

Application of Deep Neural Networks to Predict Dynamic Stability of Power System

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: 24/11/2023
Revised: 24/12/2023
Accepted: 11/04/2024
Published: 28/08/2024

KEYWORDS

Dynamic stability prediction;
Power system;
Instability;
Deep neural networks;
Perceptron neural networks.

ABSTRACT

Electricity demand is increasing, transmission line development can not keep up with it. This puts the power system in a full load state which puts the power system operating near the boundary of stability. During operation, large disturbances cause power imbalance and voltage drops which cause instability. It is vital to detect the power system dynamic instability quickly. It prevents the disintegration of the power grid leading to widespread power outages which results in great economic losses. Traditional analysis methods are slow in making control decisions. Artificial neural networks overcome this drawback because they calculate quickly and accurately. This paper applies deep neural networks to predict power system dynamic stability. Evaluated on the IEEE 39bus power system data set, the deep neural networks have a validation accuracy as high as 96.99%. Compared with perceptron neural networks, deep neural networks have 1.5% higher validation accuracy.

Ứng Dụng Mạng Neural Sâu Chẩn Đoán Ổn Định Động Hệ Thống Điện

Phan Viết 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: 24/11/2023
Ngày hoàn thiện: 24/12/2023
Ngày chấp nhận đăng: 11/04/2024
Ngày đăng: 28/08/2024

TỪ KHÓA

Chẩn đoán ổn định động;
Hệ thống điện;
Mất ổn định;
Mạng neural sâu;
Mạng neural perceptron.

TÓM TẮT

Nhu cầu tiêu thụ điện ngày càng tăng cao, trong khi đầu tư phát triển đường dây truyền tải không đáp ứng kịp, làm cho hệ thống điện phải làm việc ở mức đầy tải, đưa hệ thống điện vận hành cận ranh giới ổn định. Trong vận hành, các kích động lớn diễn ra đột ngột làm mất cân bằng công suất, điện áp sụt giảm gây ra mất ổn định. Phát hiện nhanh mất ổn định động hệ thống điện là rất quan trọng giúp ngăn chặn tình trạng tan rã lưới điện, làm mất điện trên diện rộng, gây thiệt hại lớn về kinh tế. Phương pháp phân tích truyền thống tốn nhiều thời gian giải quyết chậm trễ trong việc ra quyết định điều khiển, mạng neural nhân tạo khắc phục được nhược điểm này nhờ tính toán nhanh chóng chính xác. Bài báo này áp dụng mạng neural sâu để chẩn đoán ổn định động hệ thống điện. Kết quả thực thi trên tập dữ liệu của hệ thống điện IEEE 39bus, mạng neural sâu cho độ chính xác cao đến 96,99%. So với mạng neural perceptron, mạng neural sâu có độ chính xác kiểm tra cao hơn 1,5%.

Doi: <https://doi.org/10.54644/jte.2024.1498>

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

Mất ổn định hệ thống điện (HTĐ) có thể mất điện trên diện rộng, đây là vấn đề HTĐ gặp phải ngày nay. Đặc biệt, HTĐ vận hành luôn phải đối mặt với các kích động lớn diễn ra đột ngột như ngắn mạch trên đường dây truyền tải, mất máy phát hoặc tải lớn, hoặc mất liên kết giữa hai bus hệ thống. Các kích

động này làm mất cân bằng công suất, điện áp hệ thống sụt giảm dễ gây ra mất ổn định. Ổn định HTĐ là khả năng cho phép HTĐ duy trì trạng thái cân bằng ổn định dưới các điều kiện vận hành bình thường và trở lại trạng thái cân bằng ổn định sau khi chịu tác động nhiễu [1]. Ổn định HTĐ được phân loại thành: Ổn định góc rotor, ổn định tần số và ổn định điện áp. Ổn định góc rotor đề cập đến khả năng các máy điện đồng bộ của HTĐ được kết nối với nhau duy trì trạng thái đồng bộ sau khi chịu tác động nhiễu [2]. Nhằm mục đích đánh giá thuộc tính động của HTĐ một cách nhanh chóng và chính xác, đánh giá ổn định động, hay còn gọi là ổn định quá độ, được thực hiện bằng cách quan sát sự thay đổi của góc rotor trong thời gian xảy ra sự cố [3], để xác định HTĐ có thể chịu được những kích động ngẫu nhiên mà không làm mất sự ổn định. Đánh giá ổn định động có tầm quan trọng to lớn để vận hành an toàn và đáng tin cậy HTĐ.

Trong đánh giá ổn định động HTĐ, phương pháp phân tích truyền thống dựa trên mô phỏng miền thời gian chính xác và linh hoạt nhưng đòi hỏi phải giải một tập lớn các 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 vẫn là một thách thức [4]. Phương pháp số và phương pháp trực tiếp thì hoặc thực tế khó khăn hoặc không cung cấp mô hình chi tiết của các thành phần HTĐ cần thiết để đánh giá ổn định. Phương pháp này dựa vào công thức toán học giải hệ phương trình vi phân phi tuyến của hành vi động HTĐ nên tốc độ tính toán không đủ nhanh [5]. Phương pháp hàm năng lượng quá độ và tiêu chuẩn diện tích bằng nhau mở rộng cũng đã áp dụng trong đánh giá ổn định động HTĐ. Tuy nhiên, những phương pháp này có một số hạn chế về mô hình và chúng vẫn cần nhiều tính toán để xác định chỉ số phân tích ổn định động [6]. Do các phương pháp phân tích truyền thống tính toán phức tạp, việc phân tích đánh giá ổn định HTĐ dựa trên một tập hợp lớn các phương trình vi phân, tốn nhiều thời gian giải, làm chậm trễ trong việc phát hiện mất ổn định có thể xảy ra. Cho nên mạng neural nhân tạo (Artificial Neural Networks-ANN) có thể là giải pháp thay thế đáng để được xem xét áp dụng. ANN và các biến thể của chúng trở thành một trong những phương pháp được các nhà nghiên cứu áp dụng vào bài toán có tính phi tuyến cao, trong đó có bài toán đánh giá ổn định HTĐ. Đánh giá ổn định động của HTĐ là yêu cầu hàng đầu trong vận hành và điều khiển [7], là phân tích được thực hiện để xác định xem hệ thống có ổn định hay không khi bị sự cố [8]. Sau khi được huấn luyện, ANN tính toán kết quả đầu ra nhanh chóng khi có tín hiệu vào [9]. Do vậy, ANN được nhiều công trình giới thiệu áp dụng để đánh giá ổn định HTĐ.

Trong những năm gần đây, học sâu (Deep Learning) được các nhà nghiên cứu quan tâm và được áp dụng trong nhiều lĩnh vực. Học sâu là một phần của học máy, ban đầu được ứng dụng chủ yếu nhận dạng văn bản, âm thanh và hình ảnh [10]. Trong đó, mạng neural sâu (Deep Neural Networks-DNN) được sử dụng nhiều trong lĩnh vực hình ảnh và thị giác máy tính [11]. DNN được áp dụng phân loại hình ảnh [12], phân loại ung thư phổi [13], chuyển đổi ảnh quang học sang ảnh có độ phân giải cao trong xử lý ảnh [14], nhận dạng khuyết tật bề mặt thép cán nóng [15], v.v ... Trong lĩnh vực HTĐ, các tác giả phân tích khả năng triển khai ứng dụng DNN trong dự báo phụ tải, dò tìm, chẩn đoán lỗi, đánh giá an ninh và đánh giá ổn định HTĐ [16], chẩn đoán lỗi và bảo vệ HTĐ [17], dự đoán công suất ngắn hạn cho lĩnh vực năng lượng tái tạo [18], định vị lỗi trong lưới phân phối [19]. Điều này thấy hướng ứng dụng DNN để phân loại, nhận dạng là hướng được nhiều tác giả quan tâm áp dụng. Do khả năng học nhanh chóng quan hệ phi tuyến vào ra, đáp ứng được tốc độ tính toán cũng như hiệu suất, DNN trở thành công cụ hiệu quả trong nhận dạng ổn định HTĐ.

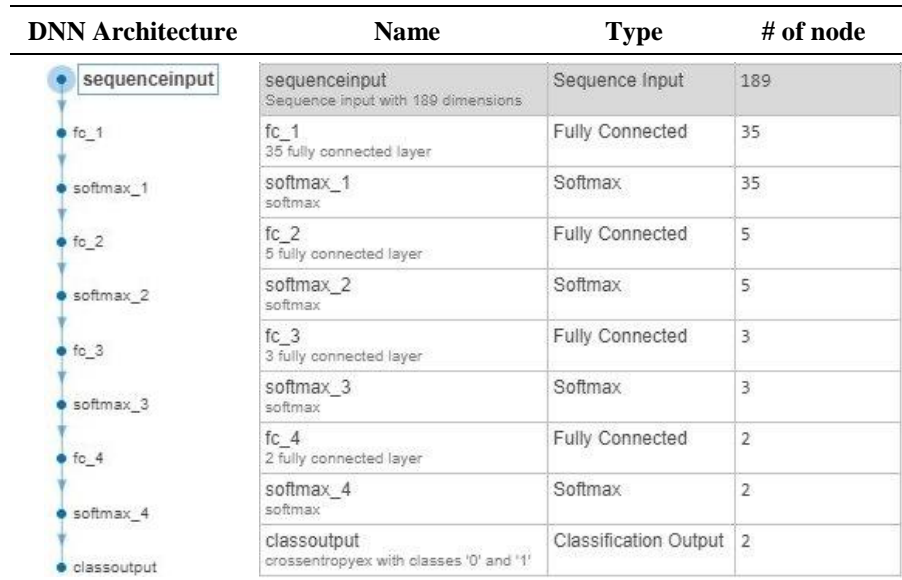
Bài báo này đề nghị áp dụng mạng DNN học tri thức dữ liệu vận hành HTĐ, bao gồm dữ liệu ổn định và không ổn định để chẩn đoán ổn định động HTĐ. Kết quả kiểm tra trên tập dữ liệu sơ đồ HTĐ IEEE 39bus cho thấy mạng DNN cải thiện độ chính xác chẩn đoán so với mạng MLPNN (Multilayer Perception Neural Networks).

2. Mạng DNN

DNN là một trong những mô hình học sâu mạnh mẽ, tiêu biểu trong công nghệ học sâu, có thể tự động học các đặc trưng phân cấp từ đầu vào chưa được xử lý. DNN là mạng được kết nối đầy đủ, trong đó, các lớp Fully Connected của DNN được biểu diễn bằng các lớp Feed-forward Neural Networks (FNN) điển hình dựa trên mô hình neural perceptron [20].

2.1. Cấu trúc mạng DNN

Trong bài báo này giới thiệu áp dụng cấu trúc tuần tự (Sequence), gồm có lớp đầu vào, lớp ẩn và lớp đầu ra. Lớp đầu vào là Sequence Input. Lớp ẩn gồm 4 lớp Fully Connected và 4 lớp Softmax. Lớp đầu ra là Classification Output để phân loại. Giải thuật học và cập nhật trọng số là narrow-normal. Hàm kích hoạt cho lớp ẩn và lớp đầu ra là hàm Softmax. Cấu trúc mô hình DNN được trình bày ở Hình 1.



Hình 1. Cấu trúc mô hình DNN

2.2. Lớp Sequence Input

Lớp đầu vào tuần tự (Sequence Input) đặt thuộc tính tên, kích thước cho dữ liệu đầu vào. Đối với đầu vào tuần tự vector, inputSize là vô hướng tương ứng với số đặc trưng [21].

Trong code Matlab, lớp đầu vào tuần tự được gọi theo cú pháp sau:

```
layers = [  
    sequenceInputLayer(inputSize,Name,Value),  
];
```

2.3. Lớp Fully Connected

Lớp kết nối đầy đủ (Fully Connected) có nhiệm vụ trích xuất đặc trưng dữ liệu, mỗi lớp sử dụng giá trị đầu ra của lớp trước làm giá trị đầu vào.

Lớp ẩn sử dụng 4 lớp Fully Connected. Cấu trúc DNN có nhiều lớp ẩn làm cho DNN ‘sâu’. Các lớp Fully Connected giảm dần số nút trong lớp ẩn nhằm mục đích chọn những đặc trưng cho bộ phân lớp giúp cải thiện độ chính xác nhận dạng.

Trong mỗi lớp Fully Connected, để khởi tạo trọng số và độ lệch, sử dụng bộ khởi tạo WeightsInitializer và BiasInitializer. Trong đó, 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.

Trong code Matlab, lớp kết nối đầy đủ và bộ khởi tạo được gọi theo cú pháp sau:

```
layers = [  
    fullyConnectedLayer(numClasses),  
    'WeightsInitializer','narrow-normal',  
    'BiasInitializer','narrow-normal',  
];
```

2.4. Hàm kích hoạt Softmax

Trong mỗi lớp Fully Connected có một lớp Softmax. Lớp Softmax sử dụng hàm kích hoạt Softmax.

Hàm kích hoạt Softmax 1, 2, 3 có nhiệm vụ cung cấp sự phân tách phi tuyến rõ ràng giữa các lớp Fully Connected 1, 2, 3. Hàm kích hoạt Softmax 4 có nhiệm vụ tính toán xác suất của một lớp trên tổng số lớp xuất hiện trong lớp Fully Connected 4, và truyền kết quả cho lớp phân loại.

Về mặt toán học, đầu ra của một neuron có thể được biểu diễn theo công thức (1).

$$a_j = f\left(\sum (w_{ij} * x_i) + b_j\right) \quad (1)$$

Trong đó: a_j là đầu ra (kích hoạt) của neuron j , f là hàm kích hoạt, w_{ij} là trọng số kết nối đầu vào i với neuron j , x_i là giá trị đầu vào cho đầu vào i , b_j là ngưỡng độ lệch của neuron j .

Lớp Fully Connected của DNN được biểu diễn bằng các lớp Feed-forward Neural Networks (FNN) dựa trên sự phát triển của các perceptron nhiều lớp, đối với mỗi lớp, phương trình (1) có thể được trình bày ở dạng ma trận, công thức (2).

$$A = f(WX + B) \quad (2)$$

Trong đó: A là ma trận kích hoạt, f là hàm kích hoạt được áp dụng theo từng phần tử, W là ma trận trọng số, X là ma trận đầu vào, B là ma trận độ lệch.

Sau khi tính toán kích hoạt cho tất cả các lớp, lớp đầu ra sẽ đưa ra dự đoán cuối cùng. Đối với nhiệm vụ phân loại, hàm Softmax thường được sử dụng trong lớp đầu ra để chuyển đổi kích hoạt thành xác suất. Hàm Softmax được biểu diễn theo công thức (3).

$$\text{softmax}(a_i) = \frac{\exp(a_i)}{\sum(\exp(a_j))} \quad (3)$$

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

Trong code Matlab, lớp hàm Softmax được gọi theo cú pháp sau:

```
layers = [  
softmaxLayer,  
];
```

2.5. Đầu ra bộ phân loại

Lớp phân loại (Classification Output) tính toán tổn thất Cross-Entropy giữa đầu ra dự đoán của mạng và nhãn dữ liệu đúng cho phân loại dạng nhị phân $\{0\}$ và $\{1\}$.

Trong lớp phân loại, hàm huấn luyện `trainNetwork` lấy các giá trị xác suất từ hàm Softmax 4 để xác định lớp cho đầu vào của lớp phân loại. Hàm tổn thất Cross-Entropy tính toán chéo, loại trừ các lớp có giá trị đối lập và mã hoá đầu ra. Hàm tổn thất Cross-Entropy được biểu diễn như công thức (4).

$$\text{loss} = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^K w_i t_{ni} \ln y_{ni}' \quad (4)$$

Trong đó: N là số mẫu, K là số lớp, w_i là trọng số của lớp i , t_{ni} hiển thị 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. Nói cách khác, y_{ni} là xác suất được sử dụng để xác định lớp mà mạng liên kết đầu vào thứ n với lớp i .

Trong code Matlab, lớp phân loại được gọi theo cú pháp sau:

```
layers = [  
classificationLayer  
];
```

Đầu ra bộ phân loại được gán giá trị nhị phân $\{1\}$ là 'ổn định' và $\{0\}$ là 'không ổn định'. Do kết quả tính toán là số thập phân nên đầu ra được hàm `round()` chuyển về đầu ra nhị phân theo công thức (5).

Nếu $y > 0,5 \rightarrow y = 1$ ổn định

Nếu $y \leq 0,5 \rightarrow y = 0$ không ổn định

(5)

2.6. Quá trình phân tích và đánh giá ổn định động sử dụng DNN

Quá trình phân tích và đánh giá ổn định động HTĐ sử dụng DNN được thực hiện gồm các bước như sau:

Bước 1. Xây dựng tập mẫu. Mô phỏng offline, quan sát góc rotor của máy phát thứ i so với máy phát chuẩn. Tập dữ liệu là một ma trận, gồm dữ liệu ổn định và không ổn định. Ma trận dữ liệu X , phương trình (6), có n biến và m mẫu. Ma trận đầu ra Y , phương trình (7), được mã hoá dạng nhị phân, nhãn $\{1\}$ cho mẫu ổn định và nhãn $\{0\}$ cho mẫu không ổn định.

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \quad (6)$$

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_m \end{bmatrix} \quad (7)$$

Bước 2. Chuẩn hoá dữ liệu. Tập dữ liệu được chuẩn hoá theo công thức (8).

$$x'_{ij} = \frac{x_{ij} - M(x_i)}{\sigma(x_i)} \quad (8)$$

Trong đó: x_{ij} và x'_{ij} là giá trị ban đầu và giá trị chuẩn hóa của biến đặc trưng thứ i , $M(x_{ij})$ là giá trị trung bình của dữ liệu, $\sigma(x_i)$ là phương sai chuẩn của dữ liệu.

Bước 3. Phân chia dữ liệu huấn luyện và kiểm tra. Tập dữ liệu được chia ngẫu nhiên thành tập dữ liệu huấn luyện và kiểm tra.

Bước 4. Huấn luyện DNN. Đây là bước cho mạng học tri thức ổn định HTĐ từ ma trận dữ liệu. Để huấn luyện mạng cần tiến hành cài đặt các thông số cho mạng, xác định hàm tối ưu trọng số, ngưỡng độ lệch cho lớp Fully Connected, xác định hàm kích hoạt cho lớp Softmax, xác định hàm tính toán cho lớp ra Classification Output.

Bước 5. Đánh giá độ chính xác nhận dạng của DNN. Độ chính xác nhận dạng huấn luyện hoặc kiểm tra được tính theo phương trình (9).

$$\text{Độ chính xác (\%)} = \frac{\text{Số mẫu đúng}}{\text{Tổng số mẫu}} \cdot 100 \quad (9)$$

3. Đánh giá ổn định động hệ thống điện

3.1. Hệ thống điện IEEE 39bus

Hệ thống điện IEEE 39bus được biết đến rộng rãi với tên gọi HTĐ New-England 10 máy, là một HTĐ tương đương của các hệ thống con của vùng đông bắc Hoa Kỳ và Canada, được coi là HTĐ mẫu cho những nghiên cứu được trình bày. Các máy phát và tải trong hệ thống đại diện cho tập hợp của nhiều nhánh máy phát điện và tải kết nối tới cùng một bus. Hệ thống gồm có 10 máy phát, 12 máy biến áp, 34 đường dây truyền tải và 19 tải. Có 2 cấp điện áp là 345kV và 20kV. Hệ thống được cho như ở Hình 2.

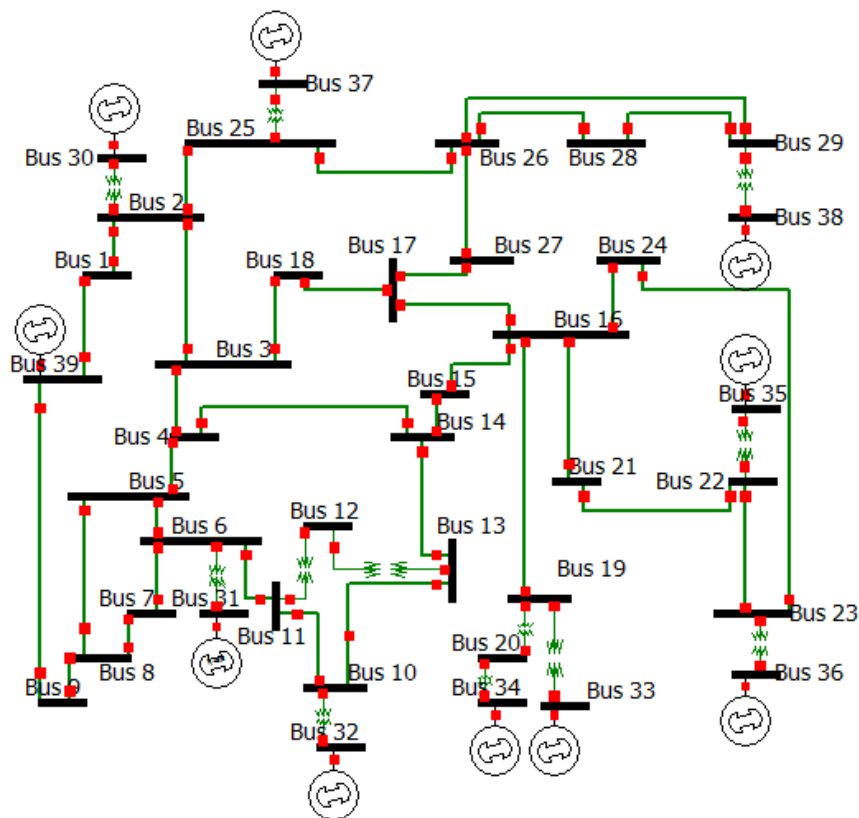
3.2. Xây dựng tập mẫu học

Để cung cấp mẫu đại diện cho cả điều kiện và tình huống vận hành HTĐ bình thường và bất thường, việc thu thập dữ liệu ổn định và không ổn định là nền tảng xây dựng và huấn luyện mô hình DNN để đánh giá ổn định động HTĐ. Một tập dữ liệu huấn luyện và kiểm tra với những điểm vận hành khác nhau được tạo ra nhằm mục đích bao phủ các thông số chế độ vận hành. Trong nghiên cứu này, để mô phỏng ổn định động HTĐ, nhiều mô phỏng đã được thực hiện trên chương trình ổn định quá độ của Powerworld được phân tích thực thi trên HTĐ IEEE 39bus, xét sự cố ngắn mạch 3 pha cân bằng tại các


bus và ở những vị trí 25%, 50% và 75% đường dây truyền tải, xem xét một phạm vi tương đối rộng lớn các điều kiện vận hành hệ thống và tiêu chuẩn đánh giá ổn định HTĐ thông qua việc cài đặt các thông số chuẩn của mô hình HTĐ IEEE 39bus và thực hiện kích hoạt các hệ thống tự động điều chỉnh điện áp, điều chỉnh kích từ, điều chỉnh tần số, giới hạn công suất phát, v.v ... và chạy phân bố công suất tối ưu. Công suất tác dụng và công suất phản kháng của các phụ tải trong lưới mẫu thử nghiệm trong mức từ 90% đến 120% giá trị của tải cơ bản. Bằng cách cài đặt các thông số chuẩn của mô hình HTĐ IEEE 39bus, thực hiện kích hoạt các hệ thống tự động, ... và chạy phân bố công suất tối ưu nhằm tận dụng hết khả năng mang tải của HTĐ sẵn có. Nghĩa là công suất tác dụng và công suất phản kháng của các máy phát điện có thể tự động điều chỉnh tương ứng trong giới hạn Max Min để cân bằng sự thay đổi của phụ tải. Dựa trên điều này, các biến đại diện là độ thay đổi công suất phát (ΔP_{gen} , ΔQ_{gen}), độ thay đổi công suất tải (ΔP_{load} , ΔQ_{load}), độ giảm điện áp tại các bus (ΔV_{bus}), độ thay đổi công suất phân bố trên các đường dây truyền tải (ΔP_{flow} , ΔQ_{flow}). Trong quá trình mô phỏng, đánh giá thuộc tính động của HTĐ trong quá trình ngắn mạch dựa trên quan sát mối quan hệ giữa các góc rotor của các máy phát điện. HTĐ ổn định nếu bất kỳ góc rotor tương đối của máy phát thứ i δ_i so với máy phát chuẩn không vượt quá 180° . Ngược lại, nếu góc rotor tương đối vượt quá 180° thì HTĐ mất ổn định. Đánh giá góc rotor tương đối của máy phát thứ i δ_i so với máy phát chuẩn cho trường hợp ổn định và mất ổn định được trình bày trong Hình 3 và Hình 4.

Kết quả mô phỏng thu được ma trận dữ liệu có 664 mẫu, gồm các mẫu ổn định và mẫu không ổn định. Tập mẫu ổn định có 431 mẫu. Tập không ổn định có 233 mẫu. Biến đầu vào là vectơ gồm $[(\Delta P_{gen}, \Delta Q_{gen})_a, (\Delta P_{load}, \Delta Q_{load})_b, (\Delta V_{bus})_c, (\Delta P_{flow}, \Delta Q_{flow})_d]$, trong đó $a=20$, $b=38$, $c=39$, $d=92$.


Trong HTĐ IEEE 39bus thì: a là số lượng đặc trưng các nút máy phát, b là số lượng đặc trưng các tải, c là số lượng đặc trưng các bus, d là số lượng đặc trưng các đường dây truyền tải. Tổng số đặc trưng cho mỗi mẫu là 189.



Hình 2. Hệ thống điện IEEE 10 máy 39bus



Hình 3. Góc rotor máy phát trường hợp ổn định



Hình 4. Góc rotor máy phát trường hợp không ổn định

3.3. Chuẩn hoá dữ liệu

Áp dụng hàm zscore để chuẩn hoá, trong code Matlab hàm chuẩn hoá dữ liệu và gán nhãn được gọi theo cú pháp sau:

```
X=zscore(X);
Y=[ones(n1,1); zeros(n2,1)];
```

Trong đó: X là tập mẫu học. Y là tập mẫu đã được gán nhãn, gồm n1 mẫu được gán nhãn {1} là mẫu ‘ổn định’ và n2 mẫu được gán nhãn {0} là mẫu ‘không ổn định’.

3.4. Phân chia dữ liệu huấn luyện và kiểm tra

Tập dữ liệu đã chuẩn hoá gồm 664 mẫu (431 mẫu ổn định, 233 mẫu không ổn định) được chia ngẫu nhiên thành 80% huấn luyện và 20% kiểm tra. Như vậy, mỗi tập huấn luyện có 531 mẫu huấn luyện (345 mẫu ổn định, 186 mẫu không ổn định) và tập kiểm tra có 133 mẫu đánh giá (86 mẫu ổn định, 47 mẫu không ổn định).

3.5. Huấn luyện và đánh giá mô hình nhận dạng

Huấn luyện mạng là xác định các trọng số và ngưỡng độ lệch để giảm thiểu tổn thất giữa đầu ra dự đoán và nhãn dữ liệu đúng.

Thông số cài đặt và điều kiện dừng khi huấn luyện hoặc kiểm tra:

Tốc độ học cơ bản: 'Initial Learn Rate', 0.01, ...

Hệ số phân rã độ dốc bình phương: 'Squared Gradient Decay Factor', 0.999, ...

Số lần lặp tối đa: 'Max Epochs', 1000, ...

Dữ liệu đánh giá: 'Validation Data', {Tập kiểm tra}, ...

Tần suất phê chuẩn độ chính xác nhận dạng: 'Validation Frequency', 30, ...

3.6. Kết quả nhận dạng

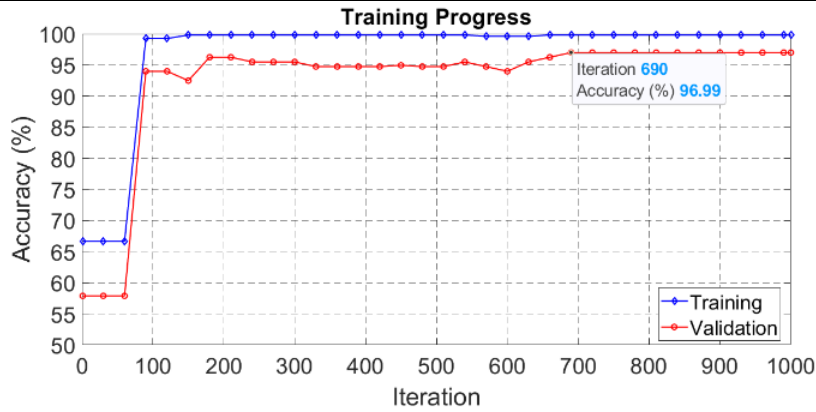
Mô hình DNN nhận dạng ổn định động HTĐ được chọn có cấu trúc tuần tự, Hình 1. Huấn luyện và đánh giá mạng sử dụng tập dữ liệu huấn luyện và kiểm tra của HTĐ IEEE 39bus.

Công cụ mạng DNN được hỗ trợ bởi phần mềm Matlab 2021b. Trong huấn luyện mạng DNN, việc chọn số neural trong lớp Fully Connected là rất quan trọng, vì nó tác động rất lớn đến độ chính xác. Kết quả nhận dạng được so sánh với mạng neural perceptron MLPNN.

Mạng MLPNN được chọn để so sánh có 3 lớp là lớp đầu vào, lớp ẩn và lớp đầu ra. Giải thuật học và cập nhật trọng số được chọn là thuật toán Levenberg-Marquardt. Hàm kích hoạt lớp ẩn và lớp ngõ ra là hàm tansig và purelin.

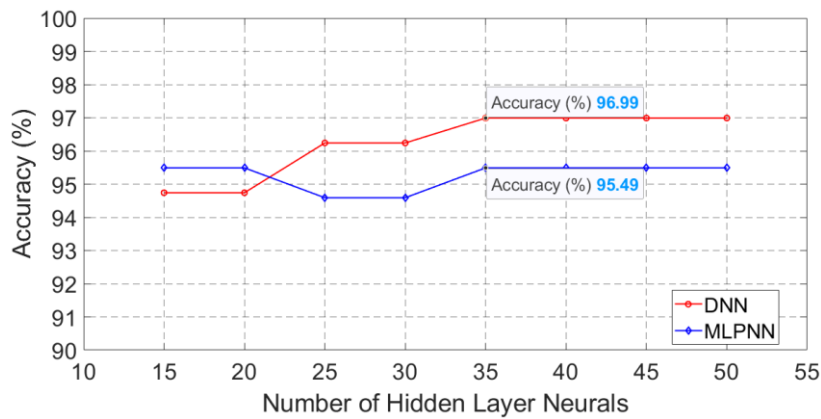
Bằng phương pháp thực nghiệm thử sai huấn luyện nhiều lần với số neural ẩn khác nhau để tìm kết quả tốt nhất. Kết quả thực thi được trình bày ở Hình 5 và Hình 6.

Hình 5 trình bày quá trình huấn luyện và kiểm tra của DNN.



Hình 5. Quá trình huấn luyện và kiểm tra của DNN

Hình 6 trình bày kết quả so sánh độ chính xác nhận dạng của DNN và MLPNN với số neural ẩn thay đổi.



Hình 6. So sánh độ chính xác nhận dạng của DNN và MLPNN

Kết quả so sánh độ chính xác nhận dạng của DNN và MLPNN tại số neural ẩn từ 15 đến 50 được trình bày ở Bảng 1.

Bảng 1. Độ chính xác nhận dạng kiểm tra của DNN và MLPNN

Số neural ẩn	DNN	MLPNN
15	94,74%	95,49%
20	94,74%	95,49%
25	96,24%	94,59%
30	96,24%	94,59%
35	96,99%	95,49%
40	96,99%	95,49%
45	96,99%	95,49%
50	96,99%	95,49%

4. Bàn luận

Hình 5, trong các lần lặp ban đầu, do 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 690, độ chính xác đã xác lập ở 96,99%.

Hình 6 và Bảng 1, thay đổi số neural từ 15 đến 50 thì số neural ẩn từ 35 đến 50 mạng DNN có độ chính xác nhận dạng đạt cao đến 96,99%, mạng MLPNN có độ chính xác nhận dạng đạt cao đến 95,49%. Như vậy, DNN cho độ chính xác kiểm tra cao hơn MLPNN là 1,5%.

So với các kết quả của các công trình công bố trước đây là từ 94% đến 97%, kết quả bài báo 96,99% là chấp nhận được.

5. Kết luận

Bài báo giới thiệu áp dụng mạng neural sâu DNN để chẩn đoán ổn định động HTĐ. Phân tích thực thi trên HTĐ IEEE 39bus, DNN có độ chính xác nhận dạng cao. Đánh giá so sánh với mạng neural perceptron MLPNN trên cùng tập mẫu và biến đầu vào, DNN cải thiện độ chính xác phân loại và thực hiện tốt hơn về mặt độ chính xác. Kết quả nhận dạng bởi DNN có thể được sử dụng như là một phương pháp cho đo lường giám sát độ thay đổi công suất và độ giảm điện áp, sau đó đưa ra công thức về kế hoạch điều khiển phòng ngừa đáng tin cậy hỗ trợ cho hoạt động điều độ về vấn đề ổn định động HTĐ. Nghiên cứu này mở ra hướng áp dụng DNN như là một công cụ hiệu quả trong việc cải thiện các phương pháp chẩn đoán ổn định động HTĐ hiện nay, góp phần nâng cao mức độ vận hành an toàn và ổn định của 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] M. Pavella, D. Ernst, and D. R. Vega, "Transient Stability of Power Systems A Unified Approach to Assessment and Control," *Kluwer Acad. Publ.*, pp. 1–254, 2000.
- [2] N. I. A. Wahab, A. Mohamed, and A. Hussain, "An Improved Method in Transient Stability Assessment of a Power System Using Probabilistic Neural Network," *Journal of Applied Sciences Research*, vol. 3, no. 11, pp. 1267–1274, 2007.
- [3] D. R. Krishna, K.V.S. R. Murthy and G. G. Rao, "Application of Artificial Neural Networks in Determining Critical Clearing Time in Transient Stability Studies," *2008 Joint International Conference on Power System Technology and IEEE Power India Conference*, New Delhi, India, 2008, pp. 1-6, doi: 10.1109/ICPST.2008.4745324.
- [4] Y. Xu *et al.*, "Earlier detection of risk of blackout by real-time dynamic security assessment based on extreme learning machines," *2010 Int. Conf. Power Syst. Technol. Technol. Innov. Mak. Power Grid Smarter, POWERCON2010*, 2010, doi: 10.1109/POWERCON.2010.5666055.
- [5] R. Zhang, Y. Xu, Z. Y. Dong, K. Meng, and Z. Xu, "Intelligent systems for power system dynamic security assessment: Review and classification," *DRPT 2011 - 2011 4th Int. Conf. Electr. Util. Deregul. Restruct. Power Technol.*, pp. 134–139, 2011, doi: 10.1109/DRPT.2011.5993876.
- [6] A. Karami, "Power system transient stability margin estimation using neural networks," *Int. J. Electr. Power Energy Syst.*, vol. 33, no. 4, pp. 983–991, 2011, doi: 10.1016/j.ijepes.2011.01.012.
- [7] B. P. Soni, V. Gupta, R. Kumar, A. Saxena, and S. L. Surana, "Application of ANN for stability assessment of large power system by post-fault rotor angle measurements," *2018 IEEMA Engineer Infinite Conference (eTechNXT)*, New Delhi, India, 2018, pp. 1-6, doi: 10.1109/ETECHNXT.2018.8385363.
- [8] S. Kalyani and K. S. Swarup, "Pattern analysis and classification for security evaluation in power networks," *Int. J. Electr. Power Energy Syst.*, vol. 44, no. 1, pp. 547–560, 2013, doi: 10.1016/j.ijepes.2012.07.065.
- [9] Y. Xu, Z. Y. Dong, L. Guan, R. Zhang, K. P. Wong, and F. Luo, "Preventive dynamic security control of power systems based on pattern discovery technique," *IEEE Trans. Power Syst.*, vol. 27, no. 3, pp. 1236–1244, 2012, doi: 10.1109/TPWRS.2012.2183898.
- [10] 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.
- [11] M. R. Gonzalez, F. R. S. Sevilla, P. Korba, and R. C. 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.
- [12] P. Bras, "Langevin Algorithms for Very Deep Neural Networks with Application to Image Classification," *Procedia Comput. Sci.*, vol. 222, pp. 303–310, 2023, doi: 10.1016/j.procs.2023.08.169.
- [13] R. Mothkur and B. N. Veerappa, "Classification of Lung Cancer Using Lightweight Deep Neural Networks," in *Procedia Computer Science*, Elsevier B. V., 2022, pp. 1869–1877, doi: 10.1016/j.procs.2023.01.164.
- [14] A. Gupta and S. K. Jain, "Conversion from multi-spectral data into SAR data with Deep Convolution Neural Architecture using Generative Adversarial Network," in *Procedia Computer Science*, Elsevier B. V., 2022, pp. 1760–1767, doi: 10.1016/j.procs.2023.01.154.
- [15] Y. Zhao, X. Sun, and J. Yang, "Automatic recognition of surface defects of hot rolled strip steel based on deep parallel attention convolution neural network," *Mater. Lett.*, vol. 353, p. 135313, Dec. 2023, doi: 10.1016/j.matlet.2023.135313.
- [16] 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.

- [17] Y. Yang, F. Tu, S. Huang, Y. Tu, and T. Liu, "Research on CNN-LSTM DC power system fault diagnosis and differential protection strategy based on reinforcement learning," *Front. Energy Res.*, vol. 11, p. 1258549, 2023, doi: 10.3389/feerg.2023.1258549.
- [18] W. Liao, B. B. Jensen, J. R. Pillai, Z. Yang, and K. Liu, "Short-term power prediction for renewable energy using hybrid graph convolutional network and long short-term memory approach," *Electr. Power Syst. Res.*, vol. 211, p. 108614, Oct. 2022, doi: 10.1016/j.epsr.2022.108614.
- [19] H. Mirshekali, A. Keshavarz, R. Dashti, S. Hafezi, and H. R. Shaker, "Deep learning-based fault location framework in power distribution grids employing convolutional neural network based on capsule network," *Electr. Power Syst. Res.*, vol. 223, p. 109529, Oct. 2023, doi: 10.1016/j.epsr.2023.109529.
- [20] Z. Tian, Y. Shao, M. Sun, Q. Zhang, P. Ye, and H. Zhang, "Dynamic stability analysis of power grid in high proportion new energy access scenario based on deep learning," *Energy Reports*, vol. 8, pp. 172–182, 2022, doi: 10.1016/j.egy.2022.03.055.
- [21] 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 the degree of master in electrical engineering from Ho Chi Minh City University of Technology and Education in 2016, Vietnam. Currently, he is a lecturer at the Faculty of Electrical and Electronics Engineering at Dongnai College of High Technology, Vietnam. His main areas of research interests are control and automation engineering, 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. degree in electrical engineering from Ho Chi Minh City University of Technology and Education in 2019, Vietnam. Currently, 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 interests are load shedding in power system, stability power system prediction, LV surge protection device.

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