

Power System Transient Stability Recognition based on Bidirectional Long Short-Term Memory - Fully Connected Neural Networks

Viet Thinh Phan^{1*}, Ngoc Au Nguyen²

¹Dongnai College of High Technology, Vietnam

²Ho Chi Minh City University of Technology and Education, Vietnam

*Corresponding author. Email: phanvietthinh1978@gmail.com

ARTICLE INFO

Received: 08/12/2024
Revised: 17/01/2025
Accepted: 04/02/2025
Published: 28/05/2025

KEYWORDS

Transient stability recognition;
Power system instability;
Deep neural networks;
BiLSTM neural networks;
Fully connected neural networks.

ABSTRACT

Fast recognition of power system transient instability is one of the important solutions to prevent power grid collapse. Traditional analysis methods are slow in making control decisions, and simulation methods require much time and are not feasible, neural networks overcome this drawback because they calculate quickly and accurately. This paper introduces the application of BiLSTM-FC (Bidirectional Long Short-Term Memory - Fully Connected) deep neural network architecture to identify the transient stability of power systems, and it applies a confusion matrix to test the recognition accuracy of each layer. Simulations to determine stable or unstable power systems are performed on IEEE 39bus power systems with the help of PowerWorld software to create a network training database. The test results comparing the performance between BiLSTM-FC and BiLSTM architectures show that BiLSTM-FC architecture achieves better performance than BiLSTM architecture. The BiLSTM-FC has a validation accuracy as high as 99.5%. Compared with BiLSTM, BiLSTM-FC has 2.77% higher validation accuracy.

Nhận Dạng Ổn Định Quá Độ Hệ Thống Điện dựa trên Mạng Neural Bộ Nhớ Dài Ngắn Hạn Hai Chiều - Kết Nối Đầy Đủ

Phan Việt Thịnh^{1*}, Nguyễn Ngọc Âu²

¹Trường Cao đẳng Công nghệ cao Đồng Nai, Việt Nam

²Trường Đại học Sư phạm Kỹ thuật Thành phố Hồ Chí Minh, Việt Nam

*Tác giả liên hệ. Email: phanvietthinh1978@gmail.com

THÔNG TIN BÀI BÁO

Ngày nhận bài: 08/12/2024
Ngày hoàn thiện: 17/01/2025
Ngày chấp nhận đăng: 04/02/2025
Ngày đăng: 28/05/2025

TỪ KHÓA

Nhận dạng ổn định quá độ;
Mất ổn định hệ thống điện;
Mạng neural sâu;
Mạng neural BiLSTM;
Mạng neural fully connected.

TÓM TẮT

Nhận dạng nhanh mất ổn định quá độ hệ thống điện là một trong những giải pháp quan trọng giúp ngăn chặn tình trạng tan rã lưới điện. Phương pháp phân tích truyền thống tốn nhiều thời gian giải gây chậm trễ trong việc ra quyết định điều khiển, phương pháp mô phỏng thì đòi hỏi rất nhiều thời gian và không khả thi, mạng neural khắc phục được nhược điểm này nhờ tính toán nhanh chóng và chính xác. Bài báo này giới thiệu áp dụng kiến trúc mạng neural sâu BiLSTM-FC (Bidirectional Long Short-Term Memory - Fully Connected) để nhận dạng ổn định quá độ hệ thống điện và áp dụng ma trận nhầm lẫn vào kiểm tra kết quả độ chính xác nhận dạng của từng lớp riêng. Mô phỏng để xác định hệ thống điện ổn định hoặc không ổn định được thực thi trên hệ thống điện IEEE 39bus với sự trợ giúp của phần mềm PowerWorld để tạo cơ sở dữ liệu huấn luyện mạng. Kết quả kiểm tra so sánh hiệu suất giữa kiến trúc BiLSTM-FC và BiLSTM cho thấy kiến trúc BiLSTM-FC đạt hiệu suất tốt hơn kiến trúc BiLSTM. BiLSTM-FC cho độ chính xác cao đến 99,5%. So với BiLSTM, BiLSTM-FC có độ chính xác kiểm tra cao hơn 2,77%.

Doi: <https://doi.org/10.54644/jte.2025.1739>

Copyright © JTE. This is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/) which permits unrestricted use, distribution, and reproduction in any medium for non-commercial purpose, provided the original work is properly cited.

1. Giới thiệu

Trong các hệ thống điện (HTĐ) hiện đại, việc sử dụng thiết bị điện tử công suất ngày càng tăng và sự tác động của các nguồn năng lượng tái tạo đã làm tăng đáng kể độ phức tạp vận hành và điều khiển HTĐ [1], [2]. Trong khi đó, nhu cầu phụ tải ngày càng tăng cao, HTĐ phải làm việc ở mức đầy tải, đưa HTĐ vận hành ngày càng tiến gần đến ranh giới an toàn và ổn định [3]. Trong vận hành, các kích động lớn diễn ra đột ngột sẽ tạo ra sự chênh lệch công suất phát-tải và điện áp tại các bus, phá vỡ trạng thái cân bằng mômen của các máy phát điện đồng bộ dẫn đến lệch lớn góc rotor, quá trình quá độ xảy ra và HTĐ ổn định phụ thuộc khả năng duy trì đồng bộ và cân bằng mômen của các máy điện đồng bộ [4].

Để đánh giá ổn định quá độ (Transient Stability Assessment-TSA), phương pháp mô phỏng miền thời gian chính xác và phổ biến nhất nhưng đòi hỏi giải một tập lớn phương trình vi phân. Đối với mô hình có kích thước lớn và tham số nhiều, việc mô phỏng từng bước mất nhiều thời gian nên khó đưa ra dự đoán trực tuyến nhanh chóng [5]. Phương pháp trực tiếp thuận lợi cho việc phân tích sự cố và xác định được biên giới hạn ổn định quá độ (Transient Stability-TS). Tuy nhiên, phương pháp này dựa vào công thức toán học giải hệ phương trình vi phân phi tuyến nên trở nên khó khăn trong các hệ thống lớn [6]. Phương pháp hàm năng lượng quá độ và tiêu chuẩn điện tích bằng nhau mở rộng có một số hạn chế về mô hình và chúng yêu cầu nhiều phép tính để tính chỉ số TS [7]. Do các phương pháp TSA truyền thống tính toán phức tạp, mất nhiều thời gian nên việc ứng dụng các phương pháp học máy (Machine Learning-ML) trong HTĐ là giải pháp mới để giải quyết độ phức tạp tính toán của những bài toán ổn định có tính phi tuyến mạnh, nhiều chiều [8], [9]. Nhiều kỹ thuật ML khác nhau như mạng neural nhân tạo (Artificial Neural Networks-ANN) [10], [11], máy vectơ hỗ trợ (Support Vector Machine-SVM) [12], [13] và cây quyết định (Decision Tree-DT) [14] đã được nghiên cứu áp dụng trong TSA của HTĐ.

Học sâu (Deep Learning-DL) là công nghệ tiên tiến nhất trong lĩnh vực ML, có ưu điểm trích chọn đặc trưng tự động nên được sử dụng rộng rãi trong đánh giá ổn định và an ninh HTĐ [15]. Do sự cải thiện về hiệu suất tính toán và dung lượng dữ liệu, DL cho thấy hiệu suất vượt trội về độ chính xác và độ tin cậy so với ML thông thường [16]. Trong DL, mạng neural sâu (Deep Neural Networks-DNN) có nhiều ứng dụng thành công trong nhiều lĩnh vực khác nhau, chẳng hạn như nhận dạng hình ảnh và xử lý ngôn ngữ, chúng cũng có tiềm năng lớn để thay đổi cách thức giám sát, phân tích và kiểm soát lưới điện ngày nay [17]. Mạng neural tích chập (Convolutional Neural Networks-CNN), mạng niềm tin sâu (Deep Belief Networks-DBN), mạng neural hồi quy (Recurrent Neural Networks-RNN) là các kiến trúc phổ biến được sử dụng để tạo các mô hình DL. CNN là một trong những mô hình DL mạnh mẽ nhất chủ yếu được sử dụng trong lĩnh vực thị giác máy tính và hình ảnh. Tuy nhiên, do độ chính xác cao trong việc học và khái quát hóa các hàm và mẫu phi tuyến phức tạp, nên loại mạng này hiện đang ngày càng nhận được sự chú ý trong nhiều nhiệm vụ học thuật và công nghiệp [18]. Đối với các bài toán phân loại chung, DBN được sử dụng rộng rãi. RNN là một kiến trúc DL chủ yếu được sử dụng để xử lý dữ liệu tuần tự. RNN có khả năng tích lũy thông tin trong quá khứ vì nó sở hữu bộ nhớ và loại được sử dụng rộng rãi là bộ nhớ dài ngắn hạn (Long Short-Term Memory-LSTM) [19].

Nhiều công trình đã được giới thiệu áp dụng trong TSA. [20] đề xuất CNN để TSA dựa trên ổn định góc, biên độ điện áp và pha điện áp. DBN áp dụng để TSA dựa trên công suất tác dụng, phản kháng của đường dây truyền tải, điện áp bus và góc điện áp [21]. RNN với các đơn vị LSTM được sử dụng để dự đoán ranh giới TS dựa trên dòng công suất và điện áp của mạng truyền tải [22]. LSTM được sử dụng để TSA dựa trên các đặc điểm cụm quỹ đạo của các góc công suất của máy phát sau khi khắc phục sự cố [23]. Recurrent Convolutional Neural Networks (RCNN) kết hợp CNN và LSTM TSA và ổn định điện áp ngắn hạn dựa trên góc rotor và biên độ điện áp [24]. [25] đề xuất CNN song song và Gated Recurrent Unit (GRU) để TSA dựa trên góc công suất của mỗi máy phát trong giai đoạn sau nhiễu loạn. Graph Convolutional Neural Networks (GCNN) và Deep Reinforcement Learning (DRL) TSA dựa trên trạng thái dòng điện-dòng công suất [26]. Recurrent Graph Convolutional Networks (RGCN) với Graph Convolutional Networks (GCN) và các đơn vị LSTM được sử dụng để TSA dựa trên biên độ điện áp bus, pha tương đối của bus và tốc độ rotor của các máy phát [27].

Bài báo này áp dụng kiến trúc BiLSTM-FC (Bidirectional Long Short-Term Memory - Fully Connected) để nhận dạng ổn định quá độ HTĐ. Hiệu quả của BiLSTM-FC được kiểm tra trên HTĐ IEEE 39bus cho độ chính xác nhận dạng cao, cho thấy BiLSTM-FC đạt hiệu suất tốt hơn BiLSTM.

2. Phương trình dao động của máy điện đồng bộ

Phương trình dao động [28] biểu diễn dao động góc rotor δ trong quá trình nhiễu loạn của một máy điện đồng bộ trong hệ thống n-máy có thể được mô tả bằng hai phương trình vi phân bậc một (1) - (2).

$$\frac{d\delta_i}{dt} = \Delta\omega_i \quad (1)$$

$$\frac{d\Delta\omega_i}{dt} = \frac{1}{M_i} (P_{mi} - P_{ei} - D_i\Delta\omega_i) \quad (2)$$

Công suất điện ngõ ra của máy thứ i trong hệ thống n-máy được cho bởi phương trình (3).

$$P_{ei} = E_i^2 G_{ii} + \sum_{j \neq i}^n E_i E_j \{G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)\} \quad (3)$$

Trong đó, δ_i và δ_j là góc rotor máy thứ i và j, $\Delta\omega_i$ là độ lệch tốc độ rotor, P_{mi} là công suất cơ đầu vào, P_{ei} là công suất điện đầu ra, M_i là mômen quán tính, D_i là hệ số giảm chấn, $G_{ij} + jB_{ij}$ là độ dẫn truyền giữa máy thứ i và j, E_i và E_j là điện áp không đổi phía sau điện kháng quá độ của máy i và j.

Trong bài báo này, công cụ tính toán phân bố công suất tối ưu OPF trong PowerWorld được sử dụng để mô phỏng giải phương trình dao động. Trạng thái ổn định quá độ được xác định bằng cách quan sát góc rotor khi xảy ra ngắn mạch. HTĐ là ổn định khi độ lệch góc rotor của hai máy phát bất kỳ không quá 180° , và là không ổn định khi độ lệch góc rotor của hai máy phát bất kỳ vượt quá 180° .

3. Kiến trúc mạng neural sâu

3.1. Mạng neural bộ nhớ dài ngắn hạn hai chiều BiLSTM

BiLSTM (Bidirectional LSTM) là kiến trúc kết nối hai LSTM có thời gian đối lập đến cùng một đầu ra, kết quả được tính toán dựa trên trạng thái ẩn của cả hai LSTM.

Hình 1 [27], [29] mô tả các ô nhớ của LSTM. Ô LSTM gồm có cổng quên, cổng đầu vào và cổng đầu ra. Ô này xác định dữ liệu nào cần giữ trong bộ nhớ và dữ liệu nào cần bỏ qua bằng cách sử dụng ba chức năng điều khiển cổng, trong đó dữ liệu sau sẽ chuyển thông tin cần thiết một cách có chọn lọc.

Cổng quên (Forget Gate) lựa chọn dữ liệu nào cần ghi nhớ và dữ liệu nào cần xóa. Đầu ra là 0 hoặc 1, trong đó 0 có nghĩa là quên và 1 là giữ lại. Hàm sigmoid chịu trách nhiệm về quyết định này, đầu ra như công thức (4).

$$f_t = \sigma(W_{xf} x_t + W_{hf} h_{t-1} + b_f) \quad (4)$$

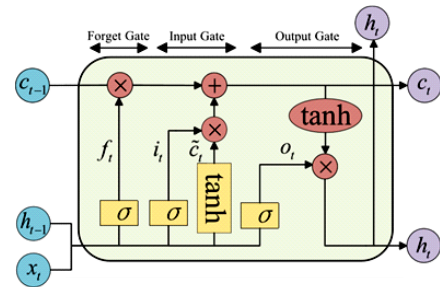
Trong đó, σ là hàm sigmoid, W_{xf} , W_{hf} và b_f là ma trận trọng số đầu vào-cổng quên, ẩn-cổng quên và độ lệch của cổng quên, x_t là đầu vào tại lần lặp t và h_{t-1} là đầu ra tại lần lặp t-1.

Cổng đầu vào (Input Gate) sử dụng hàm sigmoid để xác định giá trị nào sẽ cập nhật, công thức (5).

$$i_t = \sigma(W_{xi} x_t + W_{hi} h_{t-1} + b_i) \quad (5)$$

Trong đó, σ là hàm sigmoid, W_{xi} , W_{hi} và b_i là ma trận trọng số đầu vào-cổng đầu vào, ẩn-cổng đầu vào và độ lệch của cổng đầu vào.

Hàm tanh tạo một vectơ mới của ô nhớ có thể được thêm vào trạng thái ô nhớ, công thức (6).



Hình 1. Kiến trúc LSTM

$$\tilde{c}_t = \tanh(W_{xc} x_t + W_{hc} h_{t-1} + b_c) \quad (6)$$

Trong đó, \tanh là hàm hyperbolic tangent, W_{xc} , W_{hc} và b_c là ma trận trọng số đầu vào-nhớ, ẩn-nhớ và độ lệch của nội dung mới của ô nhớ được cập nhật.

Trạng thái ô nhớ sau đó được cập nhật bằng cách ghép cả f_t và \tilde{c}_t . LSTM cập nhật trạng thái ô cũ c_{t-1} (ô nhớ tại lần lặp $t-1$) thành c_t như trong công thức (7).

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (7)$$

Cổng ra (Output Gate) sử dụng hàm sigmoid để tính toán đầu ra o_t như trong công thức (8).


$$o_t = \sigma(W_{xo} x_t + W_{ho} h_{t-1} + b_o) \quad (8)$$

Trong đó, σ là hàm sigmoid, W_{xo} , W_{ho} và b_o là ma trận trọng số kết nối đầu vào-cổng đầu ra, ẩn-cổng đầu ra và độ lệch của cổng đầu ra.

Cuối cùng, nhân o_t với $\tanh(c_t)$ để có đầu ra cuối cùng của LSTM, để xác định phần nào cần loại bỏ như trong công thức (9).

$$h_t = o_t \tanh(c_t) \quad (9)$$

Hạn chế của LSTM là chỉ có thể sử dụng bối cảnh trước đó cho đến một thời điểm hiện tại, không biết các trạng thái tương lai. BiLSTM khắc phục bằng cách kết nối hai LSTM có thời gian đối lập. Trước tiên mạng chạy chuỗi theo hướng tiến để tính toán trạng thái ẩn hướng tiến, sau đó chạy chuỗi theo hướng lùi để tính toán trạng thái ẩn hướng lùi. Tại thời điểm này, trạng thái đầu ra được tính từ trạng thái ẩn theo hai hướng. Tuy nhiên, cả hai \vec{h} và \overleftarrow{h} đều nhận đầu vào từ cùng một vectơ x_t và chúng tương tác với cùng một vectơ đầu ra y_t .



Hình 2. Kiến trúc BiLSTM với 3 bước liên tiếp

Hình 2 [30], [31] BiLSTM tính toán chuỗi ẩn tiến \vec{h} , chuỗi ẩn lùi \overleftarrow{h} và chuỗi đầu ra y bằng cách lặp lại lớp lùi từ $t = T$ đến 1, lớp tiến từ $t = 1$ đến T , và sau đó cập nhật lớp đầu ra theo công thức (10) - (12).

$$\vec{h}_t = \sigma(W_{x\vec{h}} x_t + W_{\vec{h}\vec{h}} \vec{h}_{t-1} + b_{\vec{h}}) \quad (10)$$

$$\overleftarrow{h}_t = \sigma(W_{x\overleftarrow{h}} x_t + W_{\overleftarrow{h}\overleftarrow{h}} \overleftarrow{h}_{t-1} + b_{\overleftarrow{h}}) \quad (11)$$

$$y_t = \sigma(W_{\vec{h}y} \vec{h}_t + W_{\overleftarrow{h}y} \overleftarrow{h}_t + b_o) \quad (12)$$

Trong đó, $W_{x\vec{h}}$, $W_{\vec{h}\vec{h}}$, $W_{\vec{h}y}$ và $W_{x\overleftarrow{h}}$, $W_{\overleftarrow{h}\overleftarrow{h}}$, $W_{\overleftarrow{h}y}$ lần lượt là các ma trận trọng số hướng tiến và hướng lùi cho các tương tác đầu vào-ẩn, ẩn-ẩn và ẩn-đầu ra.

3.2. Mạng neural bộ nhớ dài ngắn hạn hai chiều BiLSTM - Kết nối đầy đủ FC

Phần này trình bày áp dụng mạng neural sâu BiLSTM-FC vào nhận dạng ổn định quá độ HTĐ [15], [33]. Kiến trúc thiết kế nhờ sự hỗ trợ của Matlab R2021b.

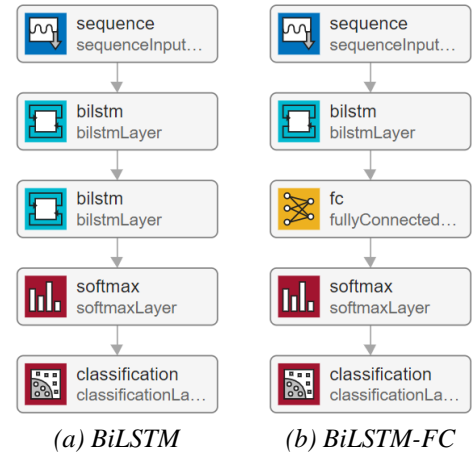
Hình 3a, BiLSTM gồm có 1 lớp sequence input, 2 lớp bilstm, 1 lớp softmax, 1 lớp classification để phân loại.

Hình 3b, BiLSTM-FC gồm 1 lớp sequence input, 1 lớp bilstm, 1 lớp fully connected, 1 lớp softmax, 1 lớp classification để phân loại.

3.2.1. Lớp sequence input

Lớp sequence input sử dụng vector biến đầu vào chứa thông tin đặc trưng của trạng thái HTĐ ngay khi sự cố xảy ra, gồm ΔP_{gen} , ΔQ_{gen} , ΔP_{load} , ΔQ_{load} , ΔV_{bus} , ΔP_{flow} , ΔQ_{flow} . Kết quả phân tích kiến trúc BiLSTM và BiLSTM-FC được trình bày trong Bảng 1.

Bảng 1, kiến trúc mạng BiLSTM-FC nhận vector biến đầu vào qua lớp sequence input. Số neural lớp sequence input là 189 bằng với số biến đặc trưng của vector biến đầu vào. Lớp phân loại được mã hoá nhận biến nhị phân, {1} là ổn định và {0} là không ổn định. Số neural ẩn lớp FC chọn bằng 2 để ngày càng gần hơn với mẫu và để xác định lớp mục tiêu. Số neural ẩn lớp BiLSTM chọn bằng 28 thông qua thực nghiệm thử sai để tìm kết quả tốt nhất.



Hình 3. Kiến trúc BiLSTM và BiLSTM-FC

Bảng 1. Kết quả phân tích kiến trúc BiLSTM và BiLSTM-FC nhận dạng ổn định quá độ

No.	BiLSTM	# of node	No.	BiLSTM-FC	# of node
1	sequence input layer	189	1	sequence input layer	189
2	bilstm layer	28	2	bilstm layer	28
3	bilstm layer	2	3	fully connected layer	2
4	softmax layer	2	4	softmax layer	2
5	classification layer	2	5	classification layer	2

3.2.2. Lớp BiLSTM

Để khởi tạo trọng số đầu vào, trọng số hồi quy và độ lệch, lớp BiLSTM sử dụng bộ khởi tạo InputWeightsInitializer, RecurrentWeightsInitializer và BiasInitializer. Trong đó, bộ khởi tạo InputWeightsInitializer sử dụng hàm glorot, bộ khởi tạo RecurrentWeightsInitializer sử dụng hàm orthogonal, bộ khởi tạo BiasInitializer sử dụng đơn vị công quân. Hàm kích hoạt trạng thái và kích hoạt công là hàm tanh và hàm sigmoid.

3.2.3. Lớp fully connected

Để ánh xạ hiệu quả thông tin đặc trưng của dữ liệu được tính toán từ BiLSTM sang FC, lớp fully connected sẽ mở rộng và giảm chiều của dữ liệu đầu ra BiLSTM, công thức (13).

$$y_j = f\left(\sum w_{ij}x_i + b_j\right) \quad (13)$$

Trong đó, x_i , y_j là biến đầu vào, đầu ra, w_{ij} là trọng số kết nối, b_j là độ lệch, f là hàm kích hoạt.

Để khởi tạo, bộ khởi tạo WeightsInitializer và BiasInitializer sử dụng hàm narrow-normal. Hàm narrow-normal khởi tạo trọng số và độ lệch bằng cách lấy mẫu độc lập từ một phân phối chuẩn có giá trị trung bình bằng 0 và độ lệch chuẩn 0,01. Hàm kích hoạt cho lớp fully connected là hàm softmax.

3.2.4. Lớp softmax

Sau khi các trọng số đặc trưng được trích xuất bởi các lớp fully connected, chúng được ánh xạ bởi một tập con của lớp softmax tới đầu ra cuối cùng của mạng đối với xác suất cho từng lớp trong các nhiệm vụ phân loại. Lớp softmax sử dụng hàm kích hoạt softmax, biểu diễn theo công thức (14).

$$\text{softmax}(y_i) = \frac{\exp(y_i)}{\sum(\exp(y_j))} \quad (14)$$

Trong đó, y_i và y_j là kích hoạt của neuron đầu ra i và j , $\text{softmax}(y_i)$ là xác suất của lớp i .

3.2.5. Lớp phân loại

Lớp phân loại tính toán tổn thất cross-entropy cho các nhiệm vụ phân loại và phân loại có trọng số với các lớp loại trừ lẫn nhau. Trong lớp phân loại, hàm tổn thất cross-entropy tính toán loại trừ các lớp có giá trị đối lập và mã hoá đầu ra, được biểu diễn như công thức (15).

$$\text{loss} = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^K w_i t_{ni} \ln y_{ni} \quad (15)$$

Trong đó: N là số mẫu, K là số lớp, w_i là trọng số của lớp i , t_{ni} là mẫu thứ n thuộc lớp thứ i , y_{ni} là đầu ra của mẫu n lớp i , mẫu này là giá trị từ hàm softmax.

Đầu ra bộ phân loại được mã hoá nhãn nhị phân, nhãn {1} là ổn định và {0} là không ổn định.

4. Kết quả nhận dạng ổn định quá độ hệ thống điện


4.1. Xây dựng tập biến và mẫu

Trong bài báo này, mô hình được đề nghị kiểm tra trên sơ đồ HTĐ IEEE 39bus, 10 máy phát, 34 đường dây truyền tải và 19 tải được trình bày trong Hình 4.

Phần mềm PowerWorld tính toán mẫu công suất phát tương ứng nhờ công cụ tính toán phân bố công suất tối ưu OPF. Thực hiện mô phỏng offline để thu thập dữ liệu đánh giá ổn định quá độ HTĐ với 6 mức tải từ 70% đến 120% tải cơ bản. Tình huống bất ngờ được xem xét là sự cố ngắn mạch ba pha chạm đất xảy ra trên tất cả các bus và trên tất cả các đường dây ở những vị trí 25%, 50%, và 75% chiều dài đường dây. Thời gian cắt ngắn mạch được cài đặt 50 ms và thời gian mô phỏng là 5s. HTĐ là ổn định khi độ lệch góc rotor của hai máy phát bất kỳ không quá 180° , và là không ổn định khi độ lệch góc rotor của hai máy phát bất kỳ vượt quá 180° .

Vectơ biến đầu vào chứa thông tin đặc trưng của trạng thái HTĐ. Thông số của biến sự cố chứa sự thay đổi tức thì của các thông số trạng thái ngay khi sự cố xảy ra như độ khác biệt công suất các nút

phát ($\Delta P_{\text{gen}} \Delta Q_{\text{gen}}$), độ khác biệt công suất các nút tải ($\Delta P_{\text{load}} \Delta Q_{\text{load}}$), độ khác biệt điện áp tại các bus (ΔV_{bus}), độ khác biệt công suất trên các đường dây truyền tải ($\Delta P_{\text{flow}} \Delta Q_{\text{flow}}$). Biến đầu vào là $x \{(\Delta P_{\text{gen}} \Delta Q_{\text{gen}})_{20} (\Delta P_{\text{load}} \Delta Q_{\text{load}})_{38} (\Delta V_{\text{bus}})_{39} (\Delta P_{\text{flow}} \Delta Q_{\text{flow}})_{92}\}$, trong đó, 20, 38, 39, 92 lần lượt đại diện cho số lượng nút máy phát, số lượng tải, số lượng bus, số lượng đường dây truyền tải, được xây dựng thành tập mẫu và biến là một ma trận, gồm mẫu ổn định và mẫu không ổn định. Tổng số biến đầu vào là 189. Kết quả mô phỏng có 995 mẫu bao gồm 676 mẫu ổn định và 319 mẫu không ổn định. Vectơ biến đầu ra đại diện cho trạng thái của HTĐ. 1 biến đầu ra là $y \{1 \ 0\}$ được mã hoá nhãn nhị phân, nhãn {1} là ổn định và nhãn {0} là không ổn định. Toàn bộ dữ liệu được chuẩn hoá trước khi huấn luyện.



Hình 4. HTĐ IEEE 10 máy 39bus

Tập dữ liệu được chia ngẫu nhiên thành 80% huấn luyện và 20% kiểm tra. Tổng cộng có 796 mẫu được chọn từ 995 mẫu làm tập huấn luyện, 199 mẫu được sử dụng làm tập kiểm tra như trong Bảng 2.

Bảng 2. Tập huấn luyện và kiểm tra của HTĐ IEEE 39bus

Tập dữ liệu	Số mẫu ổn định	Số mẫu không ổn định	Tổng số mẫu
Tập huấn luyện	541	255	796

Tập kiểm tra	135	64	199
Tổng số mẫu	676	319	995

4.2. Huấn luyện và đánh giá mô hình

4.2.1. Huấn luyện mô hình

Để tiến hành huấn luyện, cài đặt các siêu tham số liên quan đến hàm tổn thất, thuật toán tối ưu hóa, kỹ thuật khởi tạo, và số lần lặp được tóm tắt trong Bảng 3. Thuật toán tối ưu hóa ngẫu nhiên Adam với tốc độ học thay đổi được áp dụng để giảm thiểu hàm tổn thất. Các thông số khác mặc định.

Bảng 3. Cài đặt các siêu tham số BiLSTM-FC

Training Hyperparameters	Function/Selected Values		
Initialization technique	BiLSTMLayer	InputWeightsInitializer	glorot
		RecurrentWeightsInitializer	orthogonal
		BiasInitializer	unit-forget-gate
	FullyConnectedLayer	WeightsInitializer	narrow-normal
		BiasInitializer	narrow-normal
Loss function	cross-entropy		
Optimization algorithm	Adam algorithm		
Learning rate	0,0100		
Batch size	128		
Epoch number	200		

4.2.2. Đánh giá mô hình

Hiệu suất của bộ phân loại được đánh giá dựa trên ma trận nhầm lẫn. Đối với phân loại nhị phân, ma trận là một hình vuông 2x2 như thể hiện trong Bảng 4, trong đó, cột biểu diễn bộ phân loại dự đoán, trong khi hàng là giá trị thực của nhãn lớp [32].

Bảng 4. Ma trận nhầm lẫn cho phân loại nhị phân

Lớp không ổn định được gán nhãn P (Positive), lớp ổn định được gán nhãn N (Negative).	Dự đoán	
	không ổn định	ổn định
Dự đoán không ổn định	TP	FN
Dự đoán ổn định	FP	TN

TP (True Positive): Số trường hợp không ổn định được nhận dạng chính xác là không ổn định.

TN (True Negative): Số trường hợp ổn định được nhận dạng chính xác là ổn định.

FN (False Negative): Số trường hợp không ổn định bị nhận dạng nhầm.

FP (False Positive): Số trường hợp ổn định bị nhận dạng nhầm.

Độ chính xác (Accuracy-ACC) là tỷ lệ giữa số lượng đánh giá đúng trên tổng số lượng đánh giá, được xác định như công thức (16).

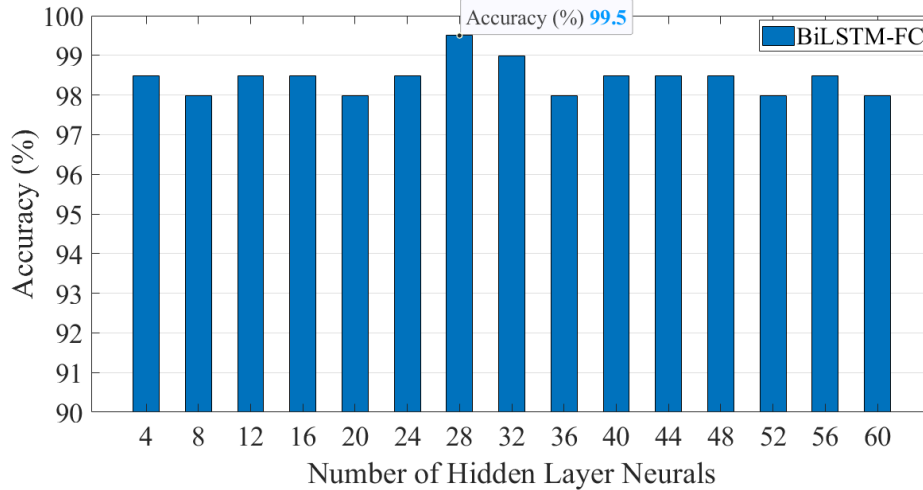
$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\% \quad (16)$$

4.3. Kết quả nhận dạng

Trong huấn luyện mạng thì việc chọn số neural lớp ẩn và các siêu tham số huấn luyện cho BiLSTM-FC là rất quan trọng, vì nó ảnh hưởng lớn đến độ chính xác. Thông qua thực nghiệm thử sai huấn luyện

nhiều lần với số neural ẩn và các siêu tham số huấn luyện khác nhau để tìm số neural ẩn với độ chính xác nhận dạng kỳ vọng. Số neural ẩn được chọn trong vùng khảo sát tương ứng với độ chính xác nhận dạng cao nhất, đạt yêu cầu.

Các siêu tham số huấn luyện mô hình BiLSTM-FC được trình bày ở Bảng 3. Hình 5 trình bày kết quả kiểm tra của BiLSTM-FC khi thay đổi số neural ẩn BiLSTM từ 4 đến 60. Ở số neural ẩn 28 BiLSTM-FC có độ chính xác nhận dạng đạt cao nhất.



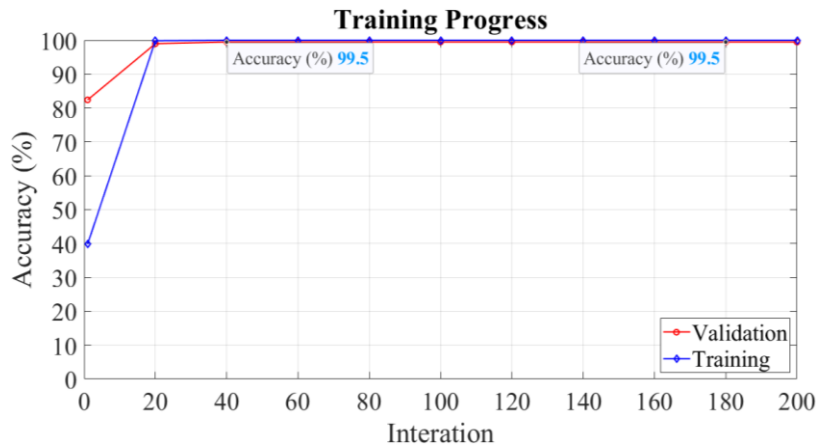
Hình 5. Độ chính xác kiểm tra của BiLSTM-FC khi thay đổi số neural ẩn

Kết quả huấn luyện và kiểm tra của BiLSTM-FC và BiLSTM được tính toán trung bình cho 10 lần thực hiện. Kết quả được trình bày ở Bảng 5.

Bảng 5. Độ chính xác huấn luyện và kiểm tra của BiLSTM-FC và BiLSTM


No	BiLSTM-FC		BiLSTM	
	Huấn luyện (%)	Kiểm tra (%)	Huấn luyện (%)	Kiểm tra (%)
1	100%	99,0%	100%	95,48%
2	100%	98,5%	100%	96,98%
3	100%	100%	100%	95,98%
4	100%	99,0%	100%	97,49%
5	100%	100%	100%	96,48%
6	100%	99,5%	100%	97,99%
7	100%	100%	100%	94,97%
8	100%	99,5%	100%	97,49%
9	100%	100%	100%	96,98%
10	100%	99,5%	100%	97,49%
Trung bình		99,5%		96,73%

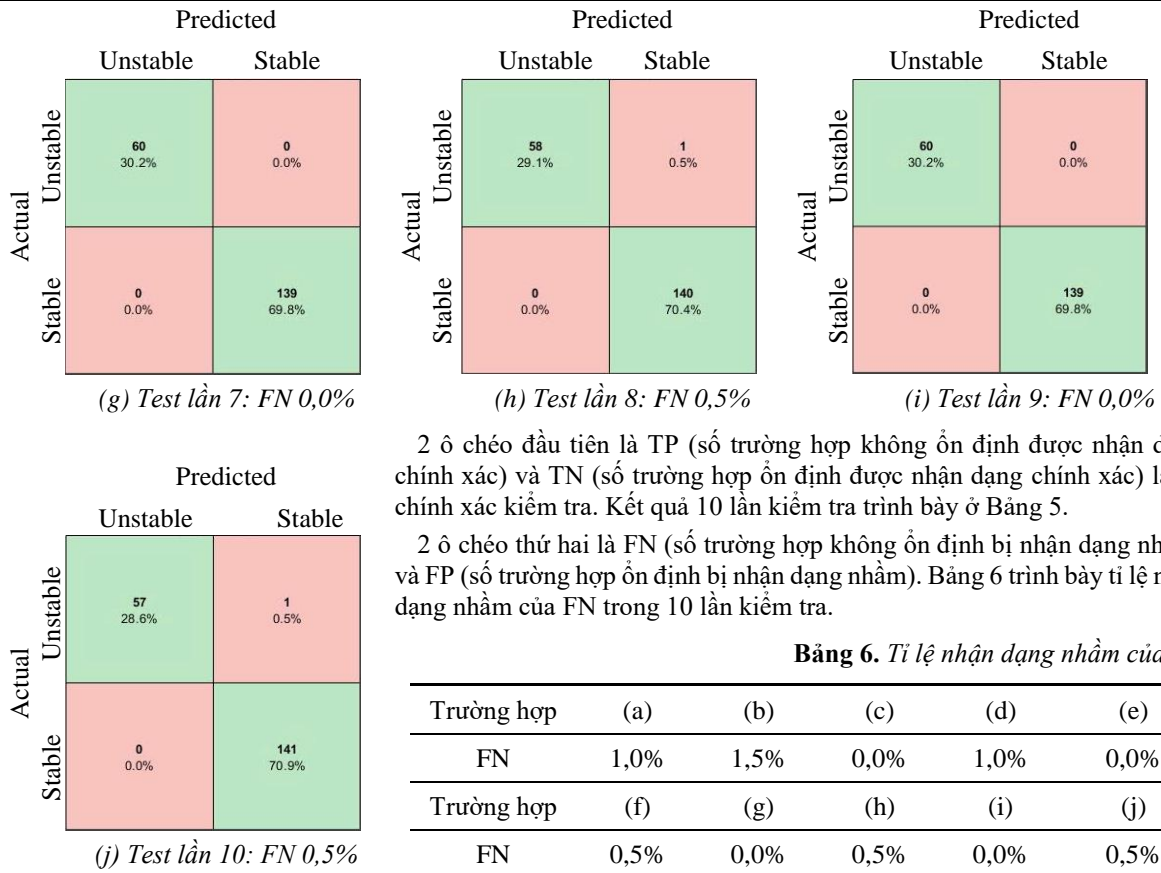
Hình 6 minh họa quá trình huấn luyện và kiểm tra ở lần huấn luyện thứ 6 của BiLSTM-FC.



Hình 6. Quá trình huấn luyện và kiểm tra ở lần huấn luyện thứ 6 của BiLSTM-FC sau 200 lần lặp

Trường hợp nhận dạng nhầm FN và FP của BiLSTM-FC dựa trên ma trận nhầm lẫn sau 10 lần kiểm tra được trình bày ở Hình 7.





2 ô chéo đầu tiên là TP (số trường hợp không ổn định được nhận dạng chính xác) và TN (số trường hợp ổn định được nhận dạng chính xác) là độ chính xác kiểm tra. Kết quả 10 lần kiểm tra trình bày ở Bảng 5.

2 ô chéo thứ hai là FN (số trường hợp không ổn định bị nhận dạng nhầm) và FP (số trường hợp ổn định bị nhận dạng nhầm). Bảng 6 trình bày tỉ lệ nhận dạng nhầm của FN trong 10 lần kiểm tra.

Bảng 6. Tỉ lệ nhận dạng nhầm của FN

Trường hợp	(a)	(b)	(c)	(d)	(e)
FN	1,0%	1,5%	0,0%	1,0%	0,0%
Trường hợp	(f)	(g)	(h)	(i)	(j)
FN	0,5%	0,0%	0,5%	0,0%	0,5%

Tỉ lệ nhận dạng nhầm của FP trong 10 lần kiểm tra là 0,0%.

Hình 7. Trường hợp nhận dạng nhầm FN và FP của BiLSTM-FC dựa trên ma trận nhầm lẫn

Tổng số biến đầu vào là 189, bao gồm độ khác biệt công suất các nút phát ($\Delta P_{gen} \Delta Q_{gen}$), độ khác biệt công suất các nút tải ($\Delta P_{load} \Delta Q_{load}$), độ khác biệt điện áp tại các bus (ΔV_{bus}), độ khác biệt công suất trên các đường dây truyền tải ($\Delta P_{flow} \Delta Q_{flow}$). Tập biến này bao trùm các kịch bản vận hành đối với tình huống bất ngờ được xem xét trong bài báo này. Tuy nhiên, khi phân tích bài toán nhận dạng ổn định HTĐ gặp phải vấn đề số biến lớn của tập dữ liệu, nhưng không phải tất cả các biến đều hữu ích. Các biến thừa sẽ gây nhiễu làm giảm tính năng của bộ phân lớp hay chẩn đoán. Giảm chiều dữ liệu hoặc chọn biến quan trọng nhằm mục đích rút gọn mô hình và chọn số ít biến đặc trưng cho bộ phân lớp, điều này còn giúp giảm số cảm biến đo lường, giảm thời gian tính toán.

Phân tích tính quan trọng của từng loại đặc trưng đầu vào, lần lượt kiểm nghiệm loại bỏ các biến là độ khác biệt công suất phản kháng đường dây, độ khác biệt công suất phản kháng máy phát, độ khác biệt công suất phản kháng tải, độ khác biệt điện áp các bus, cho số biến giảm đáng kể trong khi độ chính xác nhận dạng vẫn đạt giá trị kỳ vọng so với toàn tập biến. Kết quả huấn luyện và kiểm tra của BiLSTM-FC được tính toán trung bình cho 10 lần thực hiện. Kết quả được trình bày ở Bảng 7.

Bảng 7. Độ chính xác huấn luyện và kiểm tra của BiLSTM-FC khi giảm biến đầu vào

No	Biến máy phát		Biến tải		Biến bus		Biến đường dây		Số biến đầu vào	Huấn luyện (%)	Kiểm tra (%)
	ΔP_{gen}	ΔQ_{gen}	ΔP_{load}	ΔQ_{load}	ΔV_{bus}	ΔP_{flow}	ΔQ_{flow}	Trung bình		Trung bình	
1	10	10	19	19	39	46	46	189	100%	99,5%	
2	10	10	19	19	39	46		143	100%	99,45%	
3	10		19	19	39	46		133	100%	99,45%	

4	10	19	39	46	114	100%	99,05%
5	10		39	46	95	100%	99,25%
6	10	19		46	75	100%	98,99%
7	10	19	39		68	100%	98,59%

5. Bàn luận

Hình 5, khi thay đổi số neural BiLSTM từ 4 đến 60, BiLSTM-FC có độ chính xác nhận dạng đạt từ 97,99% đến 99,5%. Ở số neural ẩn 28 BiLSTM-FC có độ chính xác nhận dạng đạt cao 99,5%.

Bảng 5, trung bình sau 10 lần huấn luyện và kiểm tra, BiLSTM-FC có độ chính xác kiểm tra đạt cao đến 99,5%, BiLSTM có độ chính xác kiểm tra đạt cao 96,73%. Như vậy, BiLSTM-FC cho độ chính xác kiểm tra cao hơn BiLSTM là 2,77%. Kết quả kiểm tra cho thấy kiến trúc BiLSTM-FC đạt hiệu suất tốt hơn kiến trúc BiLSTM.

Hình 6, trong các lần lặp ban đầu, do mạng khởi tạo trọng số ngẫu nhiên nên độ chính xác chưa cao. Tuy nhiên, mạng đã điều chỉnh trọng số làm gia tăng độ chính xác, đến lần lặp thứ 40, độ chính xác đã xác lập ở 99,5%.

Hình 7 và Bảng 6, trong 10 lần kiểm tra tỉ lệ nhầm của lớp không ổn định ở lần kiểm tra thứ 1, thứ 4 (trường hợp a, d) là 1,0%, ở lần kiểm tra thứ 2 (trường hợp b) là 1,5%, ở lần kiểm tra thứ 6, thứ 8, thứ 10 (trường hợp f, h, j) là 0,5%, còn lại 4 trường hợp ở lần kiểm tra thứ 3, thứ 5, thứ 7, thứ 9 (trường hợp c, e, g, i) là 0,0%, trong 10 lần kiểm tra tỉ lệ nhầm trung bình là 0,5%, hay độ chính xác trung bình là 99,5%. Tỉ lệ nhầm của lớp ổn định trong 10 lần kiểm tra là 0,0%, hay độ chính xác là 100%. Kết quả cho thấy độ chính xác nhận dạng từng lớp cao.

Bảng 7, với số biến là 68 biến, giảm đến 2,77 lần, độ chính xác nhận dạng của BiLSTM-FC đạt cao 98,59%, cho thấy tất cả 189 biến không phải điều quan trọng như nhau. Khi thực hiện giảm chiều dữ liệu hoặc chọn biến quan trọng để rút gọn mô hình, độ chính xác nhận dạng vẫn đạt giá trị kỳ vọng.

6. Kết luận

Bài báo giới thiệu kiến trúc mạng neural sâu BiLSTM-FC, và trình bày áp dụng vào nhận dạng ổn định quá độ HTĐ. Tập dữ liệu huấn luyện mạng được xây dựng bằng mô phỏng với sự trợ giúp của phần mềm PowerWorld. Kết quả nghiên cứu kiểm tra trên tập dữ liệu của sơ đồ chuẩn IEEE 39bus. Bài báo cũng đã áp dụng ma trận nhầm lẫn vào kiểm tra kết quả độ chính xác nhận dạng của từng lớp riêng. Kết quả kiểm tra độ nhận dạng độ sai khác của từng lớp là nhỏ, thấy độ chính xác nhận dạng từng lớp cao, không bị chênh lệch. Kết quả này giúp xác định sai số gặp phải ở từng lớp riêng và cung cấp các thông tin chi tiết về độ chính xác của mô hình huấn luyện. Kết quả kiểm tra so sánh hiệu suất giữa kiến trúc BiLSTM-FC và BiLSTM trên cùng tập mẫu cho thấy kiến trúc BiLSTM-FC đạt hiệu suất cao hơn kiến trúc BiLSTM. Nghiên cứu này mở ra hướng áp dụng BiLSTM-FC như là một công cụ hiệu quả trong việc cải thiện hiệu suất học của các phương pháp nhận dạng ổn định quá độ HTĐ.

Lời cảm ơn

Cám ơn Phòng thí nghiệm Năng lượng tái tạo và Hệ thống điện, Khoa Điện-Điện tử, Trường Đại học Sư phạm Kỹ thuật Thành phố Hồ Chí Minh đã hỗ trợ trong quá trình nghiên cứu bài báo này.

Xung đột lợi ích

Các tác giả tuyên bố không có xung đột lợi ích trong bài báo này.

TÀI LIỆU THAM KHẢO

- [1] J. Xie, "A Review of Machine Learning Applications in Power System Resilience Jian," pp. 1–5, 2019, [Online]. Available: <https://doi.org/10.1109/PESGM41954.2020.9282137>.
- [2] B. A. Carreras, P. Colet, J. M. Reynolds-Barredo, and D. Gomila, "Assessing Blackout Risk with High Penetration of Variable Renewable Energies," *IEEE Access*, vol. 9, pp. 132663–132674, 2021, doi: 10.1109/ACCESS.2021.3114121.
- [3] Q. H. Wu, Y. Lin, C. Hong, Y. Su, T. Wen, and Y. Liu, "Transient Stability Analysis of Large-scale Power Systems: A Survey," *CSEE J. Power Energy Syst.*, vol. 9, no. 4, pp. 1284–1300, 2023, doi: 10.17775/CSEEJPES.2022.07110.

- [4] M. Pavella, D. Ernst, and D. Ruiz-Vega, "Transient Stability of Power Systems A Unified Approach to Assessment and Control," *Kluwer Acad. Publ.*, pp. 1–254, 2000.
- [5] J. N. Xin Li a, Chenkai Liu a b, Panfeng Guo a c, Shengchi Liu a, "Deep learning-based transient stability assessment framework for large-scale modern power system," *Int. J. Electr. Power Energy Syst.*, vol. 139, no. July, 2022.
- [6] W. Z. Songyan Wang, Jilai Yu, "Transient Stability Assessment Using Individual Machine Equal Area Criterion PART I: Unity Principle," *IEEE Access*, vol. 6, pp. 77065–77076, 2018.
- [7] U. Shahzad, "Artificial Neural Network For Transient Stability Assessment: A Review," 2022, [Online]. Available: <http://arxiv.org/abs/2206.06800>.
- [8] Z. Xie, D. Zhang, X. Han, and W. Hu, "Power system transient stability preventive control optimization method driven by Stacking Ensemble Learning," *Energy Reports*, vol. 9, pp. 757–765, 2023, doi: 10.1016/j.egy.2023.05.106.
- [9] O. A. Alimi, K. Ouahada, and A. M. Abu-Mahfouz, "A Review of Machine Learning Approaches to Power System Security and Stability," *IEEE Access*, vol. 8, pp. 113512–113531, 2020, doi: 10.1109/ACCESS.2020.3003568.
- [10] Bhanu Pratap Soni; Vikas Gupta; Rajesh Kumar; Akash Saxena; S.L. Surana, "Application of ANN for stability assessment of large power system by post-fault rotor angle measurements," *IEEE*, 2018.
- [11] R. Yousefian and S. Kamalasadani, "A Review of Neural Network Based Machine Learning Approaches for Rotor Angle Stability Control," pp. 1–14, 2017, [Online]. Available: <http://arxiv.org/abs/1701.01214>.
- [12] U. Shahzad, "Support vector machine for transient stability assessment : A review," no. June, 2022.
- [13] R. T. Dabou, I. Kamwa, C. Y. Chung, and C. F. Mugombozi, "Time Series-Analysis Based Engineering of High-Dimensional Wide-Area Stability Indices for Machine Learning," *IEEE Access*, vol. 9, pp. 104927–104939, 2021, doi: 10.1109/ACCESS.2021.3099459.
- [14] Y. Yang, Y. Huang, J. Liu, Y. Liu, T. Liu, and Y. Xiang, "Measurement-based cell-DT method for power system transient stability classification," *CSEE J. Power Energy Syst.*, vol. 3, no. 3, pp. 278–285, 2017, doi: 10.17775/cseejpes.2015.01230.
- [15] S. Akhtar, M. Adeel, M. Iqbal, A. Namoun, A. Tufail, and K. H. Kim, "Deep learning methods utilization in electric power systems," *Energy Reports*, vol. 10. Elsevier Ltd, pp. 2138–2151, Nov. 01, 2023, doi: 10.1016/j.egy.2023.09.028.
- [16] F. Bellizio, J. L. Cremer, M. Sun, and G. Strbac, "A causality based feature selection approach for data-driven dynamic security assessment," *Electr. Power Syst. Res.*, vol. 201, 2021, doi: 10.1016/j.epsr.2021.107537.
- [17] Y. Zhao *et al.*, "A Fast and Accurate Transient Stability Assessment Method Based on Deep Learning: WECC Case Study," *2022 IEEE Power Energy Soc. Innov. Smart Grid Technol. Conf. ISGT 2022*, no. 1839684, 2022, doi: 10.1109/ISGT50606.2022.9817531.
- [18] M. Ramirez-Gonzalez, F. R. Segundo Sevilla, P. Korba, and R. Castellanos-Bustamante, "Convolutional neural nets with hyperparameter optimization and feature importance for power system static security assessment," *Electr. Power Syst. Res.*, vol. 211, p. 108203, Oct. 2022, doi: 10.1016/j.epsr.2022.108203.
- [19] S. Patel and A. Patel, "Deep Learning Architectures and its Applications A Survey," *Int. J. Comput. Sci. Eng.*, vol. 6, no. 6, pp. 1177–1183, Jun. 2018, doi: 10.26438/ijcse/v6i6.11771183.
- [20] J. Kim, H. Lee, S. Kim, S. H. Chung, and J. H. Park, "Transient Stability Assessment Using Deep Transfer Learning," *IEEE Access*, vol. 11, no. October, pp. 116622–116637, 2023, doi: 10.1109/ACCESS.2023.3320051.
- [21] S. Wu, L. Zheng, W. Hu, R. Yu, and B. Liu, "Improved Deep Belief Network and Model Interpretation Method for Power System Transient Stability Assessment," *J. Mod. Power Syst. Clean Energy*, vol. 8, no. 1, pp. 27–37, 2020, doi: 10.35833/MPCE.2019.000058.
- [22] L. Zheng and W. Hu, "Real-Time Transient Stability Assessment Based on Deep Recurrent Neural Network," pp. 6–10, 2017.
- [23] B. Li, J. Wu, L. Hao, M. Shao, R. Zhang, and W. Zhao, "Anti-Jitter and Refined Power System Transient Stability Assessment Based on Long-Short Term Memory Network," *IEEE Access*, vol. 8, pp. 35231–35244, 2020, doi: 10.1109/ACCESS.2020.2974915.
- [24] E. A. Tapia, D. G. Colomé, and J. L. Rueda Torres, "Recurrent Convolutional Neural Network-Based Assessment of Power System Transient Stability and Short-Term Voltage Stability," *Energies*, vol. 15, no. 23, 2022, doi: 10.3390/en15239240.
- [25] S. Cheng, Z. Yu, Y. Liu, and X. Zuo, "Power system transient stability assessment based on the multiple paralleled convolutional neural network and gated recurrent unit," *Prot. Control Mod. Power Syst.*, vol. 7, no. 1, 2022, doi: 10.1186/s41601-022-00260-z.
- [26] T. McKerahan, "Transient stability preventive control based on graph convolution neural network and transfer deep reinforcement learning," pp. 1–13, 2022, doi: 10.17775/CSEEJPES.2022.05030.
- [27] J. Huang, L. Guan, Y. Su, H. Yao, M. Guo, and Z. Zhong, "Recurrent graph convolutional network-based multi-task transient stability assessment framework in power system," *IEEE Access*, vol. 8, pp. 93283–93296, 2020, doi: 10.1109/ACCESS.2020.2991263.
- [28] P. Kundur, *Power System Stability And Control*. McGraw-Hill, Inc.: Electric Power Research Institute, 1994.
- [29] T. Yang, B. Li, and Q. Xun, "LSTM-Attention-Embedding Model-Based Day-Ahead Prediction of Photovoltaic Power Output Using Bayesian Optimization," *IEEE Access*, vol. 7, pp. 171471–171484, 2019, doi: 10.1109/ACCESS.2019.2954290.
- [30] Z. Cui, R. Ke, Z. Pu, and Y. Wang, "Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction," pp. 1–11, 2018, [Online]. Available: <http://arxiv.org/abs/1801.02143>.
- [31] Z. Yu *et al.*, "Using bidirectional lstm recurrent neural networks to learn high-level abstractions of sequential features for automated scoring of non-native spontaneous speech," *2015 IEEE Work. Autom. Speech Recognit. Understanding, ASRU 2015 - Proc.*, pp. 338–345, 2016, doi: 10.1109/ASRU.2015.7404814.
- [32] M. Bekkar, H. K. Djema, and T. A. Alitouche, "Evaluation Measures for Models Assessment over Imbalanced Data Sets," *J. Inf. Eng. Appl.*, vol. 3, no. 10, pp. 27–38, 2013, [Online]. Available: <http://www.iiste.org/Journals/index.php/JIEA/article/view/7633>.
- [33] MATLAB R2021b.



Phan Viet Thinh completed his Bachelor of Electrical Engineering from Ho Chi Minh City University of Technology and Education in 2009, Vietnam. He received a master's degree in electrical engineering from Ho Chi Minh City University of Technology and Education in 2016, Vietnam. He is a lecturer at the Faculty of Electrical and Electronics Engineering at Dongnai College of High Technology, Vietnam. His main areas of research interest are control and automation engineering, and power system stability prediction.

Email: phanvietthinh1978@gmail.com. ORCID:  <https://orcid.org/0009-0003-2424-1052>



Nguyen Ngoc Au was born in Vietnam. He received his M.Sc. degree in electrical engineering from Ho Chi Minh City University of Technology and Education in 2003, Vietnam, and his Ph.D. in electrical engineering from Ho Chi Minh City University of Technology and Education in 2019, Vietnam. He is a lecturer at the Faculty of Electrical and Electronics Engineering at Ho Chi Minh City University of Technology and Education, Vietnam. His main areas of research interest are load shedding in power systems, stability power system prediction, and LV surge protection devices.

Email: aunn@hcmute.edu.vn. ORCID:  <https://orcid.org/0000-0002-2245-8755>