



DỰ BÁO BIẾN ĐỘNG VÀ RỦI RO CỰC ĐOẠN CỦA STABLECOIN: BẰNG CHỨNG TỪ USDT VỚI MÔ HÌNH GARCH-KNN VÀ ƯỚC LƯỢNG VAR-CVAR

TRẦN BÁ THUẤN¹

Tóm tắt

Nghiên cứu đề xuất khung lai GARCH-KNN được tối ưu hóa bằng GA-PSO nhằm dự báo biến động và rủi ro cực đoạn của stablecoin USDT trong thị trường tiền mã hóa. Dữ liệu được xử lý thông qua log-return, các chỉ báo kỹ thuật và PCA nhằm giảm chiều dữ liệu và hạn chế đa cộng tuyến. Kết quả thực nghiệm cho thấy mô hình GARCH-KNN vượt trội so với GARCH và KNN đơn lẻ với MAE = 0.0027, RMSE = 0.0087, $R^2 = 0.9507$ và QLIKE thấp, phản ánh độ chính xác dự báo cao. Mô hình đồng thời nắm bắt hiệu quả hiện tượng cụm biến động và cải thiện khả năng dự báo rủi ro. Các kết quả thực nghiệm cung cấp bằng chứng hỗ trợ cải thiện cơ chế giám sát thị trường, tối ưu hóa quản trị rủi ro và tăng cường ổn định tài chính trong bối cảnh thị trường biến động mạnh và bất định gia tăng.

Từ khóa: Dự báo biến động, Mô hình GARCH-KNN, rủi ro cực đoạn, SHAP, Tether (USDT)

Phân loại mã JEL: C22, G17, G12, G18, G15

FORECASTING VOLATILITY AND TAIL RISK OF STABLECOINS: EVIDENCE FROM USDT USING THE GARCH-KNN MODEL AND VAR-CVAR ESTIMATION

Abstract

This study proposes a hybrid GARCH-KNN framework optimized by the Genetic Algorithm-Particle Swarm Optimization (GA-PSO) approach to forecast volatility and tail risk of the USDT stablecoin in the cryptocurrency market. The dataset is processed using log returns, technical indicators, and Principal Component Analysis (PCA) to reduce dimensionality and mitigate multicollinearity. The empirical results demonstrate that the hybrid GARCH-KNN model outperforms the standalone GARCH and KNN models, achieving MAE = 0.0027, RMSE = 0.0087, $R^2 = 0.9507$, and a lower QLIKE value, indicating superior forecasting accuracy. The proposed model also effectively captures volatility clustering and improves tail risk forecasting performance. These findings provide empirical evidence for enhancing market surveillance mechanisms, optimizing risk management practices, and strengthening financial stability amid heightened market volatility and uncertainty.

Keywords: Volatility forecasting, GARCH-KNN model, tail risk, SHAP, Tether (USDT)

JEL Classification: C22, G17, G12, G18, G15

Ngày nhận bài: 2/5/2026; Ngày hoàn thiện biên tập: 1/7/2026; Ngày duyệt đăng: 8/7/2026

GIỚI THIỆU

Trong những năm gần đây, stablecoin đã trở thành một thành tố quan trọng trong hệ sinh thái tài chính số nhờ cơ chế neo giá với tiền pháp định, qua đó giúp giảm chi phí giao dịch và tăng hiệu quả thanh toán xuyên biên giới (Ante, 2025). Tuy nhiên, sự phát triển này đồng thời đặt ra các thách thức đáng kể đối với ổn định hệ thống tài chính và cơ chế giám sát tiền tệ (Auer và cộng sự, 2023). Mặc dù stablecoin thường có mức biến động thấp hơn các tài sản tiền mã hóa khác, chúng vẫn tiềm ẩn rủi ro phi tuyến và hiệu ứng lan truyền mạnh trong những giai đoạn căng thẳng thị

trường, được ghi nhận thông qua các mô hình như GARCH, DCC-GARCH và CoVaR (Gherghina và cộng sự, 2025; Franco và cộng sự, 2025). Trong lĩnh vực dự báo biến động, xu hướng nghiên cứu đang dịch chuyển từ mô hình kinh tế lượng truyền thống sang các phương pháp học sâu và mô hình lai, bao gồm CNN-LSTM và các biến thể dựa trên yếu tố rủi ro (Kim, 2025; Fieberg và cộng sự, 2023). Đồng thời, các mô hình tích hợp như wavelet-HAR-RV, TVTP-MS-HAR-RV và HAR-RV kết hợp LSTM-PCA đã cho thấy sự cải thiện đáng kể khả năng dự báo ngoài mẫu (Clements và Vatsa, 2026; Li và cộng sự, 2025). Trong khi đó, các

¹ Khoa Hệ thống Thông tin Kinh tế, Trường Đại học Kinh tế Huế; Email: tbthuan@hce.edu.vn



phương pháp học máy như LSTM, SVM hay học tăng cường thường vượt trội so với mô hình truyền thống, còn KNN chủ yếu được sử dụng như mô hình tham chiếu (benchmark) (Nti và cộng sự, 2020; Hu và cộng sự, 2021; Fischer và Krauss, 2018).

Tuy nhiên, hiện chưa có nghiên cứu nào khai thác khung GA-GARCH-PSO-KNN trong dự báo biến động stablecoin dưới điều kiện rủi ro cực đoan và bất định pháp lý. Khoảng trống này đặc biệt quan trọng trong bối cảnh Việt Nam đang từng bước hoàn thiện khung pháp lý cho tài sản số, tiền mã hóa và cơ chế quản lý stablecoin, nhằm vừa thúc đẩy đổi mới tài chính vừa kiểm soát rủi ro hệ thống. Do đó, nghiên cứu này đề xuất khung lai GA-GARCH-PSO-KNN tích hợp SHAP và VaR-CVaR nhằm nâng cao độ chính xác dự báo, tăng khả năng giải thích và mô hình hóa động lực biến động của USDT, qua đó đóng góp cả về phương pháp luận và thực nghiệm trong bối cảnh thị trường tài chính mới nổi và môi trường pháp lý đang được hoàn thiện.

PHƯƠNG PHÁP NGHIÊN CỨU

Phương pháp

Nghiên cứu này đề xuất khung phương pháp định lượng tích hợp nhằm dự báo biến động và đo lường rủi ro cực đoan của USDT trong bối cảnh bất định pháp lý. Dữ liệu đầu vào được xây dựng từ các đặc trưng tài chính - kỹ thuật bao gồm biến động, thanh khoản và động lượng thị trường. Trước tiên, mô hình GA-GARCH được sử dụng để ước lượng động lực biến động có điều kiện và tạo biến đặc trưng đầu vào quan trọng. Tiếp theo, PCA được áp dụng để giảm chiều dữ liệu, trích xuất các nhân tố tiềm ẩn và loại bỏ đa cộng tuyến, qua đó tối ưu không gian đặc trưng. Trên nền dữ liệu đã xử lý, mô hình KNN được triển khai để học cấu trúc phi tuyến của lợi suất và được tối ưu hóa tham số bằng PSO nhằm nâng cao hiệu suất dự báo. Để tăng khả năng giải thích, phương pháp SHAP được sử dụng nhằm định lượng mức độ đóng góp của từng biến đối với dự báo biến động. Đồng thời, rủi ro cực đoan được đo lường thông qua VaR và CVaR, phản ánh đầy đủ rủi ro đuôi trong thị trường. Mô hình được thiết kế theo cơ chế dự báo 21-bước nhằm mô phỏng động lực trung hạn của thị trường. Hiệu năng được đánh giá bằng MAE, MSE, RMSE, R^2 , STD và QLIKE. Cuối cùng, kiểm định chéo theo chuỗi thời gian và phân tích độ nhạy được thực hiện nhằm đảm bảo tính ổn định và khả năng tổng quát hóa của mô hình trong điều kiện dữ liệu tài chính biến động cao.

Dữ liệu

Dữ liệu nghiên cứu sử dụng chuỗi giá stablecoin USDT, trong đó giá đóng cửa hiệu chỉnh được chọn để phản ánh chính xác giá điều chỉnh theo thị trường. Từ đó, log return được tính nhằm đảm bảo tính dừng, đồng thời xây dựng biến động lợi suất thông qua độ lệch chuẩn trượt.

Tập dữ liệu được mở rộng bằng các chỉ báo kỹ thuật thuộc nhóm động lượng, xu hướng, biến động và thanh khoản, giúp tăng khả năng mô hình hóa phi tuyến của hành vi thị trường stablecoin. Trước khi phân tích, dữ liệu được làm sạch và chuẩn hóa để đảm bảo tính đồng nhất thang đo.

Mô hình hóa được thực hiện theo cơ chế dự báo đa bước với 21 ngày nhằm phản ánh động lực biến động theo thời gian. Dữ liệu được chia 80% huấn luyện và 20% kiểm tra. Cuối cùng, PCA được áp dụng để giảm chiều, giữ lại 95% phương sai, giúp loại bỏ nhiễu, giảm đa cộng tuyến và tối ưu hiệu quả dự báo. *Nghiên cứu sử dụng cách viết số thập phân theo chuẩn quốc tế.*

KẾT QUẢ THỰC NGHIỆM


Phân tích khám phá dữ liệu

Chuỗi biến động lịch sử giai đoạn 2017-2026 (Bảng 1, Hình 1) bao gồm 3,047 quan sát với tần suất ngày, phản ánh tính liên tục của dữ liệu tài chính. Giá trị trung bình 0.0298 cao hơn đáng kể so với trung vị 0.0076, cho thấy phân phối lệch phải rõ rệt, được xác nhận bởi hệ số skewness dương 3.1258.

Độ nhọn kurtosis = 13.0117 phản ánh phân phối có đuôi dày, hàm ý sự tồn tại của rủi ro cực đoan. Các phân vị 95% và 99% cho thấy biến động có thể tăng đột biến trong các trạng thái thị trường căng thẳng.

BẢNG 1: THỐNG KÊ MÔ TẢ CỦA BIẾN ĐỘNG LỊCH SỬ			
Thống kê	Giá trị	Thống kê	Giá trị
Giai đoạn	2017/11/30-2026/4/24	Số quan sát	3,047
Tần suất	Hàng ngày	Trung bình (Mean)	0.029801
Độ lệch chuẩn	0.0478	Trung vị (Median)	0.0076
Nhỏ nhất	0.000661	Lớn nhất	0.3244 (2017-12-26)
1%	0.001021	99%	0.277433
5%	0.001445	95%	0.100774
25%	0.004245	75%	0.047457
Độ lệch (Skewness)	3.1258	Độ nhọn (Kurtosis)	13.0117
Kiểm định ADF	Dừng	Kiểm định PP	Dừng
Kiểm định JB	Phi chuẩn	Kiểm định SW	Phi chuẩn

Nguồn: Kết quả nghiên cứu



Nguồn: Kết quả nghiên cứu

**BẢNG 2: MÔ HÌNH GARCH-KNN TÍCH HỢP TỐI ƯU HÓA GA-PSO**

Component	Parameter	Search Range	Optimal Value	Interpretation
Cấu hình GA	Kích thước quần thể	-	20	Đảm bảo đa dạng tìm kiếm
	Số thế hệ	-	10	Số vòng lặp hội tụ
	Tỷ lệ lai ghép	[0,1]	0.7	Khả năng khám phá
	Tỷ lệ đột biến	[0,1]	0.2	Tránh cực trị cục bộ
	Chọn lọc	-	K = 3	Áp lực chọn lọc
	Mã hóa	[1,5]	(p,q) = (1,5)	Không gian mô hình rời rạc
GARCH (GA)	(p, q)	[1-5]	(1,1)	Cấu trúc biến động tối ưu
	ω	-	1.32e-07	Phương sai dài hạn
	α_1	-	0.20	Độ nhạy với cú sốc
	β_1	-	0.78	Tính dai dẳng biến động
	$\alpha_1 + \beta_1$	-	0.98	Tính dai dẳng cao
GA hội tụ	Best AIC	-	-29165.09	Mức độ phù hợp tối ưu
Cấu hình PSO	Kích thước bầy đàn	-	20	Số tác nhân tìm kiếm
	Số vòng lặp	-	30	Chiều sâu tối ưu
	Quán tính (w)	[0,1]	0.7	Cân bằng khám phá-khai thác
	c1, c2	-	1.5, 1.5	Hệ số học
	Mục tiêu	-	Minimize MSE	Hàm mục tiêu
	CV folds	-	3	Kiểm soát tổng quát hóa
KNN (PSO)	n_neighbors	[3, 50]	3	Học cục bộ độ lệch thấp
	leaf_size	[10, 60]	38	Tối ưu tìm kiếm cây
	p (Minkowski)	[1, 2]	1	Ổn định với ngoại lai
	weights	{uniform, distance}	distance	Trọng số theo khoảng cách
	algorithm	{auto, kd_tree}	auto	Tìm kiếm thích nghi

Nguồn: Kết quả nghiên cứu

BẢNG 3: HIỆU SUẤT, ĐỘ ỔN ĐỊNH VÀ PHÂN TÍCH ĐỘ NHAY CỦA MÔ HÌNH PSO-KNN

Danh mục	Chỉ tiêu	Kết quả	Diễn giải
Tối ưu PSO	Cấu hình tốt nhất	n_neighbors=3, leaf_size=38, p=1, weights=distance	Học phi tuyến cục bộ
Kiểm định chéo	MAE	0.0032	Sai số dự báo thấp
	RMSE	0.0122	Dự báo biến động ổn định
	R ²	0.8759	Khả năng giải thích cao
	QLIKE	0.0409	Ước lượng rủi ro chính xác
Độ ổn định (5-fold)	Độ lệch chuẩn R ²	±0.023	Ổn định qua các fold
	Thời gian huấn luyện	0.011s	Hiệu quả tính toán
Phân tích độ nhạy (±2%)	ΔR^2 (n_neighbors)	0.175%	Rất ổn định
	ΔR^2 (leaf_size)	0.000%	Không nhạy cảm

Nguồn: Kết quả nghiên cứu

Kiểm định ADF và Phillips-Perron xác nhận chuỗi dừng, phù hợp cho mô hình hóa chuỗi thời gian tài chính. Ngược lại, các kiểm định chuẩn hóa (Jarque-


Bera, Shapiro-Wilk, D'Agostino-Pearson) đều bác bỏ giả thuyết phân phối chuẩn, khẳng định đặc trưng phi-chuẩn của dữ liệu.

Ước lượng mô hình GARCH-KNN tối ưu thông qua GA-PSO


Khung mô hình GARCH-KNN tích hợp GA-PSO thể hiện tính nhất quán phương pháp luận khi tách biệt rõ lựa chọn cấu trúc và tối ưu dự báo (Bảng 2). Thuật toán GA xác định mô hình GARCH (1,1) tối ưu thông qua tối thiểu hóa AIC, cho thấy cấu trúc gọn nhẹ nhưng đủ nắm bắt động lực biến động thị trường. Các tham số ước lượng phản ánh độ nhạy cao với cú sốc ($\alpha_1 = 0.20$) và tính dai dẳng mạnh của biến động ($\beta_1 = 0.78$), với tổng $\alpha_1 + \beta_1 = 0.98$ hàm ý hiện tượng cụm biến động rõ rệt. Điều này biện minh việc sử dụng phương sai có điều kiện làm biến đầu vào. Trên cơ sở đó, KNN được tối ưu bằng PSO với n_neighbors = 3 và trọng số theo khoảng cách, giúp tăng khả năng học phi tuyến trong điều kiện biến động thay đổi. Kiến trúc lai này kết nối hiệu quả giữa kinh tế lượng và học máy, nâng cao khả năng diễn giải và hiệu năng dự báo.

Đầu ra từ mô hình GARCH, cụ thể là biến Volatility_GARCH_Scaled, được sử dụng như một đặc trưng quan trọng phản ánh rủi ro động trong chuỗi thời gian. Tập dữ liệu đầu vào gồm 36 biến kỹ thuật, thống kê và chỉ báo thị trường, được chuẩn hóa bằng StandardScaler để đảm bảo tính đồng nhất thang đo. PCA được áp dụng nhằm giảm chiều dữ liệu, giữ lại 95% phương sai tích lũy, qua đó loại bỏ đa cộng tuyến, giảm nhiễu và tối ưu không gian đặc trưng cho mô hình PSO-KNN. Trên tập kiểm tra (Bảng 3), mô hình đạt hiệu suất cao với MAE = 0.002721, MSE = 0.000076 và RMSE = 0.008738, phản ánh sai số thấp và ổn định. Hệ số R² = 0.950796 cho thấy khả năng giải thích mạnh, trong khi STD = 0.008727 và QLIKE = 0.035295 xác nhận độ chính xác và độ phù hợp cao trong dự báo biến động.

Mô hình KNN được tối ưu bằng PSO, kết hợp với dữ liệu đã được biến đổi qua PCA và đặc trưng biến động từ GARCH, cho thấy hiệu suất dự báo mạnh mẽ và tính ổn định cao. Kết quả kiểm định chéo cho thấy sai số dự báo thấp và ổn định, với MAE bằng 0.0032 và RMSE bằng 0.0122, trong khi giá trị R² đạt 0.8759, phản ánh khả năng giải thích tốt các động lực phi tuyến trong dữ liệu. Hàm mất mát QLIKE bằng 0.0409 tiếp tục khẳng định khả năng mô hình hóa rủi ro chính xác trong điều kiện phương sai thay đổi theo thời gian. Phân tích độ ổn định qua 5-fold cho thấy độ lệch chuẩn của R² rất nhỏ (±0.023), chứng minh khả năng tổng quát hóa tốt của mô hình. Đồng thời, thời gian huấn luyện trung bình chỉ khoảng 0,011 giây, cho thấy tính hiệu quả tính toán cao. Phân tích độ nhạy cũng cho thấy mô hình rất ổn định trước các thay đổi nhỏ của siêu tham số, đặc biệt là leaf_size ($\Delta R^2 = 0\%$), trong khi n_neighbors chỉ ảnh hưởng rất nhỏ (0,175%). Tổng thể, khung GA-GARCH-PCA-PSO-KNN thể hiện

**HÌNH 2: DỰ BÁO BIẾN ĐỘNG VÀ RỦI RO CỰC ĐOẠN CỦA USDT**

Nguồn: Kết quả nghiên cứu

HÌNH 3: XẾP HẠNG TẦM QUAN TRỌNG CỦA CÁC ĐẶC TRƯNG GỐC DỰA TRÊN SHAP

Nguồn: Kết quả nghiên cứu

BẢNG 4: SO SÁNH HIỆU SUẤT MÔ HÌNH GARCH-KNN TỐI ƯU VÀ CÁC MÔ HÌNH KHÁC

Mô hình/Thang đo	MAE	RMSE	R_2	QLIKE	STD
GARCH	0.1316	0.1316	-4588.6	-2.9515	0.0030
KNN	0.0031	0.0111	0.9261	0.0299	0.0111
GARCH-KNN	0.0027	0.0087	0.9507	0.0352	0.0087

Nguồn: Kết quả nghiên cứu

một phương pháp dự báo biến động phi tuyến ổn định, hiệu quả và có khả năng tổng quát hóa cao trong chuỗi thời gian tài chính.

Kết quả dự báo biến động và rủi ro cực đoan của mô hình GARCH-KNN tối ưu

Kết quả dự báo (Hình 2) cho thấy biến động có xu hướng gia tăng theo thời gian, phản ánh sự chuyển dịch từ trạng thái thị trường ổn định sang trạng thái rủi ro cao hơn. Giá trị biến động tăng dần từ khoảng 0.0030 lên 0.0048, cho thấy sự tích lũy rủi ro theo thời gian. Đồng thời, các thước đo rủi ro cực đoan như VaR và CVaR ở mức 1% và 5% đều gia tăng tương ứng, trong đó CVaR luôn lớn hơn VaR, phản ánh sự tồn tại của rủi ro cực đoan rõ rệt và tính bất đối xứng trong phân phối lợi suất.

Đáng chú ý, mức tăng của CVaR lớn hơn tốc độ tăng của biến động, cho thấy hiệu ứng khuếch đại rủi ro phi tuyến. Ngoài ra, chuỗi dự báo còn cho thấy dấu hiệu chuyển trạng thái từ rủi ro thấp sang rủi ro cao trong giai đoạn giữa mẫu, xác nhận khả năng mô hình GARCH-KNN trong việc nắm bắt động lực rủi ro thay đổi theo thời gian.

Phân tích dựa trên SHAP các đặc trưng gốc quan trọng từ các thành phần PCA

Các kết quả SHAP (Hình 3) cho thấy cấu trúc dự báo biến động của mô hình mang tính nhất quán cao

giữa các nhóm đặc trưng. Nhóm đo lường độ biến động dựa trên high-low như Parkinson_vol (1.000), YangZhang_vol (0.999997) và GarmanKlass_vol (0.998891) đóng vai trò chi phối tuyệt đối, phản ánh rằng thông tin nội tại của giá trong ngày là yếu tố giải thích chính cho biến động thị trường. Nhóm rủi ro cực đoan và mức độ dao động như VaR_5, ATR, BB_width và Donchian_Width đều có mức độ quan trọng rất cao (0.98), cho thấy mô hình nhạy mạnh với các tín hiệu rủi ro cực đoan và biến động bút phá (breakout volatility).

Các chỉ báo tổng hợp như HV, QV_95 và VWAP duy trì mức ảnh hưởng đáng kể, phản ánh sự kết hợp giữa biến động lịch sử và xu hướng giao dịch. Đáng chú ý, biến Volatility_GARCH_Scaled vẫn giữ vai trò quan trọng (0.911), xác nhận đóng góp ổn định của thành phần GARCH trong việc cung cấp thông tin phương sai có điều kiện. Tổng thể, cấu trúc các đặc trưng quan trọng chứng tỏ mô hình PSO-KNN không chỉ phụ thuộc vào một nhóm biến đơn lẻ mà khai thác hiệu quả cả biến động nội tại, rủi ro cực đoan và động lực thị trường, đảm bảo tính toàn diện và khả năng giải thích cao.

Thảo luận và hàm ý chính sách

Kết quả so sánh (Bảng 4) minh chứng sự khác biệt rõ rệt giữa các mô hình tuyến tính và phi tuyến. GARCH đơn thuần có hiệu suất kém nhất với MAE = 0.1316, RMSE = 0.1316 và R^2 âm lớn (-4588.6), phản ánh không phù hợp với dữ liệu phi tuyến và rủi ro dự báo sai lệch nghiêm trọng (QLIKE âm). Ngược lại, PSO-KNN cải thiện đáng kể với MAE = 0.0031, RMSE = 0.0111 và R^2 = 0.9261, chứng minh khả năng học phi tuyến hiệu quả trên dữ liệu đã giảm chiều PCA. Đặc biệt, GARCH-KNN đạt kết quả vượt trội nhất với MAE = 0.0027, RMSE = 0.0087 và R^2 = 0.9507, đồng thời QLIKE thấp, cho thấy khả năng mô hình hóa rủi ro cực đoan tốt hơn.

Kết quả khẳng định mô hình lai GARCH-KNN vượt trội nhờ kết hợp giữa kinh tế lượng và học máy phi tuyến, giúp nắm bắt cơ chế biến động và giảm quá khớp thông qua PCA, kiểm định chéo và PSO. Tuy nhiên, mô hình vẫn có chi phí tính toán cao và hạn chế ngoại suy của KNN.

Hướng nghiên cứu tương lai tập trung vào LSTM-GARCH-Attention, mô hình đồ thị lan truyền rủi ro và tối ưu Bayes. Về chính sách, mô hình hỗ trợ dự báo VN-Index, quản trị rủi ro ngân hàng và giám sát FII tại Việt Nam, đồng thời hữu ích cho phòng hộ danh mục và giám sát rủi ro crypto quốc tế. Stablecoin như USDT vừa ổn định thanh khoản vừa tiềm ẩn rủi ro hệ thống, đặc biệt trong bối cảnh pháp lý đang hoàn thiện.

KẾT LUẬN

Nghiên cứu này đề xuất khung mô hình lai GARCH-PSO-KNN tích hợp PCA và SHAP nhằm dự



báo biến động và rủi ro cực đoan trong thị trường stablecoin. Mô hình đạt hiệu suất dự báo cao với $R^2 \approx 0.95$, RMSE thấp và QLIKE nhỏ, đồng thời ổn định trong kiểm định chéo và phân tích độ nhạy. Kết quả SHAP cho thấy các thước đo biến động nội tại (Parkinson_vol, YangZhang_vol, GarmanKlass_vol) chi phối mạnh (≈ 1.0), phản ánh vai trò trung tâm của thông tin biên độ giá trong hình thành co cụm biến động. Đồng thời, các chỉ báo rủi ro cực đoan như VaR_5, ATR và BB_width (≈ 0.98) cho thấy khả năng

nhận diện rõ các giai đoạn thị trường căng thẳng và rủi ro tập trung theo cụm.

Về chính sách, tại Việt Nam, mô hình có thể hỗ trợ giám sát biến động VN-Index, cảnh báo sớm rủi ro hệ thống trong ngân hàng và theo dõi dòng vốn FII trong bối cảnh thị trường mới nổi dễ tổn thương trước cú sốc toàn cầu. Trên phạm vi quốc tế, mô hình hữu ích cho quản trị rủi ro danh mục, phòng hộ tài sản số và giám sát rủi ro hệ thống tài chính, đặc biệt trong thị trường stablecoin và crypto. ■

Tài liệu tham khảo:

1. Ante, L. (2025). Stablecoins in cross-border payments and financial stability. *Telematics and Informatics*. <https://doi.org/10.1016/j.tele.2025.102063>
2. Auer, R., và cộng sự (2023). Stablecoins and crypto markets. *Bank for International Settlements Working Papers*. <https://www.bis.org/publ/work.htm>
3. Anh Viet Tran, & Bui Thanh Khoa (2025). Systematic review of blockchain business applications and the metaverse. *SAGE Open*. <https://doi.org/10.1177/21582440251398266>
4. Baur, D. G., Hong, K., & Lee, A. D. (2018). Bitcoin: Medium of exchange or speculative asset? *Journal of International Financial Markets, Institutions & Money*. <https://doi.org/10.1016/j.intfin.2017.12.004>
5. Bustos, O., & Pomares-Quimbaya, A. (2020). Machine learning techniques in stock market prediction: A systematic review. *Expert Systems with Applications*, 153, 113464. <https://doi.org/10.1016/j.eswa.2020.113464>
6. Clements, A., & Vatsa, P. (2026). Forecasting realized volatility using HAR models and wavelet decomposition: A volatility-timing perspective. *The North American Journal of Economics and Finance*, 83, 102605. <https://doi.org/10.1016/j.najef.2026.102605>
7. Duong Thi Van Anh, & Nguyen Thi Loi (2025). Blockchain and sustainable accounting in Vietnam. *Sustainability*. <https://doi.org/10.3390/su17104658>
8. Fieberg, C., Liedtke, G., Metko, D., & Zaremba, A. (2023). Cryptocurrency factor momentum. *Quantitative Finance*, 23(12), 1853-1869. <https://doi.org/10.1080/14697688.2023.2269999>
9. Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669. <https://doi.org/10.1016/j.ejor.2017.11.054>
10. Franco, J. P. M., và cộng sự (2025). Quantifying systemic risk in cryptocurrency markets: A high-frequency CoVaR approach. *Pacific-Basin Finance Journal*. <https://doi.org/10.1016/j.pacfin.2025.102377>
11. Gherghina, Ş.-C., & Constantinescu, C.-A. (2025). Volatility of cryptocurrencies during COVID-19 and Russia-Ukraine war. *Risks*, 13(3), 1-43.
12. Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2019). Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124, 226-251. <https://doi.org/10.1016/j.eswa.2018.10.012>
13. Hong Kong Monetary Authority. (2026). Assessing the impact of stablecoins on exchange rate volatility. <https://www.hkma.gov.hk/media/eng/publication-and-research/research/research-memorandums/2026/RM02.pdf>
14. Hu, Z., Zhao, Y., & Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. *Applied System Innovation*, 4(1), 9. <https://doi.org/10.3390/asi4010009>
15. Kim, T. (2025). Bitcoin price prediction and market variables using deep learning. *Journal of Futures Markets*. <https://doi.org/10.1002/fut.70010>
16. Leushuis, R. M., & Petkov, N. (2025). Advances in forecasting realized volatility: A review. *Journal of Economic Structures*, 14, 1-35. <https://doi.org/10.1186/s40854-025-00809-5>
17. Li, H., và cộng sự (2025). Hybrid HAR-RV and machine learning approach for volatility forecasting. *Quantitative Finance / Emerging Markets Finance & Trade*. <https://doi.org/10.1080/15140326.2025.2454081>
18. Liu, Y., Tsyvinski, A., & Wu, X. (2019). Common risk factors in cryptocurrency. *Journal of Finance*, 74(4), 1659-1700. <https://doi.org/10.1111/jofi.12765>
19. Nguyen Tung Lam, & Nguyen Van Hien (2025). Cryptocurrency regulations: Implications for Vietnam. <https://doi.org/10.29121/granthaalayah.v13.i9.2025.6347>
20. Ngwaba, C. A., và cộng sự (2025). HAR-RV-CARMA: A Kalman filter-weighted hybrid model. *Risks*, 13(11), 223. <https://doi.org/10.3390/risks13110223>
21. Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). Systematic review of stock prediction using machine learning. *Artificial Intelligence Review*, 53(4), 3007-3057. <https://doi.org/10.1007/s10462-019-09754-z>