



Phân loại bệnh tim mạch dùng mô hình kết hợp giữa học máy và học sâu

Bùi Thị Cúc^{1*}, Trần Đức Tân¹

¹ Khoa Điện – Điện tử, Trường Kỹ thuật Phenikaa, Đại học Phenikaa

*Email: cuc.buithi@phenikaa-uni.edu.vn

Tóm tắt

Nhồi máu cơ tim là một trong những bệnh lý tim mạch gây tử vong hàng đầu, có xu hướng trẻ hóa trong những năm gần đây trên toàn thế giới. Hiện nay, việc chẩn đoán nhồi máu cơ tim chủ yếu dựa vào tín hiệu ECG để phát hiện các bất thường, tuy nhiên, việc này phụ thuộc rất nhiều vào khả năng phân tích của bác sĩ và thường chỉ thực hiện khi bệnh nhân đã nhập viện, gây ảnh hưởng đến hiệu quả điều trị. Vì vậy, phát hiện sớm nhồi máu cơ tim từ xa, không cần sự có mặt của bệnh nhân tại bệnh viện, là một bước tiến quan trọng về chăm sóc sức khỏe. Trong những năm gần đây, những tiến bộ trong trí tuệ nhân tạo (AI) đã mở ra nhiều cơ hội mới trong chẩn đoán nhồi máu cơ tim qua tín hiệu ECG. Tuy nhiên, hầu hết các nghiên cứu hiện nay chỉ tập trung vào mô hình học sâu mà thiếu sự giải thích kết quả. Nghiên cứu này đề xuất một phương pháp mới kết hợp giữa học máy và học sâu để nâng cao độ chính xác và khả năng diễn giải trong chẩn đoán bệnh. Cụ thể, chúng tôi sử dụng bộ dữ liệu PTB từ PhysioNet, bao gồm 549 đoạn ECG từ 15 kênh ECG cùng với lịch sử lâm sàng của 294 bệnh nhân. Kết quả thực nghiệm cho thấy mô hình SVM đạt độ chính xác cao nhất 94,54%. Hiệu quả của phương pháp được đánh giá qua các chỉ số Accuracy, Precision, Recall và F1-Score, và so sánh giữa các mô hình đưa ra kết quả giải thích.

Từ khóa: AI, CNN, ECG, PhysioNet, SVM.

Abstract

Myocardial infarction (MI) is one of the leading causes of cardiovascular-related deaths worldwide and has been affecting younger populations in recent years. Currently, MI diagnosis mainly relies on ECG signals to detect abnormalities; however, this process depends heavily on physicians' analytical skills and is often performed only after patients are hospitalized, which reduces treatment effectiveness. Therefore, early



remote detection of MI, without requiring the patient's presence in the hospital, represents a significant advancement in healthcare. Recent progress in Artificial Intelligence (AI) has opened new opportunities for MI diagnosis through ECG analysis. However, most existing studies primarily focus on deep learning models, which often lack interpretability. This study proposes a novel approach that combines machine learning and deep learning to improve both accuracy and interpretability in MI diagnosis. Specifically, we use the PTB dataset from PhysioNet, consisting of 549 ECG records from 15 ECG leads along with clinical histories of 294 patients. Experimental results show that the SVM model achieved the highest accuracy of 94.54%. The effectiveness of the proposed method was evaluated using Accuracy, Precision, Recall, and F1-Score metrics, and the comparison among models provides explanatory insights.

Keywords: *AI, CNN, ECG, PhysioNet, SVM.*

1. MỞ ĐẦU

Nhồi máu cơ tim (MI), xảy khi mô tim thiếu máu nuôi dưỡng, chủ yếu do bệnh động mạch vành (CAD) – tình trạng mạch máu bị hẹp do tích tụ chất béo và cholesterol. Nếu không được can thiệp kịp thời, tế bào tim sẽ hoại tử, dẫn đến nhồi máu cơ tim. Theo WHO, MI là nguyên nhân gây tử vong hàng đầu thế giới với 17,9 triệu ca tử vong mỗi năm [1]. Ở Việt Nam, số ca mắc bệnh đã gia tăng đáng kể, từ 92 ca (1991 – 1995), lên hơn 1500 ca (2000 – 2001), với tỷ lệ tử vong 17,4% [2]. Mặc dù đa số các trường hợp mắc bệnh là người cao tuổi (trên 65 tuổi), nhồi máu cơ tim hiện đang có xu hướng trẻ hóa.

Các phương pháp điều trị nhồi máu cơ tim phổ biến như đặt stent hoặc phẫu thuật bắc cầu động mạch vành thường mất nhiều thời gian và chi phí cao. Do đó, việc chẩn đoán sớm MI trở thành chủ đề được quan tâm trong nghiên cứu. Hiện nay, các công nghệ tiên tiến như MRI tim, CT động mạch vành và siêu âm tim hỗ trợ chẩn đoán với độ chính xác cao, hình ảnh rõ nét và khả năng cung cấp thông tin chi tiết về cấu trúc và chức năng tim. Tuy nhiên, hạn chế về chi phí, thiết bị cồng kềnh và quy trình phức tạp khiến chúng chưa phù hợp để theo dõi trên thời gian thực. Một hướng tiếp cận khác là



sử dụng điện tâm đồ (ECG giúp phát hiện nhồi máu cơ tim thông qua phân tích hình dạng và thời gian của tín hiệu điện tim, qua đó cung cấp thông tin chi tiết về hoạt động của tim [3]. Với sự phát triển vượt bậc của AI, việc phân tích và phân loại tín hiệu ECG ngày càng chính xác, mở ra nhiều triển vọng cho kỹ thuật y sinh.

Trí tuệ nhân tạo (AI) vận hành dựa trên các mô hình thuật toán để học hỏi và mô phỏng trí thông minh của con người [4], trong đó học máy (ML) - một nhánh của AI – giúp máy tính nhận diện và phân tích các mẫu dữ liệu. Để phát hiện nhồi máu cơ tim, nhiều phương pháp như biến đổi Wavelet, phân tích tín hiệu trong miền thời gian, đa thức hồi quy, và học máy có giám sát đã được áp dụng. Một thách thức lớn trong học máy là “curse of dimensionality” khi làm việc với tập dữ liệu lớn. Để giải quyết, các kỹ thuật chọn lọc và trích xuất đặc trưng giúp loại bỏ các thông tin thừa, cải thiện độ chính xác [5]. Dun và cộng sự [6] đã thử nghiệm nhiều thuật toán như hồi quy logistic, SVM, Random Forest và học sâu, đồng thời tinh chỉnh các siêu tham số để tăng độ chính xác cho mô hình mạng nơ ron và đạt độ chính xác 78,3%. Singh [7] đạt hiệu suất 100% khi phát hiện bệnh động mạch vành bằng GDA (Generalized Discriminant Analysis) kết hợp Extreme Learning Machine và Fisher để trích xuất và chọn lọc đặc trưng. Các nghiên cứu sử dụng tập dữ liệu UCI với 14 đặc trưng, tập trung vào phân loại hoặc dự đoán bệnh tim, áp dụng các mô hình học máy quen thuộc cũng đạt được độ chính xác khá cao, như Random Forest với 89,2% [8], cây quyết định 89,1% [9], mạng nơ ron nhân tạo (ANN) 92,7% [10], SVM đạt 88% [11]. Dù mang lại kết quả khả quan, các phương pháp này vẫn gặp hạn chế khi xử lý phân đoạn tim phức tạp, tốn thời gian và chưa tối ưu trong thực tế lâm sàng. Gần đây, học sâu ngày càng được ứng dụng rộng rãi, nhưng dự đoán nhồi máu cơ tim bằng học sâu vẫn còn ít được nghiên cứu [12].

Từ 2019-2024, nhiều nghiên cứu đã tập trung vào ứng dụng học máy và học sâu trong phân loại và dự đoán bệnh tim mạch. Nghiên cứu [13] kết hợp học sâu và học tổ hợp (ensemble learning) để đánh giá nguy cơ mắc bệnh tim, trong đó học sâu được áp dụng để trích xuất đặc trưng, còn học tổ hợp đưa ra dự đoán. Nghiên cứu khác [14] so sánh các thuật toán học máy và học sâu trên tập dữ liệu bệnh tim của UCI với 14 thuộc tính và kết quả là thuật toán KNeighbors hoạt động tốt hơn trên tập dữ liệu nhỏ, đạt độ



chính xác 83,29%, còn học sâu chủ yếu đóng vai trò tham chiếu trong nghiên cứu này. Trên tập dữ liệu UCI machine learning repository dataset, các tác giả [15] kết hợp CNN (Convolution Neural Network) và LSTM (Long Short-Term Memory) với 76 đặc trưng, đạt độ chính xác 89% khi phân loại dữ liệu thành hai nhóm bình thường và bất thường, đạt hiệu suất cao hơn so với SVM, Naïve Bayes và Decision Tree. Cùng trên tập dữ liệu này, Sadia Arooj và cộng sự [16] áp dụng DCNN (Deep CNN) để phát hiện bệnh tim trên 1050 bệnh nhân với 14 thuộc tính, và đạt độ chính xác 91,7%. Trong khi đó, tác giả [17] đề xuất mô hình lai dựa trên phép biến đổi wavelet liên tục (CWT) và CNN, gọi tắt WT-CNN, sử dụng RUSBoost để cân bằng dữ liệu, nâng độ chính xác lên 97,2%.

Nghiên cứu [18] sử dụng ba tập dữ liệu gồm hai bộ công khai (70.000 và 1.190 mẫu) và một bộ thu thập nội bộ (600 mẫu). Mô hình đề xuất kết hợp CNN- LSTM, K-Nearest Neighbors và XGB (Extreme Gradient Boosting), sau đó áp dụng phương pháp bỏ phiếu đa số (majority voting) để đưa ra dự đoán cuối cùng. Trong khi đó, nghiên cứu [19] phát triển thuật toán học sâu lai HMSI (Hybrid Mutation-based Swarm Intelligence) kết hợp với AttGRU (Attention-based Gated Recurrent Unit) để phân tích dữ liệu lớn CVD khoảng 70.000 bản ghi. Dữ liệu được xử lý qua K-means Clustering để loại bỏ các giá trị ngoại lai, SMOTE (Synthetic Minority Over-Sampling Technique) để cân bằng dữ liệu và RFE (Recursive Feature Elimination) để chọn lọc đặc trưng quan trọng nhất, đạt kết quả, vượt trội so với các mô hình khác như: SAE + ANN (Sparse Autoencoder + Artificial Neural Network), LR (Logistic Regression), KNN (K-Nearest Neighbor), và Naïve Bayes với độ chính xác 95,42%.


Nghiên cứu [20] đề xuất mô hình kết hợp RNN (Recurrent Neural Network) và LSTM, đồng thời sử dụng thuật toán GSA (Genetic Sine Algorithm) để loại bỏ các đặc trưng dư thừa trước khi đưa vào mô hình học sâu. Tương tự, nghiên cứu [21] áp dụng GRNN (Gated Recurrent Neural Network) và LSTM để phân loại tín hiệu ECG của bệnh nhân tim mạch với kết quả mô hình hoạt động hiệu quả trên dữ liệu UCI và tập dữ liệu lâm sàng suy tim, vượt trội so với phương pháp truyền thống.

Nghiên cứu của chúng tôi dựa trên tín hiệu ECG 3 kênh từ bộ dữ liệu PTB Diagnostic ECG Database trên Physionet, không sử dụng các thông tin lâm sàng của

bệnh nhân. Chúng tôi đề xuất một mô hình lai kết hợp giữa học sâu và học máy nhằm khai thác tối đa ưu điểm của cả hai phương pháp. Cụ thể, tín hiệu ECG sau khi được xử lý làm sạch và phân đoạn sẽ được trích xuất đặc trưng từ ECG thô theo hai hướng: phương pháp truyền thống và áp dụng mô hình học sâu (CNN, LSTM). Các đặc trưng thu được sau đó được đưa vào các thuật toán học máy như SVM, KNN, Random Forest để phân loại bệnh nhân nhồi máu cơ tim. Kết quả thực nghiệm của chúng tôi cho thấy phương pháp trích xuất đặc trưng truyền thống kết hợp với SVM đạt độ chính xác cao nhất 94,54%, vượt trội so với phương pháp học sâu kết hợp với học máy (77,5%) ngay cả khi đã tối ưu tham số. Ngoài ra, phương pháp truyền thống không chỉ đạt hiệu suất tốt hơn mà còn có thời gian xử lý nhanh hơn, khả năng giải thích và tính linh hoạt cao hơn so với mô hình học sâu. Điều này cho thấy đặc trưng truyền thống vẫn mang lại hiệu quả đáng kể trong bài toán chẩn đoán nhồi máu cơ tim từ ECG.

Cấu trúc bài báo được trình bày như sau. Phần II giới thiệu chi tiết phương pháp nghiên cứu, bao gồm thông tin về tập dữ liệu, quy trình trích xuất và xử lý dữ liệu, phương pháp chọn lọc đặc trưng, cũng như các mô hình học sâu và học máy được áp dụng. Kết quả phân tích được trình bày trong phần III, trong khi phần IV tập trung vào thảo luận, kết luận và đề cập hướng nghiên cứu trong tương lai.

2. GIẢI QUYẾT VẤN ĐỀ



Hình 1. Sơ đồ khối của thuật toán.

Nghiên cứu đề xuất phương pháp phân loại bệnh nhân ở hai trạng thái: bị và không bị nhồi máu cơ tim thông qua trích xuất đặc trưng từ tín hiệu ECG thô. Sơ đồ khối của thuật toán được minh họa trong Hình 1, bao gồm 6 bước: (1) Lựa chọn cơ sở

dữ liệu từ Physionet, (2) Tiền xử lý dữ liệu, (3) Phân chia dữ liệu, (4) Trích xuất đặc trưng, (5) Mô hình phân loại có tối ưu tham số, (6) Đánh giá mô hình dựa trên các chỉ số. Từng bước trong sơ đồ này sẽ được phân tích chi tiết hơn trong phần tiếp theo.

2.1. Mô tả bộ dữ liệu


PTB Diagnostic ECG Database là một cơ sở dữ liệu điện tâm đồ (ECG) toàn diện, được phát triển bởi Physikalisch-Technische Bundesanstalt (PTB), Viện Đo lường Quốc gia Đức [22]. Bộ dữ liệu bao gồm các bản ghi ECG từ 294 bệnh nhân, trong đó có cả người khỏe mạnh và người mắc các bệnh lý tim mạch khác nhau. Mỗi bệnh nhân có từ 1 đến 5 bản ghi ECG, với tổng số 549 bản ghi trong toàn bộ cơ sở dữ liệu. Các bản ghi được lấy từ 15 kênh (12 đạo trình ECG tiêu chuẩn và 3 đạo trình Frank XYZ), ở tần số lấy mẫu 1000 Hz, độ phân giải biên độ là 16-bit. Tuy nhiên, trong nghiên cứu này, chúng tôi chỉ sử dụng 3 kênh (Leads) bao gồm Lead I, II, III để đơn giản hóa mô hình và giảm độ phức tạp tính toán mà vẫn đảm bảo giữ lại thông tin chẩn đoán quan trọng từ tín hiệu ECG. Bộ dữ liệu chứa các nhãn chuẩn được cung cấp bởi các bác sĩ chuyên khoa tim mạch và bao gồm các loại bệnh lý cung cấp trong Bảng 1:

Bảng 1. Các nhóm bệnh được chẩn đoán


Tên loại bệnh (tiếng Anh)	Tên loại bệnh (tiếng Việt)	Số lượng bệnh nhân
Myocardial Infarction	Nhồi máu cơ tim	148
Cardiomyopathy/Hear failure	Bệnh cơ tim	18
Bundle branch block	Rối loạn dẫn truyền tim	15
Dysrhythmia	Rối loạn nhịp tim	14
Myocardial hypertrophy	Phì đại cơ tim	7
Valvular heart disease	Bệnh van tim	6
Myocarditis	Viêm cơ tim	4
Miscellaneous	Trường hợp khác	5
Healthy controls	Khỏe mạnh	54

Trên Bảng 1, có thể phân loại thành 9 loại bệnh nhân khác nhau, nhưng chúng tôi tập trung phân loại thành bệnh nhân bị nhồi máu cơ tim và khác. Ngoài ra trong bộ dữ liệu còn cung cấp các thông tin về độ tuổi, giới tính, dữ liệu về lịch sử y tế, thuốc điều trị và liệu pháp can thiệp, bệnh lý động mạch vành, chụp tâm thất, siêu âm tim và huyết động học, tuy nhiên, chúng tôi chỉ sử dụng duy nhất tín hiệu ECG để làm đầu vào thuật toán.

Các dữ liệu ECG được chúng tôi tiền xử lý, chuyển đổi dữ liệu về đúng định dạng, áp dụng các bộ lọc số để loại bỏ nhiễu và nhiễu dao động đường cơ sở. Cụ thể, một bộ lọc băng thông Butterworth bậc 5, với dải tần từ 0,5-30Hz được áp dụng, trước khi phân đoạn 549 bản ghi ECG thành từng đoạn có chiều dài 5 giây phù hợp với mô hình trích xuất đặc trưng truyền thống và mô hình học sâu. Sau quá trình phân đoạn này, chúng tôi lấy được tất cả 9345 đoạn ECG và lưu vào bộ dữ liệu có tên: “prepared_PTBDData.mat” bao gồm thông tin các đoạn ECG và gán nhãn cho các đoạn ECG tương ứng, với ‘label = 1’ là bệnh nhân bị nhồi máu cơ tim và ‘label’ = 0 cho bệnh nhân khác.



Hình 2. Tín hiệu ECG bình thường của Patient240 mã bản ghi s0468_re.



Hình 3. Tín hiệu ECG của bệnh nhân bị nhồi máu cơ tim Patient183 mã bản ghi s0175_re.

Hình 2, 3 biểu diễn các đoạn ECG có độ dài 5 giây từ các bản ghi của các bệnh nhân trong bộ PTB Diagnostic ECG Database. Những tín hiệu ECG này sẽ cung cấp các đặc trưng được trích xuất tối ưu nhất cho mô hình phân loại.

2.2. Trích xuất đặc trưng

Toàn bộ dữ liệu sẽ được chia thành 2 phần: bộ dữ liệu huấn luyện (training sets) và bộ dữ liệu kiểm tra (testing sets). Những dữ liệu huấn luyện được lưu trữ dưới dạng mảng cell, và sau đó được chuyển thành mảng 4 chiều để đáp ứng cho định dạng đầu vào của mô hình học sâu mạng nơ ron tích chập CNN trong MATLAB. Mạng Nơ-ron tích chập (CNN) [23] đã được chứng minh là có hiệu quả trong việc tự động học các đặc trưng để phân loại chuỗi thời gian và tín hiệu. Trong nghiên cứu này, CNN được khai thác ở thế mạnh là khả năng trích xuất các đặc trưng cục bộ từ luồng dữ liệu cấp cao và truyền chúng xuống các cấp thấp hơn để phát hiện các đặc trưng phức tạp hơn mà không cần thông qua các đặc trưng được trích xuất thủ công [24]. Quá trình này được thực hiện bằng cách sử dụng các lớp tích chập trong CNN, cụ thể, tín hiệu ECG sau khi được chuẩn hóa sẽ được đưa vào các lớp tích chập (convolutional layers), nơi các bộ lọc (kernels) học cách phát hiện các mẫu đặc trưng như biên độ, hình thái sóng P, QRS và T. Thông tin này sau đó được truyền qua các lớp phi tuyến ReLu (Rectified Linear Unit),

là một hàm phi tuyến, với đầu ra là: $f(x) = \max(0,x)$ để tăng cường đặc trưng quan trọng và loại bỏ nhiễu không cần thiết. Tiếp theo, các lớp pooling giúp giảm chiều dữ liệu nhưng vẫn giữ lại thông tin quan trọng, từ đó tạo ra các đặc trưng và trích xuất đặc trưng ở lớp fully connected trước softmax.

Đồng thời, chúng tôi trích xuất thủ công các đặc trưng khác từ tín hiệu ECG để nghiên cứu so sánh. Đầu tiên, ở miền thời gian, chúng tôi trích xuất các đặc trưng cơ bản bao gồm khoảng RR, phức hợp QRS, và các chỉ số liên quan đến sự thay đổi nhịp tim (HRV) [25]. Các đặc trưng này cung cấp cái nhìn ban đầu về hoạt động điện học của tim. Tiếp theo, trên miền tần số, chúng tôi phân tích phổ mật độ công suất của tín hiệu ECG dùng phương pháp Pwelch [26] và tỉ số LF/HF [27] để xác định được các bất thường trong nhịp tim. Cuối cùng, ở miền phi tuyến, chúng tôi áp dụng phương pháp phân tích Poincaré Plot [28], Sample Entropy [29] và Detrended Fluctuation Analysis [30] để phát hiện các đặc điểm phi tuyến trong tín hiệu ECG, giúp nhận dạng các rối loạn nhịp tim hoặc các biểu hiện bệnh lý mà các đặc trưng tuyến tính không thể hiện được. Chúng tôi trích xuất và lưu trữ tất cả 36 đặc trưng khác nhau từ 3 kênh tín hiệu ECG được mô tả trong Bảng 2.

Bảng 2. Mô tả các đặc trưng trích xuất từ tín hiệu ECG.

Phân loại	Tên đặc trưng	Mô tả
Miền thời gian	Mean_Lead1, 2, 3	> Giá trị trung bình khoảng RR của nhịp tim.
	Std_Lead1, 2, 3	> Độ lệch chuẩn của các khoảng RR liên tiếp.
	Var_Lead1, 2, 3	> Phương sai và Root Mean Square của tín hiệu ECG.
	RMS_Lead1, 2, 3	> Số lượng các khoảng RR liên tiếp có sự chênh lệch >50ms
	NN50_Lead1, 2, 3	> Tỉ lệ phần trăm của NN50 so với tổng số khoảng RR bình thường.
	pNN50_Lead 1, 2, 3	> Số lượng các khoảng RR liên tiếp có sự chênh lệch >50ms
Miền tần số	LF_Power	> Phổ công suất tín hiệu trong băng tần thấp (0.04 – 0.15Hz)
	HF_Power	> Phổ công suất tín hiệu trong băng tần số cao (0.15 – 0.4Hz)
	LF_HF_Ratio	> Tỉ số giữa LF_Power/HF_Power



Miền	tuyến	DFA	> Detrended Fluctuation Analysis
tính		SD1, SD2, SD1/SD2	> Biểu đồ Poincaré
		SampEn	> Sample Entropy

2.3. Chọn lọc đặc trưng

Để giảm thiểu dư thừa trong tập dữ liệu và tăng hiệu suất mô hình dự đoán, chúng tôi sử dụng phương pháp phân tích thành phần chính Principal Component Analysis (PCA) [31] để lựa chọn đặc trưng từ các đặc trưng đã trích xuất ở trên. PCA được áp dụng để giảm chiều dữ liệu bằng cách chọn lọc các thành phần chính (Principal Components) mang lại phần lớn phương sai của dữ liệu. Cụ thể, các thành phần chính đầu tiên được giữ lại sao cho tổng phương sai được giải thích đạt ít nhất 95%, đảm bảo các thông tin quan trọng của bộ dữ liệu trích xuất đặc trưng không bị mất mát đáng kể, đồng thời giảm độ phức tạp tính toán và loại bỏ các đặc trưng tương quan mạnh ảnh hưởng tới hiệu suất và tính ổn định của mô hình học máy. Trong nghiên cứu này, PCA đã giảm từ 36 đặc trưng xuống còn 12 đặc trưng quan trọng nhất.

2.4. Mô hình thuật toán cho phân loại

Mô hình thứ nhất, chúng tôi dùng thuật toán của học máy phổ biến SVM, KNN và Random Forest để phân loại, với các tham số mô hình được tối ưu hóa dùng phương pháp Bayes. Sau đó, chúng tôi áp dụng 2 mô hình học sâu CNN và LSTM [32] để xem xét khả năng thay đổi chất lượng phân loại dựa trên tính chất non-stationary của ECG, nên CNN giúp trích xuất đặc trưng phức tạp tại một thời điểm (đặc trưng cục bộ), trong khi LSTM giúp phân tích mối quan hệ giữa các thời điểm (đặc trưng toàn cục). Cuối cùng, sau khi thử trên mô hình CNN và LSTM cho ra kết quả thấp hơn so với học máy, đồng thời thời gian để huấn luyện khá lâu, chúng tôi đã nghiên cứu trên mô hình lai - kết hợp giữa học sâu với học máy và giữa các mô hình học sâu với nhau để khai thác triệt để thế mạnh của các mô hình học thuật này.

2.5. Phương pháp đánh giá

Các chỉ số đánh giá mô hình [33]: Accuracy (viết tắt *Ac*) đánh giá độ chính xác trong quá trình training và testing cho mỗi vòng (epoch), Precision (viết tắt *Pr*) là kết quả dự đoán giữa dữ liệu được kiểm tra trong quá trình huấn luyện và F1-score (viết tắt



F_s) là giá trị trung bình của Ac và Pr , Recall (viết tắt Re) – tỉ lệ phát hiện, giá trị này càng tiệm cận với 1 chứng tỏ mô hình nhận dạng chính xác. Các chỉ số được tính toán qua Confusion Matrix có 4 thành phần là TP (True Positive), TN (True Negative), FP (False Positive) và FN (False Negative).

3. THỬ NGHIỆM

3.1. Thực nghiệm mô hình

Bài thực nghiệm được đánh giá trên phần mềm mô phỏng MATLAB 2024a với thuật toán được thực hiện là các mô hình học sâu, học máy đơn lẻ và tích hợp, đồng thời sử dụng các tiêu chí về Ac , F_s , Re , và Pr để đánh giá. Bộ dữ liệu của chúng tôi gồm 294 bệnh nhân, với 549 bản ghi và được phân đoạn thành 9345 đoạn ECG, mỗi đoạn có độ dài 5 giây và được gán nhãn tương ứng: nhồi máu cơ tim và khác. Sau đó 9345 đoạn ECG có gán nhãn tương ứng được chia ra thành 2 bộ dữ liệu: bộ dữ liệu training và bộ testing, với tỷ lệ là 8:2 (training: testing) được sử dụng trong nhiều nghiên cứu và được đánh giá, công nhận là tỷ lệ hợp lý trong quá trình thực hiện. Chúng tôi dùng phương pháp phân chia “HoldOut” để giữ lại 20% dữ liệu cho kiểm tra. Lựa chọn đặc trưng PCA đã chọn 12 thành phần chính đầu tiên từ 36 đặc trưng được trích xuất để giảm chiều dữ liệu, cải thiện độ khái quát mô hình. Mô hình học máy SVM được tối ưu hóa tham số bằng phương pháp Bayes (Bayesian Optimization) với siêu tham số quan trọng như BoxConstraint (C) và kernel thông qua hàm mục tiêu. Cụ thể, SVM sử dụng kernel Gaussian (RBF), BoxConstraint = 9,06, KernelScale = 0,637 và đạt được độ chính xác khá cao 94,54%. Mô hình KNN được tối ưu bằng cách thử nghiệm các giá trị của K – neighbors từ 1 tới 30, và các khoảng cách Chebyshev, Euclidean, Minkowski. Kết quả tối ưu K = 5, khoảng cách tối ưu Chebyshev là giá trị được chọn, và mô hình đạt độ chính xác là 93,2%, cao hơn so với mô hình Random Forest là 91,28% được mô tả trong Bảng 3.

Bảng 3. Kết quả và so sánh mô hình học máy

Mô hình	Accuracy (%)	F1-score (%)
SVM	94,54	92,03

KNN	93,2	90,04
Random Forest	91,28	86,93

Chúng tôi tiếp tục dùng mô hình học sâu CNN, mô hình lai CNN kết hợp SVM và CNN với LSTM để phân loại bệnh mà không trích xuất đặc trưng thủ công như với mô hình học máy. Kết quả thực nghiệm ở quá trình huấn luyện dữ liệu cho tiêu chí Ac ở ba mô hình trên được mô tả ở Bảng 4, mô hình CNN kết hợp LSTM có độ chính xác tương đương nhau xấp xỉ 77%. Trong đó, các siêu tham số như số lượng filters, kích thước kernel, dropout rate và learning rate ở mô hình học sâu cũng được tối ưu bằng phương pháp Bayes.

Với mô hình học sâu và mô hình học sâu CNN kết hợp với SVM, chúng tôi đưa bộ dữ liệu huấn luyện làm đầu vào mô hình CNN, trích xuất đặc trưng ở lớp fully connected, và SVM sẽ làm nhiệm vụ phân loại dữ liệu. Các tham số tối ưu để CNN và SVM hoặc động tốt như sau: NumFilters = 19; KernelSize = 3; DropoutRate = 0,15491 và LearningRate = 0.00061196, BoxConstraint = 0,16077, KernelScale = 0.0022717, kết quả đạt được là 77,31%, thấp hơn mô hình thuần CNN với độ chính xác là 77,47%. Với mô hình LSTM, Convolution Layers bao gồm 32 filters ở conv1, và 64 filter ở conv2, learning rate $1e-3$ trong 30 epochs và miniBatchSize là 64. Thời gian tối ưu hóa và huấn luyện cho mô hình CNN, LSTM rất lâu, khoảng vài giờ, trong khi mô hình SVM chỉ mất vài phút để hoàn thành.

Bảng 4. Kết quả mô hình học sâu và mô hình lai.

Mô hình	Accuracy (%)	F1-score (%)
CNN	77,31	80,2
CNN + SVM	77,47	80,4
CNN + LSTM	77,64	87,25

Kết quả cho thấy các mô hình học sâu như CNN và LSTM có hiệu suất thấp hơn so với mô hình học máy SVM trong nghiên cứu này. Nguyên nhân có thể đến từ kích thước tập dữ liệu còn hạn chế (549 mẫu) khiến mô hình học sâu không được huấn luyện đầy đủ, dẫn đến hiện tượng overfitting. Học sâu thường yêu cầu lượng dữ liệu lớn để



phát huy tối đa khả năng trích xuất đặc trưng ẩn, trong khi học máy truyền thống lại hoạt động hiệu quả hơn trên các tập dữ liệu nhỏ nếu được chọn đặc trưng phù hợp. Hơn nữa, các mô hình học sâu chưa được tối ưu hóa cấu trúc mạng và số lượng tầng mạng phù hợp với bài toán phân loại nhồi máu cơ tim trong nghiên cứu này.

Cuối cùng, để kiểm chứng tính ổn định cũng như tránh các hiện tượng overfitting và underfitting, chúng tôi đã mở rộng thử nghiệm với 5-fold cross validation trên mô hình SVM và nhận được kết quả với độ chính xác tương đương 94%, đảm bảo mô hình không phụ thuộc vào cách chia dữ liệu.

3.2. Nhận xét kết quả nghiên cứu

Kết quả nghiên cứu cho thấy, mô hình SVM đạt độ chính xác 94.54%, vượt trội so với các mô hình học sâu như CNN và LSTM (xấp xỉ 77%), nhấn mạnh rằng với dữ liệu hạn chế, đặc trưng thủ công dựa trên kiến thức về y sinh (khoảng RR, QRS, HRV, entropy, DFA và phổ tần số) vẫn đóng vai trò rất quan trọng trong phân loại nhồi máu cơ tim, không chỉ mang ý nghĩa thống kê mà còn phản ánh trực tiếp các cơ chế sinh lý bệnh học. Điều này củng cố giá trị các đặc trưng truyền thống như một nền tảng y sinh vững chắc, giúp mô hình vừa đạt hiệu suất cao vừa có tính giải thích. Đồng thời, kết quả cũng chỉ ra hạn chế của mô hình học sâu với kích thước dữ liệu nhỏ, mạng CNN/LSTM chưa đủ dữ liệu để học được đặc trưng mạnh mẽ, dẫn đến hiệu suất thấp. Ngoài ra, học sâu đòi hỏi chi phí tính toán lớn, thời gian huấn luyện kéo dài nhiều giờ, trong khi học máy chỉ mất vài phút và blackbox của học sâu gây khó khăn trong việc giải thích, hạn chế khả năng ứng dụng trong thực hành lâm sàng.

Tuy nhiên, học sâu và học máy kết hợp có thể cải thiện được hiệu quả nếu được tối ưu trên tập dữ liệu lớn hơn. Các kỹ thuật như tăng cường dữ liệu (data augmentation), transfer learning hoặc sử dụng Explainable AI là những giải pháp khả thi nhằm khắc phục những hạn chế trên mà chúng tôi sẽ phát triển ở nghiên cứu tiếp theo. Đồng thời, để kiểm chứng tính ổn định cũng như tránh các hiện tượng overfitting và underfitting, chúng tôi đã mở rộng thử nghiệm với 5-fold cross validation trên mô hình SVM. Ngoài



ra, chúng tôi sẽ thực hiện patient-specific để phản ánh sát thực tế lâm sàng trên từng bệnh nhân trong phiên bản sau này.

4. KẾT LUẬN

Nghiên cứu của chúng tôi thực hiện phân loại bệnh nhân nhồi máu cơ tim ứng dụng các thuật toán học máy, học sâu và mô hình kết hợp trên dữ liệu PTB Diagnostic ECG Database. Kết quả nghiên cứu đưa ra ba đóng góp chính cho khoa học: (1) Đóng góp học thuật: chứng minh rằng đặc trưng thủ công dựa trên kiến thức y sinh khi kết hợp với học máy (SVM) đạt hiệu suất cao hơn học sâu trên tập dữ liệu hạn chế, với độ chính xác là 94.54%, là bằng chứng quan trọng cho thấy học máy vẫn giữ vai trò chủ đạo đối với bộ dữ liệu nhỏ, trong khi học sâu yêu cầu dữ liệu lớn hơn hoặc áp dụng các kỹ thuật tối ưu hóa; (2) Ý nghĩa y sinh: các đặc trưng trên miền thời gian, tần số và phi tuyến phản ánh cơ chế bệnh của nhồi máu cơ tim, do đó giúp mô hình có giá trị về mặt diễn giải y học; (3) Ứng dụng thực tế: hệ thống được cải thiện trong tương lai có tiềm năng triển khai trong các thiết bị ECG di động hoặc wearable, hỗ trợ phát hiện nhồi máu cơ tim từ xa, đưa ra cảnh báo kịp thời và giảm tỉ lệ tử vong do nhồi máu cơ tim gây ra.

Mặc dù đạt kết quả khả quan, nghiên cứu của chúng tôi vẫn tồn tại những hạn chế về quy mô dữ liệu và chưa khai thác triệt để được hiệu suất của mô hình học sâu. Trong tương lai chúng tôi sẽ: (1) Mở rộng dữ liệu dùng các kỹ thuật data augmentation và áp dụng transfer learning để cải thiện học sâu; (2) Triển khai thực hiện patient-specific để tăng tính thuyết phục; (3) Phát triển thêm các kỹ thuật Explainable AI nhằm nâng cao khả năng giải thích cho mô hình. Kết quả nghiên cứu là tiền đề cho xây dựng hệ thống y sinh thông minh, tạo cơ sở cho những ứng dụng AI an toàn và đáng tin cậy trong thực hành lâm sàng.

LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Trường Kỹ thuật Phenikaa, Đại học Phenikaa trong đề tài mã số PU-2024-3-A-02. Tác giả xin chân thành cảm ơn các thí nghiệm viên trung tâm KHCN đã hỗ trợ trong quá trình thực hiện nghiên cứu thực nghiệm.

TÀI LIỆU THAM KHẢO



- [1]. W. H. O. a. Others (2017), “Cardiovascular disease,” world2017cardiovascula. http://www.who.int/cardiovascular_diseases/en.
- [2]. N. V. Tân (2015), *Nghiên Cứu Sự Khác Biệt Về Lâm Sàng, Cận Lâm Sàng Và Điều Trị Nhồi Máu Cơ Tim Cấp Ở Bệnh Nhân Trên Và Dưới 65 Tuổi*, Sách Việt - Chuyên ngành Nội - Tim mạch.
- [3]. D. B. Birnbaum Y (2003), The electrocardiogram in ST elevation acute myocardial infarction: correlation with coronary anatomy and prognosis, *Postgrad Med J*, số 79.935 tr. 490-504.
- [4]. Chattopadhyay, Amit K., Subhagata Chattopadhyay (2022), VIRDOCD: A virtual doctor to predict dengue fatality, *Expert Syst*, số 39, tr. 1-12.
- [5]. Liu H, Motoda. (1998), Feature Extraction, Construction and Selection, *Springer*, Cham, Switzerland.
- [6]. Dun, Boyang, Eric Wang, S. J. C. S. Majumder (2016), Heart disease diagnosis on medical data using ensemble learning, *Comput. Sci*, số 1.1, tr. 1-5.
- [7]. Dun, Boyang, Eric Wang, S. J. C. S. Majumder (2018), Detection of coronary artery disease by reduced features and extreme learning machine, *Medicine and Pharmacy Reports*, số 91, tr. 166–175.
- [8]. Khan, Shabia Shabir, S. M. K. Quadri (2016), Prediction of angiographic disease status using rule based data mining techniques, *Biological Forum—An International Journal*, số 8, tr. 103–107.
- [9]. Sen, Sanjay Kumar (2017), Predicting and diagnosing of heart disease using machine learning algorithms, *International Journal of Engineering and Computer Science*, số 6, tr. 2319–7242.
- [10]. Das, Resul, Ibrahim Turkoglu, Abdulkadir Sengur (2009), Effective diagnosis of heart disease through neural networks ensembles, *Expert Systems with Applications*, số 36, tr. 7675–7680.
- [11]. Srinivas, K., G. Raghavendra Rao, A. Govardhan (2010), Analysis of coronary heart disease and prediction of heart attack in coal mining regions using data mining techniques, *Proceedings of 2010 5th International Conference on Computer Science & Education*, tr. 1344–1349.
- [12]. Khened, M., Kollerathu, V. A., Krishnamurthi, G (2019), Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers, *Med. Image Anal*, số 51, tr. 21–45.
- [13]. Venkatesh, D., et al (2023), Prediction of heart disease using machine learning and hybrid methods, *Conference: 2023 1st International Conference on Optimization Techniques for Learning (ICOTL)*, Bengaluru, India, tr. 1-6.
- [14]. Bharti, Rohit, et al (2021), Prediction of Heart Disease Using a Combination of Machine Learning and Deep Learning, *Computational Intelligence and Neuroscience*, số 2021.1, tr. 8387680.
- [15]. Sudha, V. K., D. Kumar (2023), Hybrid CNN and LSTM Network For Heart Disease Prediction, *SN Computer Science*, số 4, tr. 172.
- [16]. Arooj, Sadia, et al (2022), A Deep Convolutional Neural Network for the Early Detection of Heart Disease, *Biomedicines*, số 10.11, tr. 2796.



- [17]. Mohammad, Farah, Saad Al-Ahmadi (2023), WT-CNN: A Hybrid Machine Learning Model for Heart Disease Prediction, *Mathematics*, số 11.22, tr. 4681.
- [18]. Sadr, Hossein, et al (2024), Cardiovascular disease diagnosis: a holistic approach using the integration of machine learning and deep learning models, *Eur J Med Res*, số 29.1, tr. 2024.
- [19]. Rao, G. Madhukar, et al (2024), AttGRU-HMSI: enhancing heart disease diagnosis using hybrid deep learning approach, *Scientific Reports*, số 14, tr. 7833.
- [20]. Baviskar, Vaishali, et al (2023), Efficient Heart Disease Prediction Using Hybrid Deep Learning Classification Models, *IRBM*, số 44, tr. 100786.
- [21]. Suhail, M. Mohamed, T. Abdul Razak (2022), Cardiac disease classification from ecg signals using hybrid recurrent neural network method, *Advances in Engineering Software*, số 174, tr. 103298.
- [22]. Goldberger, Ary L., et al. (2000), PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals, *Circulation* [Online], số 101.23, tr. e215–e220.
- [23]. Alzubaidi, Laith, et al. (2021), Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions, *J. Big Data*, số 8.1, tr. 53.
- [24]. Al Reshan, Mana Saleh, et al. (2023), A Robust Heart Disease Prediction System Using Hybrid Deep Neural Networks, *IEEE Access*, số 11, tr. 121574-121591.
- [25]. Lee, Hyojeong, et al. (2016), Prediction of Ventricular Tachycardia One Hour before Occurrence Using Artificial Neural Networks, *Sci Rep*, số 6.1, tr. 32390.
- [26]. Ebrahimzadeh, Elias, et al. (2018), Prediction of paroxysmal Atrial Fibrillation: A machine learning based approach using combined feature vector and mixture of expert classification on HRV signal, *Computer Methods and Programs in Biomedicine*, số 165, tr. 53-67.
- [27]. Huikuri, H. V., et al. (1993), Frequency domain measures of heart rate variability before the onset of nonsustained and sustained ventricular tachycardia in patients with coronary artery disease, *Circulation*, số 87.4, tr. 1220-1228.
- [28]. Bergfeldt, Lennart, Yoshiyuki Haga (2003), Power spectral and Poincaré plot characteristics in sinus node dysfunction, *J Appl Physiol* (1985), số 94.6, tr. 2217-2224.
- [29]. Delgado-Bonal, Alfonso, Alexander Marshak (2019), Approximate Entropy and Sample Entropy: A Comprehensive Tutorial, *Entropy (Basel)*, số 21.6, tr. 541.
- [30]. Chiang, Jiun-Yang, et al. (2016), Detrended Fluctuation Analysis of Heart Rate Dynamics Is an Important Prognostic Factor in Patients with End-Stage Renal Disease Receiving Peritoneal Dialysis, *PLoS One*, số 11.2, tr. e0147282.
- [31]. Howley, Tom, et al (2006), The effect of principal component analysis on machine learning accuracy with high-dimensional spectral data, *Knowledge-Based Systems*, số 19, tr. 363-370.
- [32]. Shi, Junwei, et al. (2024), Time series prediction model using LSTM-Transformer neural network for mine water inflow, *Scientific Reports*, số 14, tr. 18284.



[33]. Wang, Yutong, Cindy Rubio-González (2024), Predicting Performance and Accuracy of Mixed-Precision Programs for Precision Tuning, *IEEE/ACM 46th International Conference on Software Engineering (ICSE)*, tr. 1-13.