

HYBRID QUANTUM NEURAL NETWORK AND APPLICATION IN WRITTEN IMAGE RECOGNITION

Truong Van Minh, Nguyen Minh Chien, Pham Si Anh Duc,
Nguyen Thi Hong, Nguyen Hoang Hung Gia, Dung Van Lu*

The University of Danang - University of Science and Education

ARTICLE INFO		ABSTRACT
Received:	21/4/2025	Presently, a plethora of neural network architectures, including Convolutional Neural Networks, Recurrent Neural Networks, Feedforward Neural Networks... have undergone significant advancements, effectively tackling a wide array of machine learning challenges. Nevertheless, these frameworks encounter substantial obstacles when addressing tasks involving voluminous data, often resulting in suboptimal precision or necessitating protracted computational durations. Therefore, this study proposed using a hybrid quantum neural framework that amalgamates classical machine learning paradigms with quantum computation. Quantum computation augments processing velocity and elevate precision through its capacity for parallel execution and the exploitation of distinctive quantum mechanical phenomena. In this investigation, we deployed the hybrid quantum neural framework by combining two platforms the PyTorch and Qiskit on the Visual Studio Code. Experimental results show that the model achieved accuracies of 98.5% and 93.3% in recognizing handwritten digits and letters, respectively, underscoring the transformative potential of hybrid quantum neural frameworks in complex recognition applications.
Revised:	26/6/2025	
Published:	28/6/2025	
KEYWORDS		
Quantum algorithm		
Quantum computing		
Hybrid-quantum neural network		
Image recognition		
PyTorch & Qiskit		

MẠNG NƠ-RON LƯỢNG TỬ LẠI VÀ ỨNG DỤNG TRONG NHẬN DẠNG HÌNH ẢNH VIẾT TAY

Trương Văn Minh, Nguyễn Minh Chiến, Phạm Sĩ Anh Đức,
Nguyễn Thị Hồng, Nguyễn Hoàng Hưng Gia, Dũng Văn Lữ*

Trường Đại học Sư phạm – Đại học Đà Nẵng

THÔNG TIN BÀI BÁO		TÓM TẮT
Ngày nhận bài:	21/4/2025	Hiện nay, nhiều mô hình mạng nơ-ron như mạng nơ-ron tích chập, mạng nơ-ron hồi tiếp, mạng nơ-ron truyền thẳng... phát triển mạnh mẽ và giải quyết được nhiều vấn đề trong học máy. Tuy nhiên, đối với những bài toán cần xử lý dữ liệu lớn thì mạng nơ-ron gặp một số thách thức chưa giải quyết được, độ chính xác thấp hay cần thời gian dài. Vì vậy, nghiên cứu này đề xuất sử dụng mô hình mạng nơ-ron lượng tử lai, kết hợp giữa máy học cổ điển và tính toán lượng tử. Tính toán lượng tử giúp tăng tốc tính toán và nâng cao độ chính xác nhờ khả năng xử lý song song và tính chất đặc trưng của cơ học lượng tử. Trong nghiên cứu này, chúng tôi triển khai mô hình mạng nơ-ron lượng tử lai bằng cách dùng kết hợp hai nền tảng Pytorch và Qiskit chạy trên Visual Studio Code. Kết quả thực nghiệm cho thấy mô hình đạt độ chính xác lần lượt đạt 98,5% và 93,3% trong nhận dạng số và chữ viết tay, khẳng định tiềm năng ứng dụng của mạng nơ-ron lượng tử lai trong các bài toán nhận dạng.
Ngày hoàn thiện:	26/6/2025	
Ngày đăng:	28/6/2025	
TỪ KHÓA		
Thuật toán lượng tử		
Tính toán lượng tử		
Mạng nơ-ron lượng tử lai		
Nhận dạng hình ảnh		
PyTorch và Qiskit		

DOI: <https://doi.org/10.34238/tnu-jst.12645>

* Corresponding author. Email: dvl@ued.udn.vn

1. Giới thiệu

Mạng nơ-ron lần đầu tiên được đề xuất vào năm 1943 bởi McCulloch và Pitts [1]. Mạng nơ-ron bao gồm một số lượng tùy ý các ô hoặc nút hoặc đơn vị hoặc nơ-ron kết nối bộ đầu vào với đầu ra. Sau một thời gian dài không nhận được sự chú ý, mô hình này được phát triển và trở thành công cụ tính toán hiệu quả trong những năm gần đây bằng cách xây dựng một số đơn vị xử lý dựa trên các nút khớp được kết nối với nhau. Đây là một trong các mô hình học máy đầy tiềm năng, được sử dụng để giải quyết các vấn đề phức tạp như nhận dạng hình ảnh, xe hay máy bay tự lái, dự đoán thị trường chứng khoán (dự đoán hành vi của người tiêu dùng), hệ thống phân tích rủi ro, phân tích chất lượng môi trường, phân tích chất lượng máy tính, thử nghiệm phòng cấp cứu, thăm dò dầu khí, xử lý ngôn ngữ tự nhiên và nhiều ứng dụng khác, đặc biệt các ứng dụng xử lý với dữ liệu lớn [2]. Gần đây, nhiều nhà khoa học quan tâm ứng dụng trong nghiên cứu tin sinh, điển hình như: nghiên cứu thông tin chi tiết về chức năng của protein có cấu trúc mới lạ [3], dự đoán cấu trúc của protein gấp với độ chính xác đáng kinh ngạc [4], [5], dự đoán ái lực liên kết protein-ligand [6], thiết kế protein và xác định các cấu trúc protein gấp cụ thể mới [7], hay cải tiến đề xuất mạng nơ-ron mờ (FNN) để tăng cường khả năng xử lý sự mơ hồ và cải thiện độ chính xác của phân loại [8]. Tuy nhiên mạng nơ-ron vẫn còn gặp những thách thức khi đối mặt với những bài toán có dữ liệu lớn, trong khi yêu cầu đặt ra cần tính toán nhanh và chính xác [9].

Bên cạnh đó, máy tính lượng tử được phát triển vượt bậc dựa trên tính toán lượng tử cùng với các thuật toán lượng tử siêu việt. Tính toán lượng tử sử dụng các nguyên lý của cơ học lượng tử để thực hiện các phép tính, thay vì sử dụng các bit truyền thống (0 và 1), tính toán lượng tử sử dụng các qubit mà có thể tồn tại ở nhiều trạng thái cùng một lúc nhờ hiện tượng chồng chất, vướng víu và giao thoa lượng tử [10]. Chính vì thế, nó có tốc độ xử lý vượt bậc, tính bảo mật cao và ứng dụng rộng rãi trong tất cả các lĩnh vực như hóa học, y học, tài chính, trí tuệ nhân tạo, hay tin sinh... [10]. Sự kết hợp mạng nơ-ron và tính toán lượng tử tạo ra một lĩnh vực mới là mạng nơ-ron lượng tử (*Quantum neural network: QNN*) hướng đến việc tận dụng ưu điểm của tính toán lượng tử để cải thiện tốc độ tính toán của mạng nơ-ron [11]. Trong đó, lan truyền ngược sử dụng các kỹ thuật lượng tử để tính toán và điều chỉnh các tham số của mạng [12]. Gần đây, năm 2025, đã có những kết quả nghiên cứu nổi bật như Wu và cộng sự [13] đã chỉ ra sự song song lượng tử để đạt được song song dữ liệu trong các mô hình mạng nơ-ron lượng tử. Đặc biệt là việc đề xuất một kiến trúc QNN để khám phá các dấu ấn sinh học di truyền cho các con đường kích hoạt đầu vào với tài nguyên tiết kiệm [14]. Tuy nhiên, sự phát triển chưa tối ưu của máy tính lượng tử vẫn còn lỗi mất kết hợp, đặc biệt là lỗi càng lớn khi giải quyết bài toán phức tạp cần nhiều qubit, chính vì thế mà QNN chưa giải quyết được các bài toán phức tạp với dữ liệu lớn. Do đó, chúng ta có thể kết hợp giữa mạng nơ-ron và tính toán lượng tử để tận dụng ưu điểm của cả hai loại tính toán này. Mạng nơ-ron lượng tử lai (*Hybrid quantum neural network: H-QNN*) có khả năng xử lý song song và tính chất đặc trưng của cơ học lượng tử giúp tăng tốc tính toán và nâng cao độ chính xác [15]. Đáng chú ý là Hafeez [16] đã đề xuất mô hình H-QNN để phân loại hình ảnh nhị phân, tận dụng thế mạnh của điện toán lượng tử và mạng nơ-ron cổ điển.

Với những cảm hứng đó, bài báo này nghiên cứu về H-QNN, sử dụng kết hợp giữa Pytorch và Qiskit chạy trên nền tảng Visual Code Studio với ngôn ngữ lập trình là Python để nhận dạng hình ảnh với chữ và số viết tay. Kết quả thu được đạt độ chính xác lần lượt 98,5% và 93,3% cho nhận diện số và chữ viết tay. Thông qua quá trình so sánh với phương pháp cổ điển, thể hiện được ưu thế của phương pháp tính toán lượng tử trong việc cải thiện khả năng xử lý hình ảnh với hiệu suất cao. Triển khai mô hình H-QNN sử dụng kết hợp PyTorch và Qiskit ít được nghiên cứu cụ thể trước đó, vì vậy nghiên cứu này áp dụng mô hình vào nhận dạng chữ và số viết tay hỗ trợ tích cực trong các nghiên cứu mạng lai lượng tử AI. Nội dung tiếp theo trong bài báo đưa ra phương pháp tính toán ở phần 2, kết quả thực hiện được báo cáo ở phần 3 và cuối cùng là Kết luận.

2. Phương pháp nghiên cứu

2.1. Phương pháp xác định các chỉ số lỗi và độ chính xác

Hiệu suất nhận dạng mô hình mạng nơ-ron lai được đánh giá thông qua 2 chỉ số: Chỉ số lỗi (*Loss*) và Độ chính xác (*Accuracy*). Trong đó, chỉ số lỗi không được tính toán trực tiếp thông qua số lượng nhận dự đoán đúng, mà dựa trên mức độ sai trên từng lô (*batch*) được kiểm tra. Như vậy, khi kết hợp với chỉ số độ chính xác có thể đánh giá được mô hình có rơi vào trường hợp “quá khớp (*overfitting*)” hay không? Các chỉ số lỗi và độ chính xác được xác định như sau:

$$\text{Chỉ số lỗi} = \frac{\text{Lỗi trung bình từng lô kiểm tra}}{\text{Số lượng lô kiểm tra}} \quad (1)$$

$$\text{Độ chính xác} = \frac{\text{Số dự đoán đúng}}{\text{Tổng số mẫu}} \quad (2)$$

Có thể thấy tồn tại hai trường hợp khi mô hình có độ chính xác cao: Lỗi cao và lỗi thấp. Khi chỉ số lỗi thấp với độ chính xác cao, dễ dàng thấy hiệu suất hoạt động của mô hình được đánh giá cao. Ngược lại, chỉ số lỗi cao kết hợp với độ chính xác cao, điều này thể hiện xác suất dự đoán giữa các nhãn không có quá nhiều chênh lệch, tuy nhiên nhãn đúng vẫn có xác suất cao nhất. Do vậy, chỉ số độ chính xác không hoàn toàn phản ánh được hiệu suất học của mô hình. Nhằm hỗ trợ phân tích chỉ số lỗi, phương pháp thông dụng để khảo sát chỉ số lỗi là so sánh *loss* kiểm tra với *loss* huấn luyện và đường cơ sở (*Baseline*), khi đó có thể đánh giá khả năng học của mô hình một cách tổng quát sau khi huấn luyện. Nếu *loss* kiểm tra có giá trị gần với *loss* huấn luyện, vượt xa giá trị *baseline* thì mô hình có khả năng học hỏi, tổng quát hóa các giá trị của ảnh tốt nhằm dự đoán đúng dữ liệu không thuộc tập dữ liệu huấn luyện.

2.2. Cơ sở tính toán lượng tử

Thế mạnh của mô hình H-QNN ở việc áp dụng các tính chất độc đáo của cơ học lượng tử như tính chồng chất, vướng víu và giao thoa lượng tử trong không gian vector Hilbert [10]. Chồng chất lượng tử là trạng thái hệ lượng tử có thể tồn tại đồng thời ở nhiều trạng thái khác nhau với những trọng số (xác suất) riêng. Mỗi trạng thái qubit nói chung là sự chồng chất của các trạng thái cơ sở, chẳng hạn trạng thái bất kỳ của hệ hai qubit là chồng chất từ bốn trạng thái cơ sở:

$$|\psi\rangle = a|00\rangle + b|01\rangle + c|10\rangle + d|11\rangle \quad (3)$$

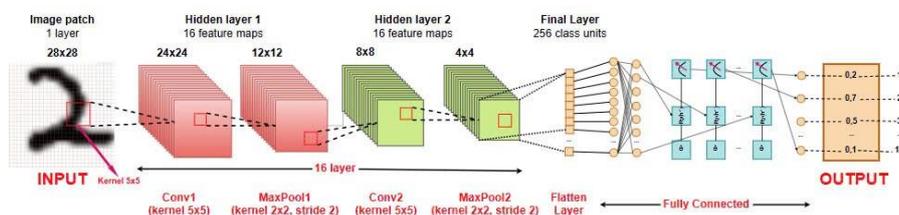
trong đó, $a, b, c,$ và d là các hệ số phức, còn gọi là biên độ trạng thái, thỏa mãn điều kiện chuẩn hóa $|a|^2 + |b|^2 + |c|^2 + |d|^2 = 1$. Như vậy, trạng thái $|\psi\rangle$ là sự kết hợp tuyến tính của các trạng thái cơ sở, các hệ số tương ứng cho biết các khả năng xảy ra các trạng thái đó. Với hệ n qubit, trạng thái lượng tử có thể tồn tại ở dạng chồng chất của 2^n trạng thái cơ sở.

Vướng víu lượng tử hay rối lượng tử là tính chất mà một trạng thái hệ lượng tử của hai hay nhiều trạng thái con có liên kết với nhau, khi thực hiện một phép đo trên trạng thái này thì ngay lập tức có ảnh hưởng đến trạng thái được vướng víu. Tức là, một trạng thái vướng víu $|\psi\rangle$ không thể biểu diễn bởi tích tensor của hai trạng thái con $|\psi_1\rangle \otimes |\psi_2\rangle$, sự vướng víu xảy ra với các trạng thái đa qubit. Ví dụ, trạng thái vướng víu của hệ hai qubit là $|\psi\rangle = (|00\rangle + |01\rangle)/\sqrt{2}$, trạng thái vướng víu của hệ ba qubit là $|\psi\rangle = (|001\rangle + |111\rangle)/\sqrt{2}$ hoặc $|\psi\rangle = (|001\rangle + |010\rangle + |100\rangle)/\sqrt{3}$.

Giao thoa lượng tử là các trạng thái lượng tử tác động lẫn nhau, làm tăng hoặc giảm xác suất xảy ra của một trạng thái.

Trên mạch lượng tử bao gồm các thanh ghi, qubit các cổng lượng tử có chức năng thực hiện các phép toán tương tác giữa các trạng thái qubit hoặc tạo ra sự biến đổi giữa các trạng thái lượng tử. Trong nghiên cứu này, chúng tôi sử dụng một số cổng lượng tử như cổng chuyển pha R, cổng Hadamard H... [10].

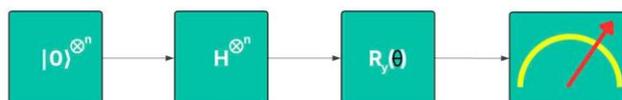
2.3. Mạng nơ-ron lượng tử lai



Hình 1. Mô hình mạng nơ-ron lai lượng tử

Mô hình mạng nơ-ron lượng tử lai được xây dựng như Hình 1, đầu vào của mô hình là các hình ảnh có kích thước 28x28 pixel và được trích xuất đặc trưng thông qua lớp tích chập (“conv1”, “conv2”) có 16 kênh đầu ra với hạt nhân (*Kernel*) kích thước 5x5 pixel. Các giá trị được trích xuất sẽ được làm nổi bật thông qua lớp *max pooling* có hạt nhân kích thước 2x2 pixel. Sau đó, các giá trị đặc trưng được chuyển thành các vector thông qua lớp kết nối đầy đủ, giảm từ 256 xuống 10 chiều ở các lớp “fc” và được đưa trực tiếp vào các giá trị θ ở các cổng xoay nhằm thực hiện tính toán lượng tử. Mạch lượng tử nằm ở lớp gần cuối của mô hình, đóng vai trò phân loại dữ liệu được trích xuất tại các lớp trước đó. Cuối cùng, đầu ra mạch lượng tử là các giá trị kì vọng Z_i được đưa trở lại mạng nơ-ron cổ điển nhằm thực hiện dự đoán kết quả bằng hàm *softmax*.

2.3.1. Mã hoá biên độ và mạch lượng tử



Hình 2. Mạch lượng tử của lớp lượng tử

Hình 2 mô tả mạch lượng tử của lớp lượng tử trong mô hình mạng lai: thanh ghi nhận dữ liệu đầu vào, qua cổng H (tạo trạng thái chồng chất), cổng R (đảo pha trạng thái), các giá trị đầu ra của mạch lượng tử là các giá trị kì vọng Z_i sẽ được đưa trở lại vào các nơ-ron của máy tính cổ điển để thực hiện dự đoán. Với một hình ảnh có kích thước $H \times W$, các điểm ảnh được chuẩn hóa biên độ về khoảng $[0, 1]$, vì vậy được bổ sung thêm chiều kênh và đạt định dạng $(1, H, W)$. Thực hiện chuẩn hóa biên độ các phần tử:

$$(x_i)_{\text{chuẩn hóa}} = \frac{x_i}{\sqrt{\sum_{i=1}^d |x_i|^2}} = \frac{x_i}{\|x\|} \quad (4)$$

Các giá trị pixel sau khi được chuẩn hóa biên độ khi đưa vào lớp đầu vào của mạng nơ-ron có kí hiệu là x , tại mỗi nút mạng nơ-ron lớp kế tiếp là tổng hợp các đặc trưng x_i của lớp trước. Như vậy đầu vào mạch lượng tử là tổng hợp các đặc trưng lớp trước đó được thực hiện trên lớp nơ-ron và thu được giá trị:

$$h_1 = \sigma(w_1 x_1 + w_3 x_2 + w_5 x_3) \quad (5)$$

$$h_2 = \sigma(w_2 x_1 + w_4 x_2 + w_6 x_3) \quad (6)$$

Với σ là hàm kích hoạt (hoặc hàm tuyến tính) và w_i là các trọng số giữa các nơ-ron. Kết quả đầu ra của lớp đầu vào mạng nơ-ron sẽ được đưa vào công xoay $R_y(h_i)$ nhằm thực hiện biến đổi và tính toán phức tạp trong không gian Hilbert.

Đầu ra mạch lượng tử Z_i được xác định dựa trên xác suất đo của trạng thái $|0\rangle$ và $|1\rangle$ của từng thanh ghi. Cụ thể, giá trị kì vọng được tính toán dựa trên công thức:

$$Z_i = P_i |0\rangle - P |1\rangle \quad (7)$$

Thực hiện các phép đo xác suất trên các qubit, phép đo làm trạng thái chồng chất sụp đổ thành trạng thái thành phần với xác suất tương ứng:

$$P(|i\rangle) = |\langle i|\psi\rangle|^2 = |x_i|^2 \quad (8)$$

Trong đó, xác suất đo của từng trạng thái được xác định:

$$P|0\rangle = \left| \frac{1}{\sqrt{2}} \left[\cos\left(\frac{\theta}{2}\right) + \sin\left(\frac{\theta}{2}\right) \right] \right|^2 \quad (9)$$

$$P|1\rangle = \left| \frac{1}{\sqrt{2}} \left[\cos\left(\frac{\theta}{2}\right) - \sin\left(\frac{\theta}{2}\right) \right] \right|^2 \quad (10)$$

2.3.2. Điều chỉnh trọng số

Để tối ưu hóa mô hình sử dụng phương pháp điều chỉnh trọng số bằng lan truyền ngược và giảm dần độ dốc. Lan truyền ngược tính độ dốc hiệu quả, truyền lỗi từ đầu ra về đầu vào để cập nhật trọng số, giảm sai số và tìm cực trị tối ưu. Trong mạch lượng tử, giảm dần độ dốc được điều chỉnh, xem mạch như hộp đen với tham số θ và độ xê dịch s , tính độ dốc bằng:

$$\nabla_{\theta} = \text{Mạch lượng tử}(\theta + s) - \text{Mạch lượng tử}(\theta - s) \quad (11)$$

Phương pháp này đặc biệt phù hợp đặc trưng lượng tử khi đạo hàm trực tiếp khó thực hiện. Hàm mất mát "Mất mát xác suất logarit âm" (NLLLoss),

$$L = -\frac{1}{N} \sum \log P(y_i | x_i) \quad (12)$$

đánh giá sai lệch giữa dự đoán và thực tế, với N là số mẫu, $P(y_i | x_i)$ là xác suất dự đoán, y_i và x_i là nhãn thực tế và dự đoán. Giá trị L trung bình trên lô giúp truyền ngược, điều chỉnh trọng số để cải thiện mô hình qua từng vòng huấn luyện. Sự kết hợp này tận dụng sức mạnh cổ điển và lượng tử, với hàm mất mát làm cầu nối để tối ưu hiệu quả.

Phương pháp lan truyền ngược cổ điển được kết hợp với từng phần tử giá trị kì vọng Z_i nhằm đưa ra công thức tổng quát cho quá trình cập nhật các trọng số mạng cổ điển ϕ (bao gồm trọng số và các tham số bias) và mạng lượng tử θ . Công thức toán học cụ thể của phương pháp như sau:

$$\frac{\partial L}{\partial \phi} = \sum_i \frac{\partial L}{\partial Z_i} \cdot \frac{\partial Z_i}{\partial \theta_i} \cdot \frac{\partial \theta_i}{\partial \phi} \quad (13)$$

Trong đó, giá trị L là chỉ số lỗi, được xác định bằng hàm mất mát đã được nhắc đến trong phần công cụ đánh giá, giá trị $\frac{\partial Z_i}{\partial \theta_i}$ là giá trị được tính trong phương pháp điều chỉnh trọng số trong mạng lượng tử ∇_{θ} . Sau cùng, giá trị ϕ được cập nhật trong hàm khi sử dụng kết quả hàm $\frac{\partial L}{\partial \phi}$ bằng thuật toán tối ưu hóa Adam [17].

3. Kết quả và bàn luận

3.1. Thực hiện trình huấn luyện và kiểm tra

Dữ liệu huấn luyện và kiểm tra cho mô hình H-QNN cho nhận diện chữ số viết tay được lấy từ tập dữ liệu "Digits", thuộc bộ dữ liệu mã nguồn mở EMNIST [18] gồm 120.000 hình ảnh huấn luyện và 20.000 hình ảnh kiểm tra. Hình 3 là ví dụ cho một số hình ảnh chữ số viết tay. Đối với nhận diện chữ viết tay, mô hình lấy dữ liệu huấn luyện và kiểm tra từ tập dữ liệu "Chữ viết tay trong định dạng .csv" bao gồm 1000 ảnh huấn luyện và 200 ảnh kiểm tra cho mỗi nhãn. Tất cả hình ảnh đều được chuẩn hóa trên thang độ xám và có kích thước 28×28 pixel [18]. Trong quá trình huấn luyện, tệp hình ảnh được chia thành các lô hình ảnh nhỏ hơn (batch) gồm 32 hình ảnh và các chỉ số lỗi và độ chính xác được cập nhật theo từng lô của từng lần học (epoch). Dựa vào trình tự và cấu trúc mạng được phân tích ở trên, yêu cầu cần thiết kế mã nguồn phù hợp cho lớp "Hybrid" và "Net" nhằm kết hợp điện toán lượng tử và mạng nơ-ron cổ điển. Tham khảo mã xây dựng lớp "Hybrid" và "Net" theo liên kết [19].

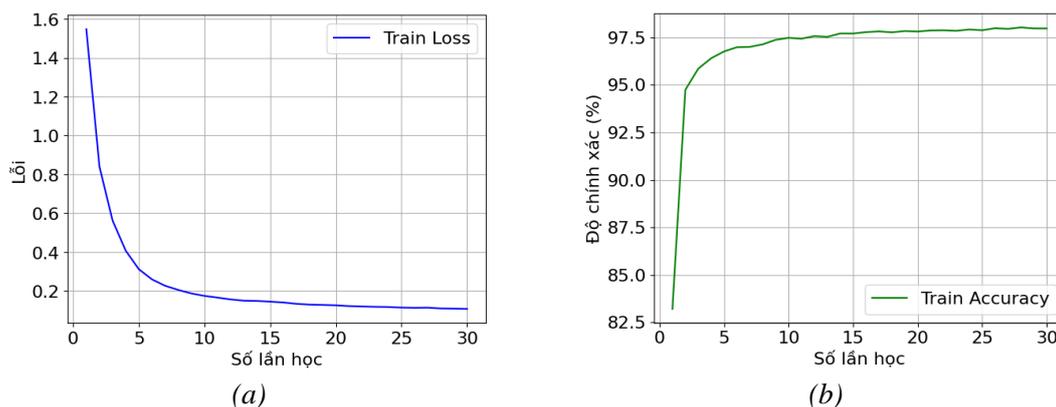
3.2. Kết quả thực nghiệm

Cấu trúc H-QNN yêu cầu phần cứng máy tính tối thiểu có hoặc có thể mô phỏng được 10 qubit với bộ nhớ đủ lớn nhằm lưu trữ và xử lý thông tin, dữ liệu của lượng lớn hình ảnh. Do vậy

nhằm có thể đáp ứng hai điều kiện trên, mô hình được thực hiện hóa trên trình soạn thảo mã nguồn miễn phí đa nền tảng Visual Code Studio được Microsoft phát triển, sử dụng môi trường lập trình Python 11 với khung làm việc Pytorch [20].



Hình 3. Một số hình ảnh chữ viết tay trong bộ dữ liệu EMNIST



Hình 4. Kết quả tìm kiếm huấn luyện mạng nơ-ron lai nhận diện số từ bộ dữ liệu "EMNIST":

(a) Lỗi và (b) Độ chính xác

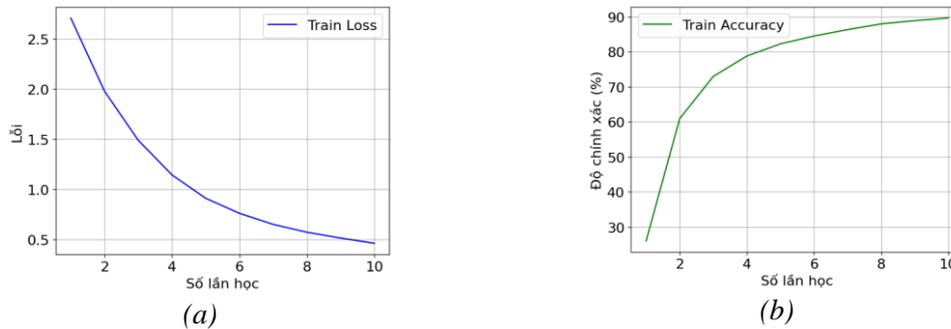
Dựa vào đồ thị lỗi trung bình và số liệu được đưa ra trong Hình 4, mô hình có khả năng dự đoán số viết tay xuất sắc trong khi lỗi trong quá trình huấn luyện thấp dần và hội tụ qua từng lần học. Tại 10 lần học đầu tiên, giá trị lỗi trung bình giảm mạnh và có xu hướng dần hội tụ về giá trị thấp nhất. Sau 30 lần học, chỉ số lỗi huấn luyện đạt giá trị thấp nhất 0,0862 với độ chính xác huấn luyện 98,3%; độ chính xác trung bình khi mô hình nhận dạng tập kiểm tra đạt 98,5% với chỉ số lỗi đạt giá trị 0,0858 được thể hiện trong Bảng 1. Phân tích chỉ số lỗi cho thấy, mô hình có khả năng tổng quát hóa các dữ liệu ảnh tốt, có khả năng học hỏi tốt khi so sánh chỉ số lỗi trong quá trình nhận dạng kiểm tra với giá trị baseline ($\approx 2,30$), do đó có thể nhận dạng tốt chữ số trong ảnh thuộc tập kiểm tra với độ chính xác cao.

Bảng 1. So sánh phương pháp mạng nơ-ron cổ điển và mạng nơ-ron lai lượng tử số viết tay

Phương pháp	Mẫu huấn luyện	Mẫu kiểm tra	Lỗi	Độ chính xác
Mạng nơ-ron cổ điển	1000	200	0,087	97,7%
Mạng nơ-ron lai lượng tử	1000	200	0,086	98,5%

Khi mô hình được huấn luyện với bộ dữ liệu chữ viết tay trong định dạng ".csv" (A-Z Handwritten Alphabets in .csv format) [21], mô hình thực hiện huấn luyện với độ chính xác trung bình đạt tỉ lệ 90,1% và giá trị lỗi đạt 0,48 sau 10 lần học như được thể hiện trên Hình 5, độ chính xác trung bình khi mô hình nhận dạng tập kiểm tra đạt 93,3% với chỉ số lỗi đạt giá trị 0,31 được thể hiện trong Bảng 2. Khi phân tích các chỉ số, giá trị lỗi và độ chính xác tại lần huấn luyện cuối cùng, nó trở nên hội tụ và lỗi của quá trình nhận dạng tập kiểm tra thấp hơn giá trị quá trình huấn luyện, vượt xa giá trị baseline ($\approx 3,25$). Như vậy, mô hình vẫn có khả năng tổng quát hóa và học hỏi tốt với bộ dữ liệu phức tạp hơn, nhận dạng tốt các hình ảnh trong tập kiểm tra.

Từ kết quả thu được, các chỉ số độ chính xác có sự gia tăng cũng như các chỉ số lỗi có sự giảm nhẹ khi nhận diện trên tập kiểm tra đối với chữ và số viết tay. Điều này là do trong quá trình huấn luyện, chúng tôi sử dụng kỹ thuật chuẩn hóa như dropout để giảm thiểu sự "quá khớp" dẫn đến giảm hiệu suất trong huấn luyện. Trong khi đó, khi đánh giá trên tập kiểm tra (kỹ thuật chuẩn hóa dropout bị giảm tác dụng), mô hình có thể hoạt động tốt hơn dẫn đến sự tăng độ chính xác kiểm tra.



Hình 1. Kết quả từng lần huấn luyện mạng nơ-ron lai nhận diện từ bộ dữ liệu “Chữ viết tay trong định dạng .csv”: (a) Lỗi và (b) Độ chính xác

Kết quả giữa mạng nơ-ron cổ điển và mô hình kết hợp mạng nơ-ron lai lượng tử được so sánh trong Bảng 1 và Bảng 2. Từ đó cho thấy, việc kết hợp mạng lượng tử có độ chính xác cao hơn và cải thiện được chỉ số lỗi, có thể hiểu rằng việc thêm lớp lượng tử giúp mô hình dễ dàng phân biệt các nhãn hơn thông qua cơ chế đánh giá lỗi.

Bảng 2. So sánh phương pháp mạng nơ-ron cổ điển và mạng nơ-ron lai lượng tử chữ viết tay

Phương pháp	Mẫu huấn luyện	Mẫu kiểm tra	Lỗi	Độ chính xác
Mạng nơ-ron cổ điển	1000	200	0,323	93,2%
Mạng nơ-ron lai lượng tử	1000	200	0,314	93,3%

4. Kết luận

Việc tích hợp tính toán lượng tử vào mạng nơ-ron mang lại những cải thiện đáng kể trong hiệu suất mô hình. Cụ thể, mô hình không chỉ đạt độ chính xác cao hơn với độ chính xác trung bình đạt 98,5% cho nhận diện số viết tay và 93,3% cho nhận diện chữ viết tay, mà còn gia tăng được “độ tự tin dự đoán” so với mạng nơ-ron cổ điển thông qua chỉ số lỗi. Đây là một minh chứng cho tiềm năng của tính toán lượng tử trong việc hỗ trợ các mô hình học sâu hiện đại.

Nghiên cứu này đề xuất một cách tiếp cận khác trong lĩnh vực nhận dạng hình ảnh, dựa trên H-QNN, các lớp mạng nơ-ron cổ điển đóng vai trò trích xuất dữ liệu ảnh và sử dụng hàm *softmax* để phân loại, còn mạng lượng tử đóng vai trò quan trọng trong xử lý và tính toán dữ liệu nhằm tối ưu hóa khả năng huấn luyện và tăng khả năng biểu diễn, nhờ vào tính chất lượng tử giúp giảm chiều sâu của mạch, giảm số lượng tham số, đồng thời đảm bảo được kết quả đầu ra. Trong các nghiên cứu sau, hứa hẹn triển khai trên phần cứng lượng tử thật và phát triển các lớp mạng được thay thế bằng mạng lượng tử và được tính toán trên các phần cứng lượng tử hoàn toàn.

Lời cảm ơn

Nghiên cứu được tài trợ bởi Quỹ Phát triển khoa học và công nghệ Quốc gia (NAFOSTED) trong đề tài mã số: 102.05-2023.49.

TÀI LIỆU THAM KHẢO/REFERENCES

- [1] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *Bull. Math. Biophys.*, vol. 5, pp. 115–133, 1943, doi: 10.1007/BF02478259.
- [2] R. Dastres and M. Soori, “Artificial neural network systems,” *Int. J. Imag. Robot.*, vol. 21, no. 2, pp. 13–25, 2021.
- [3] M. Baek *et al.*, “Accurate prediction of protein structures and interactions using a three-track neural network,” *Science*, vol. 373, no. 6557, pp. 871–876, 2021, doi:10.1126/science.abj8754.
- [4] J. Jumper *et al.*, “Highly accurate protein structure prediction with AlphaFold,” *Nature*, vol. 596, no. 7873, pp. 583–589, 2021.
- [5] D. T. Jones and J. M. Thornton, “The impact of AlphaFold2 one year on,” *Nat. Methods*, vol. 19, pp. 11–26, 2022.
- [6] F. S. Zariquiey, R. Galvelis, E. Gallicchio, J. D. Chodera, T. E. Markland, and G. de Fabritiis, “Enhancing protein-ligand binding affinity predictions using neural network potentials,” *arXiv*

- preprint arXiv:2401.00002*, 2024.
- [7] J. L. Watson *et al.*, “De novo design of protein structure and function with RFdiffusion,” *Nature*, vol. 620, no. 7976, pp. 1089–1100, 2023.
- [8] N. Q. K. Le, V. N. Nguyen, T. T. Nguyen, T. X. Tran, and T. T. Ho, “Enhancing protein sequence classification with a fuzzy neural network: A study in anticancer peptide identification,” in *Proc. 2024 Int. Conf. Fuzzy Theory Appl. (iFUZZY)*, Aug. 2024, pp. 1–6.
- [9] N. J. Ogbuke, Y. Y. Yusuf, K. Dharma, and B. Mercangoz, “Big data supply chain analytics: Ethical, privacy and security challenges posed to business, industries and society,” *Prod. Plan. Control*, vol. 33, no. 2–3, pp. 123–137, 2022, doi: 10.1080/09537287.2020.1810764.
- [10] M. A. Shafique, A. Munir, and I. Latif, “Quantum computing: Circuits, algorithms, and applications,” *IEEE Access*, vol. 12, pp. 22296–22314, 2024.
- [11] H. Padmanaban, “Quantum computing and AI in the cloud,” *J. Comput. Intell. Robot.*, vol. 4, no. 1, pp. 14–32, 2024.
- [12] Y. Kwak, W. J. Yun, S. Jung, and J. Kim, “Quantum neural networks: Concepts, applications, and challenges,” in *Proc. 12th Int. Conf. Ubiquitous Future Netw. (ICUFN)*, Aug. 2021, pp. 413–416.
- [13] S. Wu, Y. Zhang, and J. Li, “Quantum data parallelism in quantum neural networks,” *Phys. Rev. Res.*, vol. 7, no. 1, 2025, Art. no. 013177.
- [14] P. N. Nguyen, “Biomarker discovery with quantum neural networks: A case-study in CTLA4-activation pathways,” *BMC Bioinformatics*, vol. 25, no. 1, 2024, Art. no. 149.
- [15] M. Kashif, A. Marchisio, and M. Shafique, “Computational advantage in hybrid quantum neural networks: Myth or reality?,” *arXiv preprint arXiv:2412.04991*, 2024.
- [16] M. A. Hafeez, A. Munir, and H. Ullah, “H-QNN: A hybrid quantum–classical neural network for improved binary image classification,” *AI*, vol. 5, no. 3, pp. 1462–1481, 2024.
- [17] R. Agarwal, “Complete Guide to the Adam Optimization Algorithm,” Built In, 2023. [Online]. Available: <https://builtin.com/machine-learning/adam-optimization>. [Accessed March 7, 2025].
- [18] Ultralytics, “MNIST Dataset,” 2023. [Online]. Available: <https://docs.ultralytics.com/datasets/classify/mnist/#key-features>. [Accessed Mar. 20, 2025].
- [19] V. M. Truong and M. C. Nguyen, “Quantum hybrid neural network structure,” (in Vietnamese), 2024. [Online]. Available: <https://drive.google.com/drive/folders/1Sh7O87q22BCZL9cdmPFjW9fdurk2u7Ng?usp=sharing>. [Accessed Jan 8, 2025].
- [20] N. Ketkar and M. Masko, *Deep Learning with PyTorch: A Practical Approach to Building Neural Network Models Using PyTorch*. Apress, 2019.
- [21] S. Patel, “A-Z handwritten alphabets in CSV format,” *Kaggle*, 2020. [Online]. Available: <https://www.kaggle.com/datasets/sachinpatel21/az-handwritten-alphabets-in-csv-format>. [Accessed Jan 19, 2025].