mô hình dự báo. Tiếp theo, nhóm tác giả đã sử dụng 13 đặc trưng quan trọng là các chỉ số tài chính của

doanh nghiệp (Bảng 2) để tạo thành các biến đầu vào trong việc xây dựng các mô hình dự báo vỡ nợ.

Nhóm tác giả đã sử dụng công cụ Python và các packages kèm theo để xử lý, phân tích dữ liệu và xây dựng mô hình, bao gồm Numpy, Pandas, Scikit-learning, Tensorflow và Seaborn.

3.2. Phương pháp hồi quy Logistic (LR)

Hồi quy Logistic là một thuật toán phân loại được sử dụng rộng rãi, mô hình hóa mối quan hệ giữa các biến độc lập và kết quả nhị phân. Sau khi áp dụng lớp LogisticRegression từ thư viện máy học scikit-learn, quá trình huấn luyện mô hình bắt đầu bằng việc thực hiện chuẩn bị dữ liệu bao gồm mã hóa one-hot và chọn lọc các đặc trưng quan trọng để tạo điều kiện thuận lợi cho việc huấn luyện mô hình. Việc tinh chỉnh các hyperparameter từ tham số điều chỉnh (C), phương pháp phạt, và loại solver đã được thực hiện một cách cẩn thận để tối

Bảng 2. Các biến đặc trưng trong mô hình dự báo xác suất vỡ nợ

Các biến đặc trưng	Các chỉ số tài chính	Nhóm chỉ số tài chính	Kỳ vọng về dấu
X1	Lợi nhuận gộp/Doanh thu thuần	Khả năng sinh lời	-
X2	Thu nhập trước thuế/Doanh thu thuần	Khả năng sinh lời	-
X3	Thu nhập trước thuế/Tổng tài sản	Khả năng sinh lời	-
X4	Thu nhập trước thuế/Vốn chủ sở hữu	Khả năng sinh lời	-
X5	Tổng nợ phải trả/Tổng tài sản	Đòn bẩy tài chính	+
X6	Tài sản ngắn hạn/Nợ ngắn hạn	Khả năng thanh toán	-
X7	(Tài sản ngắn hạn - Hàng tồn kho)/ Nợ ngắn hạn	Khả năng thanh toán	-
X8	Lợi nhuận trước thuế và lãi vay/Lãi vay	Thanh toán lãi vay	-
X9	Thu nhập trước thuế, lãi vay và khấu hao/Nợ dài hạn	Thanh toán nợ dài hạn	-
X10	Tiền và các khoản tương đương tiền	Khả năng thanh toán	-
X11	Giá vốn hàng bán/ Hàng tồn kho bình quân	Hiệu quả hoạt động	+
X12	Các khoản phải thu/Doanh thu bình quân	Hiệu quả hoạt động	+
X13	Tổng doanh thu/Tổng tài sản	Hiệu quả hoạt động	-

Nguồn: Thống kê từ tác giả

ưu hóa hiệu suất của mô hình trên bộ dữ liệu. Phân tích hệ số thu được từ mô hình Hồi quy Logistic đã cho thấy cái nhìn sâu sắc về mức độ quan trọng và hướng ảnh hưởng của từng đặc trưng đến khả năng mất khả năng thanh toán của doanh nghiệp (Khemais & cộng sự, 2016).

Hiệu suất của mô hình Hồi quy Logistic được đánh giá sử dụng các chỉ số đánh giá như diện tích dưới Đường cong ROC (AUC) và độ chính xác. AUC cung cấp một thước đo về khả năng của mô hình phân biệt giữa người vỡ nợ và không vỡ nợ. Độ chính xác, so sánh nhãn dự đoán với nhãn thực tế, xác định hiệu suất phân loại tổng thể. Các chỉ số này được tính toán cho cả tập huấn luyện và kiểm định, cung cấp một hiểu biết toàn diện về hiệu suất của mô hình.

3.3. Phương pháp dự báo dựa trên Cây quyết định

Thuật toán Cây Quyết Định (Decision Tree) đóng vai trò như một công cụ phân tích định lượng mạnh mẽ, được triển khai một loạt quy tắc để phân chia tập dữ liệu gốc thành các phân khúc đồng nhất dựa trên thuộc tính và kết quả dự báo. Qua quá trình khai thác dữ liệu, thuật toán này phát triển dựa trên các quy tắc phân loại thể hiện qua cấu trúc cây, nơi mỗi nút đại diện cho một quyết định dựa trên một thuộc tính cụ thể. Kết quả là việc hình thành các nhóm phân loại với tính đồng nhất cao từ đó phản ánh tỷ lệ rủi ro vỡ nợ của mỗi nhóm. Mô hình này nổi bật với khả năng trực quan hóa và diễn giải, tuy nhiên nó dễ gặp phải vấn đề quá mức khớp (overfitting) làm giảm hiệu suất dự báo trên tập dữ liệu không được huấn luyện. Để giải quyết hạn chế này, kỹ thuật Rừng Ngẫu Nhiên và Tăng Cường (Gradient Boosting) được áp dụng như là các biện pháp hiệu quả nhằm tối ưu hóa

mô hình và tránh hiện tượng quá khớp, qua đó cải thiện độ chính xác và khả năng khái quát hóa của mô hình khi áp dụng trên dữ liệu mới (Memon & cộng sự, 2019).

Bên cạnh đó, XGBoost là một thuật toán tăng cường gradient mạnh mẽ được biết đến với hiệu suất cao và hiệu quả trong nhiều nhiệm vụ học máy. Trong quá trình phân tích, XGBoost đã được triển khai sử dụng lớp XGBClassifier từ thư viện XGBoost. Trước khi huấn luyện mô hình XGBoost, bộ dữ liệu đã trải qua các bước tiền xử lý, bao gồm việc mã hóa các biến phân loại và lựa chọn đặc trưng. Các hyperparameter như số lượng ước lượng, tốc độ học, độ sâu tối đa, và các tham số điều chỉnh được điều chỉnh cẩn thận để tối ưu hóa hiệu suất của mô hình. Mô hình XGBoost sau đó được huấn luyện trên bộ dữ liệu đã chuẩn bị. Trong quá trình huấn luyện, XGBoost lặp đi lặp lại xây dựng một tập hợp các cây quyết định yếu, tối ưu hóa một hàm mục tiêu cụ thể để giảm thiểu mất mát. Bằng cách kết hợp các dự đoán của nhiều người học yếu, mô hình cải thiện khả năng dự đoán của mình. Để có cái nhìn sâu sắc về tầm quan trọng tương đối của mỗi đặc trưng trong mô hình XGBoost, điểm số quan trọng của đặc trưng sau đó được trực quan hóa. Việc trực quan hóa này giúp nhận diện những đặc trưng có ảnh hưởng lớn nhất trong việc dự đoán khả năng không trả nợ của người vay. Hiệu suất của mô hình XGBoost được đánh giá sử dụng các chỉ số đánh giá tương tự như được sử dụng cho Hồi quy Logistic, bao gồm AUC và độ chính xác. Các chỉ số này được tính toán cho cả tập dữ liệu huấn luyện và kiểm định, cung cấp một đánh giá về khả năng tổng quát hóa của mô hình.

3.4. Phương pháp dự báo dựa trên Mạng No-ron nhân tạo (ANN)

Mô hình ANN thường được xây dựng với

ít nhất hai lớp nơ-ron nổi bật với khả năng xử lý thông tin không hoàn chỉnh và duy trì hiệu suất ổn định ngay cả khi có sự cố hoặc nhiễu trong dữ liệu. Cấu trúc của ANN gồm ba lớp cơ bản: lớp đầu vào, lớp ẩn và lớp đầu ra phản ánh cấu trúc tổ chức của mạng nơ-ron trong não bộ (Nur Ozkan-Gunay & Ozkan, 2007). Lớp đầu vào chịu trách nhiệm tiếp nhận và xử lý dữ liệu ban đầu, trong khi lớp ẩn thể hiện sự tương tác giữa nơ-ron đầu vào và đầu ra, cung cấp khả năng đưa ra dự đoán hoặc phân loại dựa trên dữ liệu được cung cấp. Cuối cùng, lớp đầu ra biểu diễn kết quả cuối cùng của mô hình, có thể ứng dụng trong dự đoán tình trạng vỡ nợ, là một vấn đề quan trọng trong phân tích tài chính.

Cấu trúc của mô hình Mạng Nơ-ron Nhân Tạo (ANN) được cấu thành từ nhiều lớp nơ-ron, mỗi lớp chứa một số đơn vị nơ-ron cụ thể và được xác định bởi một hàm kích hoạt đặc trưng. Quá trình thiết kế mô hình bao gồm việc xác định số lượng lớp, số lượng nơ-ron trong mỗi lớp, và loại hàm kích hoạt, tùy thuộc vào đặc điểm của bộ dữ liệu và mục tiêu nghiên cứu, cũng như thông qua phương pháp thử nghiệm và đánh giá hiệu suất mô hình. Trước khi tiến hành huấn luyện mô hình ANN, bộ dữ liệu cần trải qua quá trình tiền xử lý kỹ lưỡng, bao gồm việc chuẩn hóa các đặc trưng sử dụng kỹ thuật chuẩn hóa Min-Max. Việc này nhằm mục đích đồng nhất thang đo của dữ liệu đầu vào, từ đó nâng cao hiệu quả

hội tụ của mô hình trong quá trình huấn luyện. Bộ dữ liệu chuẩn bị được chia thành hai tập: tập huấn luyện và tập kiểm định, để mô hình có thể được huấn luyện một cách hiệu quả và đánh giá chính xác khả năng dự đoán.

Quá trình huấn luyện mô hình ANN bao gồm việc điều chỉnh trọng số và độ lệch của các nơ-ron nhằm giảm thiểu hàm mất mát và cải thiện độ chính xác trong dự đoán. Hiệu suất của mô hình được kiểm định kỹ lưỡng thông qua việc sử dụng các chỉ số đánh giá như tỷ lệ mất mát và độ chính xác, áp dụng cả trên tập huấn luyện và tập kiểm định. Phương pháp này cho phép nhà nghiên cứu đánh giá toàn diện và khách quan hiệu quả của mô hình trong việc dự đoán và phân tích tài chính, đồng thời cung cấp cơ sở để tinh chỉnh mô hình nhằm đạt được kết quả tối ưu.

3.5. Các tiêu chí đo lường khả năng dự báo rủi ro vỡ nợ của mô hình

Để đánh giá mức độ phù hợp của các mô hình dự báo xác suất vỡ nợ, một vài kỹ thuật được sử dụng như ma trận nhầm lẫn (Confussion Matrix), độ chính xác (Accuracy), Tỷ lệ precision (Precision), tỷ lệ nhạy cảm (recall), tỷ lệ Specificity (Specificity), AUC (diện tích dưới đường cong ROC) và điểm F1 (F1- score). Dưới đây là mô tả chi tiết về các chỉ số đó:

Bảng 3. Ma trận nhầm lẫn

		Predicted label (mô hình dự báo)	
		Các lớp	Không vỡ nợ (Non-default = 0)
True label (dữ liệu thực tế)	Không vỡ nợ (Non-default = 0)	True Negative (TN) Mô hình dự báo doanh nghiệp không vỡ nợ và thực tế cũng không vỡ nợ	False Positive (FP) Mô hình dự báo sẽ vỡ nợ nhưng thực tế doanh nghiệp không vỡ nợ
	Vỡ nợ (default = 1)	False Negative (FN) Mô hình dự báo doanh nghiệp không vỡ nợ nhưng thực tế lại vỡ nợ.	True Positive (TP) Mô hình dự báo doanh nghiệp sẽ vỡ nợ và thực tế cũng vậy.

Nguồn: Tổng hợp từ tác giả

(i) Ma trận nhầm lẫn (Confusion matrix)
Ma trận nhầm lẫn là công cụ thống kê mạnh mẽ trong lĩnh vực học máy đóng vai trò thiết yếu trong việc đánh giá hiệu suất của các mô hình phân loại. Bằng cách cung cấp một cái nhìn tổng quan về số lượng phân loại chính xác và sai lệch, ma trận này cho phép phân tích chi tiết hiệu quả phân loại của mô hình từ đó giúp xác định điểm mạnh và điểm yếu cụ thể của mô hình trong từng trường hợp phân loại. So sánh giữa giá trị dự đoán và giá trị thực tế qua ma trận nhầm lẫn không chỉ giúp nhận diện khả năng dự báo chính xác của mô hình trong lĩnh vực tài chính đặc biệt là trong dự báo xác suất

vỡ nợ của doanh nghiệp mà còn hỗ trợ việc tinh chỉnh mô hình nhằm tối ưu hóa khả năng phân loại và quản lý rủi ro tín dụng một cách hiệu quả. Ma trận nhầm lẫn được mô tả cụ thể trong Bảng 3.

(ii) Các chỉ số đo lường khác: Accuracy, Precision, Recall, Specificity, F1 score, AUC

4. Kết quả nghiên cứu

4.1. Kết quả so sánh về khả năng dự báo của các mô hình

Kết quả được trình bày trong Bảng 4 không chỉ minh họa sự vượt trội của các

Bảng 4. Các nhóm chỉ số để đánh giá mức độ tin cậy của một mô hình

Chỉ số	Định nghĩa	Công thức
Độ chính xác (Accuracy - ACC)	Độ chính xác của mô hình đánh giá khả năng phân loại đúng giữa các doanh nghiệp vỡ nợ và không vỡ nợ	$Accuracy = (TN + TP) / (TN + FN + TP + FP)$
Tỷ lệ precision (Precision)	Tỷ lệ này cho biết phần trăm các doanh nghiệp được dự báo vỡ nợ một cách chính xác so với tổng số doanh nghiệp dự báo sẽ vỡ nợ.	$Precision = TP / (TP + FP)$
Tỷ lệ đo lường mức độ nhạy cảm của mô hình (recall)	Recall, còn được gọi là tỷ lệ nhận dạng đúng, là chỉ số đánh giá tỷ lệ các trường hợp vỡ nợ được mô hình dự đoán chính xác so với tổng số trường hợp vỡ nợ thực tế. Một Recall cao báo hiệu rằng mô hình có khả năng phát hiện phần lớn các trường hợp vỡ nợ, giúp giảm thiểu việc bỏ qua những cá nhân hoặc doanh nghiệp có khả năng rủi ro cao, điều này rất quan trọng trong quản lý rủi ro tín dụng.	$Recall = TP / (TP + FN)$
Tỷ lệ specificity (specificity)	Chỉ số này đánh giá khả năng của mô hình trong việc chính xác nhận diện các doanh nghiệp không rơi vào tình trạng vỡ nợ. Chỉ số được tính bằng cách lấy tỷ lệ các doanh nghiệp được dự báo không vỡ nợ một cách chính xác so với tổng số doanh nghiệp thực tế không vỡ nợ.	$Specificity = TN / (TN + FP)$
Điểm số F1 (F1-Score)	F1-Score là chỉ số tổng hợp từ Precision (tỷ lệ dự đoán chính xác) và Recall (tỷ lệ phát hiện đúng), mang lại cái nhìn toàn diện về hiệu quả của mô hình phân loại. Precision tính toán tỷ lệ của những dự đoán tích cực được xác định đúng, trong khi Recall đánh giá khả năng của mô hình trong việc xác định tất cả các trường hợp tích cực thật sự. Một F1-Score cao cho thấy mô hình không chỉ phát hiện chính xác nhiều trường hợp vỡ nợ mà còn giữ tỷ lệ lỗi thấp, biểu thị khả năng cân bằng tốt giữa độ chính xác và độ nhạy của mô hình.	$F1\ Score = 2 \times (Precision \times Recall) / (Precision + Recall)$
Diện tích dưới đường cong ROC (AUC)	AUC, viết tắt của "Area Under the Curve", là một chỉ số được sử dụng để đánh giá giá hiệu suất của các mô hình phân loại, dựa trên diện tích nằm dưới đường cong ROC và trên trục tỷ lệ phản hồi dương tính giả (FPR). Chỉ số AUC dao động từ 0 đến 1, trong đó một giá trị AUC cao cho thấy khả năng phân biệt tốt giữa các lớp của mô hình. Một AUC bằng 1 chỉ ra rằng mô hình đạt hiệu quả tối ưu, không có lỗi phân loại, còn một giá trị gần với 0 báo hiệu hiệu suất phân loại là kém.	

Nguồn: Tổng hợp từ tác giả

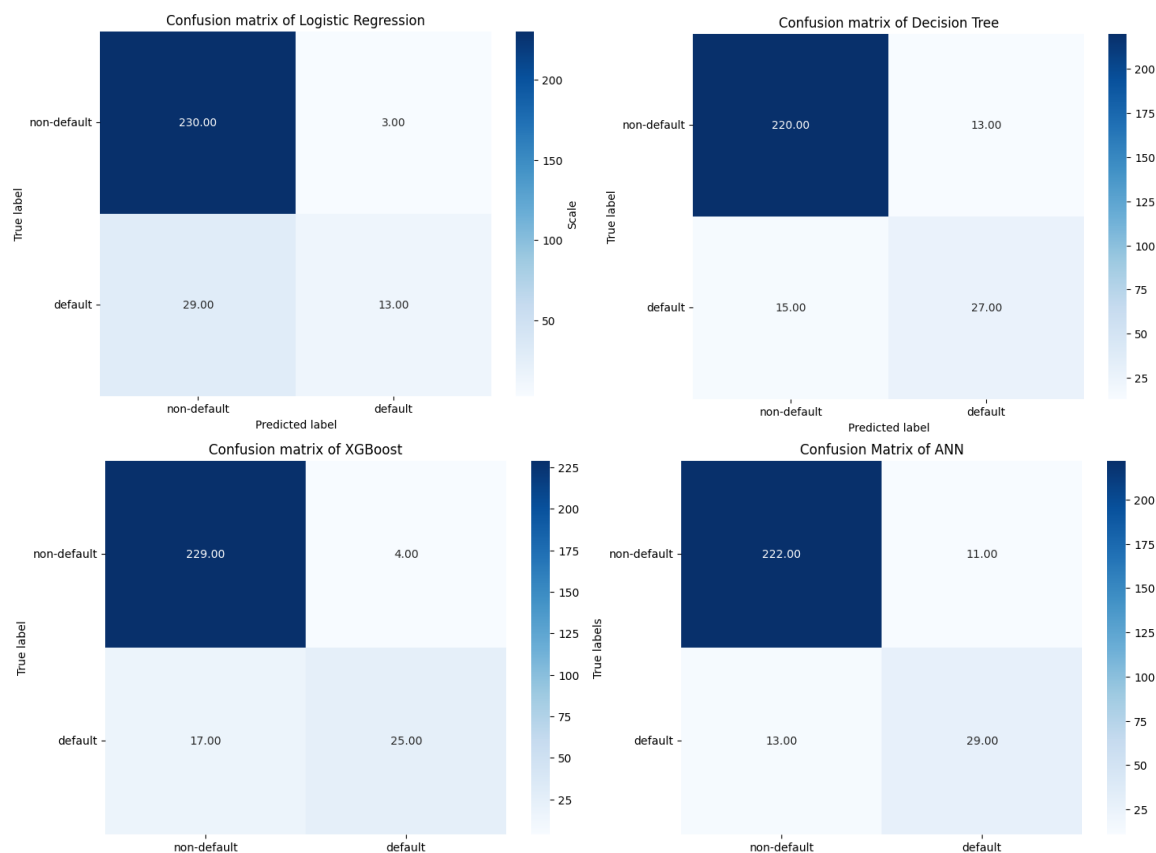
Bảng 5. Kết quả dự báo vỡ nợ của các mô hình trên tập dữ liệu ngoài mẫu

	Thuật toán	Diện tích dưới đường cong ROC (AUC)	Độ chính xác (Accuracy)	Tỷ lệ Precision (Precision)	Tỷ lệ đo lường mức độ nhạy cảm của mô hình (Recall)	Tỷ lệ Specificity (Specificity)	Điểm số F1 (F1 score)
1	Hồi quy Logistic (LR)	0,86	0,88	0,81	0,31	0,98	0,45
2	Cây quyết định (Decision Tree)	0,76	0,89	0,69	0,57	0,95	0,62
3	Tăng cường Gradient (XGBoost)	0,95	0,92	0,86	0,59	0,98	0,70
4	Mạng Nơ-ron Nhân tạo (ANN)	0,91	0,93	0,87	0,67	0,98	0,76

Nguồn: Thống kê từ tác giả

thuật toán học máy như XGBoost và Mạng Nơ-ron Nhân Tạo (ANN) so với mô hình Logistic truyền thống trong việc dự báo rủi ro vỡ nợ, mà còn nhấn mạnh tiềm năng ứng dụng của chúng trong lĩnh vực quản lý rủi ro và phân tích tài chính. Sự vượt trội của XGBoost được chứng minh thông qua chỉ số F1 Score cao hơn, thể hiện không chỉ khả năng dự báo chính xác mà còn phản ánh sự cân bằng giữa Recall (độ nhạy) và Precision (độ chính xác) của mô hình. Điều này rất quan trọng trong các ứng dụng có chi phí liên quan đến dự báo sai lệch cao. Đối với hai chỉ số toàn diện nhất là độ chính xác và điểm F1, phương pháp nổi bật nhất là ANN với độ chính xác vượt mốc 93%, theo sau đó là phương pháp XGBoost với độ chính xác gần ngang bằng, đạt khoảng 92%. Kết quả này minh chứng cho khả năng hiệu quả của các thuật toán học tập hợp trong việc ứng dụng vào dự báo rủi ro vỡ nợ trong thực tiễn. Tuy nhiên, Hồi quy Logistic (LR) và Cây Quyết định thể hiện mức độ hiệu quả kém hơn khi áp dụng vào đánh giá rủi ro vỡ nợ. Việc ưu tiên sử dụng ANN và XGBoost không chỉ dựa trên độ chính xác cao mà còn nhờ khả năng xử lý dữ liệu phức tạp. Về chỉ số Precision, ANN tiếp tục thể hiện sự vượt trội với tỷ lệ dự đoán chính xác vượt qua 87%. Bên cạnh đó, cả XGBoost

và Hồi quy Logistic (LR) cũng ghi nhận giá trị Độ chính xác trên 80%, điều này chỉ ra rằng LR và XGBoost đều có tính ứng dụng khả quan trong việc xây dựng mô hình dự báo khả năng vỡ nợ. Tuy nhiên, các phương pháp dựa trên mô hình Cây Quyết định có vẻ như không thích hợp, do khả năng phân loại kém hơn trong bối cảnh cụ thể này. Qua đó, ứng dụng ANN, XGBoost, và LR trong mô hình dự báo rủi ro vỡ nợ mang lại hiệu quả dự đoán cao, phản ánh khả năng phân biệt đúng đắn giữa trường hợp vỡ nợ và không vỡ nợ. Đối với chỉ số recall, các phương pháp Cây quyết định và mô hình XGBoost đều ở khoảng 60%, với LR thể hiện hiệu suất rõ rệt kém hơn. Điều này có nghĩa là trong trường hợp của LR, các tiêu chí đánh giá khả năng vỡ nợ quá thận trọng dẫn đến việc giảm thiểu rủi ro vỡ nợ một cách không hiệu quả. Tuy nhiên, ANN lại cho thấy hiệu suất tốt nhất đối với chỉ số này ở mức trên 67%. Điều này cung cấp một cái nhìn sâu sắc vào ưu thế của ANN trong việc cải thiện khả năng dự báo rủi ro vỡ nợ, qua đó góp phần nâng cao chất lượng quyết định tín dụng. Sự vượt trội của ANN so với LR và các phương pháp khác trong việc xử lý các mô hình dữ liệu phức tạp và không tuyến tính là yếu tố then chốt dẫn đến hiệu quả này. XGBoost và ANN đều là những thuật toán



Nguồn: Thống kê từ tác giả

Hình 1. Kết quả dự báo của các mô hình trên ma trận nhầm lẫn

học máy tiên tiến được phát triển nhằm mục đích giải quyết các bài toán phức tạp thông qua việc học sâu từ dữ liệu. Cả hai thuật toán này đều hiệu quả trong việc xử lý dữ liệu phi tuyến và mang tính phức tạp cao, cho phép họ phát hiện ra các mối liên hệ giữa biến đầu vào và đầu ra mà không yêu cầu giả định cố định về mô hình nền tảng. Tuy nhiên, qua phân tích chi tiết, ANN cho thấy sự ưu việt với điểm số F1 đạt 76%, vượt trội so với XGBoost và đáng chú ý là hơn hẳn so với Hồi quy Logistic chỉ ở mức 45%. Sự vượt trội của thuật toán ANN không chỉ được thể hiện qua khả năng dự báo chính xác mà còn qua khả năng cân bằng hiệu quả giữa việc nhận diện đúng các trường hợp vỡ nợ và giảm thiểu các sai sót, từ đó khẳng định vị thế vượt trội trong lĩnh vực dự báo vỡ nợ so với các phương pháp

khác. Điều này không chỉ nâng cao giá trị ứng dụng thực tiễn của học máy trong quản lý rủi ro, mà còn chứng minh tiềm năng mạnh mẽ của nó trong việc cải thiện quyết định tài chính và tối ưu hóa công tác quản lý rủi ro vỡ nợ, góp phần vào việc nâng cao hiệu quả và độ chính xác trong quản lý rủi ro tài chính tại các tổ chức.


Về hiệu quả dự báo vỡ nợ của các mô hình phân loại cho thấy XGBoost đạt hiệu suất cao nhất với AUC 0,95, chỉ ra khả năng rất hiệu quả trong việc phân biệt các trường hợp tích cực và tiêu cực. Mặt khác, mô hình Decision Tree có AUC thấp nhất là 0,76, phản ánh mức độ phân biệt kém hơn so với các mô hình khác. Logistic Regression và ANN cũng thể hiện hiệu quả tốt với AUC lần lượt là 0,86 và 0,91.

Sự khác biệt trong AUC giữa các mô hình

cho thấy ảnh hưởng đáng kể của lựa chọn thuật toán đối với khả năng tổng thể của mô hình trong việc xử lý dữ liệu không cân bằng. XGBoost và ANN, với AUC cao, cung cấp sự cân bằng tốt hơn giữa độ nhạy và độ chính xác tổng thể, trong khi Decision Tree, mặc dù có độ chính xác cao, lại thiếu đi sự nhạy bén cần thiết để xác định chính xác các trường hợp tích cực. Điều này củng cố lựa chọn XGBoost hoặc ANN cho các ứng dụng yêu cầu độ chính xác cao trong dự báo hành vi tín dụng.

Trong quá trình phân tích ma trận nhầm lẫn của các phương pháp dự báo hiện được minh họa qua Hình 1, có thể nhận thấy rằng mỗi mô hình có những ưu điểm nổi bật cùng với một số hạn chế cụ thể. Phân tích cụ thể cho thấy mô hình LR và XGBoost đã cho kết quả dự báo rất tốt trong việc dự đoán các trường hợp không vỡ nợ với tổng số dự đoán chính xác lên đến 230 doanh

nh nghiệp, số lượng này nổi bật hơn so với mô hình ANN, Cây quyết định lần lượt là 222 và 220 doanh nghiệp. Tuy nhiên, điểm khác biệt đáng chú ý giữa các mô hình nằm ở khả năng phát hiện những trường hợp vỡ nợ: mô hình Logistic hoạt động kém hiệu quả nhất khi chỉ nhận diện được 13 doanh nghiệp vỡ nợ trên bộ dữ liệu kiểm định, trong khi đó mô hình ANN lại nổi bật với khả năng dự đoán chính xác 29 trường hợp và vượt trội hơn cả mô hình XGBoost và Cây quyết định với kết quả ít hiệu quả hơn và chỉ đạt mức lần lượt là 25 và 17 doanh nghiệp. Khi so sánh hiệu quả giữa các mô hình, Cây quyết định và ANN thường cho kết quả tốt hơn trong việc cả hai loại trường hợp trong khi Hồi quy Logistic thì tốt hơn trong việc dự đoán các trường hợp không vỡ nợ. Đối với mô hình XGBoost, mặc dù không chính xác bằng hai mô hình kể trên nhưng lại có ưu điểm về khả năng dự đoán



Nguồn: Thống kê từ tác giả

Hình 2. Kết quả ước lượng của các mô hình trong ước lượng PD

tác quản lý rủi ro trong lĩnh vực tín dụng.

4.2. Kết quả phân tích mức độ quan trọng của các biến

Hình 2 thể hiện hệ số hồi quy của các biến trong mô hình LR, hệ số của biến X₁₃ bật lên với trị số rất cao so với các biến khác, điều này chỉ ra rằng biến này có ảnh hưởng đặc biệt mạnh mẽ tới khả năng dự đoán vỡ nợ trong mô hình. Điều này cũng ám chỉ rằng các nhà quản lý rủi ro tài chính cần phải chú trọng đặc biệt tới biến này khi phân tích và đánh giá rủi ro vỡ nợ của khách hàng. Biến X₂ cũng thể hiện hệ số hồi quy đáng kể, nhưng không mạnh mẽ bằng X₁₃, cho thấy nó cũng có vai trò trong việc định hình kết quả, nhưng không lớn như biến X₁₃.

Mô hình Cây quyết định và XGBoost cung cấp một cái nhìn khác biệt về mức độ quan trọng của các biến, với biến X₃ được cả hai mô hình đánh giá là có mức độ quan trọng nhất. Sự nhất quán này giữa hai mô hình củng cố thêm giả thiết rằng biến X₃ có tầm ảnh hưởng đáng kể tới kết quả dự đoán và nên được cân nhắc nghiêm túc khi xây dựng các mô hình dự đoán rủi ro tài chính. Tuy nhiên, trong mô hình ANN, biến X₁₂ lại nổi bật lên với mức độ quan trọng cao nhất, điều này cho thấy ANN có cách tiếp cận và đánh giá dữ liệu khác biệt, có khả năng phát hiện ra những mối liên kết phức tạp mà có thể các mô hình khác không thể nắm bắt được.

So sánh giữa các mô hình, có thể thấy rằng mỗi mô hình mang lại một góc nhìn riêng biệt về mức độ ảnh hưởng của các biến tới khả năng dự đoán vỡ nợ. Cây quyết định và XGBoost tập trung vào X₃, trong khi ANN lại cho kết quả rằng X₁₂ là biến quan trọng nhất. Điều này cung cấp một hướng tiếp cận đa chiều trong việc đánh giá và quản lý rủi ro vỡ nợ, yêu cầu các

tổ chức tài chính phải đa dạng hóa phương pháp phân tích của mình để có cái nhìn đầy đủ và chính xác hơn. Đồng thời, điều này cũng đặt ra yêu cầu về việc xây dựng mô hình dự đoán phải linh hoạt và phản ánh đúng tính chất đa dạng của dữ liệu cũng như khả năng tương tác giữa các biến đầu vào trong vấn đề thực tiễn quản trị rủi ro.

Phân tích và xác định mức độ quan trọng của các biến trong mô hình dự báo đóng một vai trò thiết yếu không chỉ giúp tập trung vào những thông tin cốt lõi khi xây dựng mô hình mà còn hỗ trợ việc ứng dụng mô hình vào thực tiễn một cách hiệu quả. Qua đó, việc giải thích ảnh hưởng của từng biến đến kết quả dự báo trở nên minh bạch và dễ hiểu hơn góp phần vào việc tối ưu hóa quyết định và chiến lược kinh doanh dựa trên cơ sở dữ liệu vững chắc. Điều này không chỉ tăng cường sự tin cậy và chính xác của mô hình, mà còn mở rộng khả năng ứng dụng của nó trong việc phát triển các giải pháp quản lý rủi ro, chiến lược đầu tư và quyết định kinh doanh dựa trên bằng chứng qua đó đem lại lợi ích thiết thực cho các tổ chức và doanh nghiệp.

5. Kết luận

Trong nền kinh tế ngày càng phức tạp hiện nay, việc dự báo rủi ro vỡ nợ trở thành một phần không thể thiếu trong quy trình quản lý rủi ro của các tổ chức tài chính. Công việc này không chỉ giúp các ngân hàng và tổ chức tín dụng khác có thể đưa ra các quyết định vay mượn một cách thông minh mà còn giúp họ ước lượng mức độ rủi ro và xác định lãi suất cho vay một cách chính xác. Đồng thời, việc quản lý danh mục tín dụng một cách hiệu quả cũng góp phần giảm thiểu tổn thất tài chính và tối ưu hóa lợi nhuận cho các nhà đầu tư. Trong quá trình nghiên cứu, nhóm tác giả đã chọn lựa và sử dụng các mô hình học máy tiên

tiến như XGBoost và ANN, đồng thời dựa trên thuật toán cây quyết định để dự báo rủi ro vỡ nợ của doanh nghiệp vừa và nhỏ tại Việt Nam trong giai đoạn từ 2010 đến 2022. Qua việc so sánh hiệu suất dự đoán của mỗi mô hình, có thể nhận thấy rằng mô hình ANN là mô hình dự báo rủi ro vỡ nợ phù hợp nhất vì hiệu suất về khả năng dự đoán tốt hơn nhiều so với các mô hình Cây quyết định, XGBoost và phương pháp truyền thống sử dụng LR.

Qua đánh giá, mô hình ANN đã thể hiện sự vượt trội so với mô hình thống kê Logistic truyền thống cũng như các mô hình học máy thông thường thông qua các chỉ số đánh giá chính xác, như tỷ lệ chính xác, Precision, Recall, và đặc biệt là Điểm số F1, với mô hình Tăng cường tỏ ra có hiệu suất cao hơn cả. Phân tích cũng đã nêu bật được tầm quan trọng của việc chọn lựa các biến dự báo chính xác như hệ số biên lợi

nhuận, tỷ suất sinh lời trước thuế trên tổng tài sản, hệ số khả năng trả lãi, và hiệu suất sử dụng tài sản, nhằm nâng cao chất lượng và độ chính xác của mô hình dự báo RRVN. Kết quả nghiên cứu mở ra hướng mới trong việc áp dụng công nghệ học máy vào lĩnh vực tài chính đặc biệt là trong quản lý rủi ro và dự báo vỡ nợ đồng thời góp phần vào việc phát triển các phương pháp tiên tiến hơn cho ngành tài chính, ngân hàng.

Nghiên cứu cũng gặp phải những hạn chế, đặc biệt là liên quan đến quy mô và chất lượng của bộ dữ liệu. Bộ dữ liệu với mẫu dữ liệu nhỏ, đặc biệt là số lượng doanh nghiệp bị vỡ nợ trong dữ liệu tương đối thấp, có thể tác động đến kết quả nghiên cứu của các mô hình. Bên cạnh đó, các biến đặc trưng trong mô hình chỉ tập trung vào dữ liệu tài chính mà không tính đến các yếu tố phi tài chính điều này làm giảm tính toàn diện và chính xác của mô hình dự báo. ■

Tài liệu tham khảo

- Ayed, N., & Bougatef, K. (2023). *Performance Assessment of Logistic Regression (LR), Artificial Neural Network (ANN), Fuzzy Inference System (FIS) and Adaptive Neuro-Fuzzy System (ANFIS) in Predicting Default Probability: The Case of a Tunisian Islamic Bank*. *Computational Economics*, 1-33. <https://doi.org/10.1007/s10614-023-10496-y>
- Cowden, C., Fabozzi, F. J., & Nazemi, A. (2019). *Default prediction of commercial real estate properties using machine learning techniques*. *The Journal of Portfolio Management*, 45(7), 55-67. <https://doi.org/10.3905/jpm.2019.1.104>
- Chang, S. Y., & Yeh, T. Y. (2012). *An artificial immune classifier for credit scoring analysis*. *Applied Soft Computing*, 12(2), 611-618. <https://doi.org/10.1016/j.asoc.2011.11.002>
- Chang, Y. C., Chang, K. H., Chu, H. H., & Tong, L. I. (2016). *Establishing decision tree-based short-term default credit risk assessment models*. *Communications in Statistics-Theory and Methods*, 45(23), 6803-6815. <https://doi.org/10.1080/03610926.2014.968730>
- Crook, J. N., Edelman, D. B., & Thomas, L. C. (2007). *Recent developments in consumer credit risk assessment*. *European Journal of Operational Research*, 183(3), 1447-1465. <https://doi.org/10.1016/j.ejor.2006.09.100>
- Dalal, S., Seth, B., Radulescu, M., Secara, C., & Tolea, C. (2022). *Predicting fraud in financial payment services through optimized hyper-parameter-tuned XGBoost model*. *Mathematics*, 10(24), 4679. <https://doi.org/10.3390/math10244679>
- Guo, W., & Zhou, Z. Z. (2022). *A comparative study of combining tree-based feature selection methods and classifiers in personal loan default prediction*. *Journal of Forecasting*, 41(6), 1248-1313. <https://doi.org/10.1002/for.2856>
- He, H., Zhang, W., & Zhang, S. (2018). *A novel ensemble method for credit scoring: Adaption of different imbalance ratios*. *Expert Systems with Applications*, 98, 105-117. <https://doi.org/10.1016/j.eswa.2018.01.012>
- Khemais, Z., Nesrine, D., & Mohamed, M. (2016). *Credit scoring and default risk prediction: A comparative study between discriminant analysis & logistic regression*. *International Journal of Economics and Finance*, 8(4), 39. <http://dx.doi.org/10.5539/ijef.v8n4p39>
- Kumar, P. R., & Ravi, V. (2007). *Bankruptcy prediction in banks and firms via statistical and intelligent techniques—A review*. *European journal of operational research*, 180(1), 1-28. <https://doi.org/10.1016/j.ejor.2006.08.043>
- Madaan, M., Kumar, A., Keshri, C., Jain, R., & Nagrath, P. (2021). *Loan default prediction using decision trees and random forest: A comparative study*. In *IOP Conference Series: Materials Science and Engineering (Vol. 1022, No. 1, p. 012042)*. IOP Publishing. <https://doi.org/10.1088/1757-899X/1022/1/012042>

- Memon, N., Patel, S. B., & Patel, D. P. (2019, November). Comparative analysis of artificial neural network and XGBoost algorithm for PolSAR image classification. In *International Conference on Pattern Recognition and Machine Intelligence* (pp. 452-460). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-34869-4_49
- Muslim, M. A., & Dasril, Y. (2021). Company bankruptcy prediction framework based on the most influential features using XGBoost and stacking ensemble learning. *International Journal of Electrical and Computer Engineering (IJECE)*, 11(6), 5549-5557. <https://doi.org/10.11591/ijece.v11i6.pp5549-5557>
- Nur Ozkan-Gunay, E., & Ozkan, M. (2007). Prediction of bank failures in emerging financial markets: an ANN approach. *The Journal of Risk Finance*, 8(5), 465-480. <https://doi.org/10.1108/15265940710834753>
- Oreski, S., Oreski, D., & Oreski, G. (2012). Hybrid system with genetic algorithm and artificial neural networks and its application to retail credit risk assessment. *Expert systems with applications*, 39(16), 12605-12617. <https://doi.org/10.1016/j.eswa.2012.05.023>
- Sigrist, F., & Hirschall, C. (2019). Grabit: Gradient tree-boosted Tobit models for default prediction. *Journal of Banking & Finance*, 102, 177-192. <https://doi.org/10.1016/j.jbankfin.2019.03.004>
- Song, Y., Wang, Y., Ye, X., Zaretski, R., & Liu, C. (2023). Loan default prediction using a credit rating-specific and multi-objective ensemble learning scheme. *Information Sciences*, 629, 599-617. <https://doi.org/10.1016/j.ins.2023.02.014>