

# NHẬN DẠNG ỔN ĐỊNH HỆ THỐNG ĐIỆN DÙNG BỘ PHÂN LỚP SVM POWER SYSTEM STABILITY RECOGNITION USING SVM CLASSIFIER

Nguyễn Ngọc Âu, Trương Văn Hiền, Phù Thị Ngọc Hiếu  
Trường Đại học Sư phạm Kỹ thuật TP.HCM, Việt Nam

Ngày toà soạn nhận bài 3/10/2019, ngày phân biện đánh giá 30/10/2019, ngày chấp nhận đăng 9/12/2019.

## TÓM TẮT

Đầu tư phát triển hạ tầng hệ thống điện (HTĐ) không theo kịp độ tăng trưởng của phụ tải. HTĐ bị áp lực vận hành ở chế độ cận giới hạn biên ổn định. Cho nên HTĐ rất dễ bị tổn thương khi gặp sự cố. Mất ổn định hệ thống điện được phát hiện sớm thì cơ hội điều khiển đưa hệ thống điện về trạng thái ổn định còn khả thi. Các phương pháp truyền thống tốn nhiều thời gian phân tích ổn định quá độ trong HTĐ nên không thích hợp trong làm việc trực tuyến. Nhận dạng là phương pháp hứa hẹn áp dụng đánh giá ổn định HTĐ trực tuyến. Bài báo giới thiệu bộ phân lớp SVM (Support Vector Machine) và đề nghị áp dụng SVM vào đánh giá ổn định HTĐ. Nghiên cứu được kiểm tra trên sơ đồ IEEE 39-bus. Bài báo đã so sánh độ chính xác nhận dạng ổn định HTĐ của SVM và mạng nơ-rôn MLP (Multilayer Perceptron Neural Network). Kết quả cho thấy bộ phân lớp SVM đạt độ chính xác nhận dạng cao hơn bộ phân lớp MLP.

**Từ khóa:** nhận dạng; phân lớp; ổn định hệ thống điện; suport vector machine; mạng nơ-rôn.

## ABSTRACT

Investment in developing power system infrastructure cannot keep up with the growth of load. The power system must operate under stressful condition, and operating point of power system is close to its stability limit. Therefore, the power system is more vulnerable to incidents. A instability of the power system needs to be detected early. Since then, opportunity drives the power system into re-stability state easier. Conventional methods are highly time-consuming for transient stability analysis of power system. So, the methods are unsuitable for on-line application. Pattern recognition is a promising method for on-line power system stability evaluation. The paper introduces a Support Vector Machine (SVM) classifier and suggests applying SVM classifier to assessment of power system stability. The study is implemented on IEEE 39-bus power system network. The accuracy recognition of SVM classifier is compared with that of MLP (Multilayer Perceptron Neural Network) classifier. The results showed that the SVM classifier achieved higher accuracy recognition than the MLP classifier.

**Keywords:** recognition; classification; power system stability; suport vector machine; neural network.

## 1. GIỚI THIỆU

Hệ thống điện (HTĐ) hiện đại bị áp lực vận hành rất gần với giới hạn biên ổn định, cho nên HTĐ dễ bị mất ổn định khi gặp sự cố. HTĐ có tính phi tuyến rất cao, để phân tích ổn định quá độ HTĐ các phương pháp truyền thống tốn nhiều thời gian giải. Vì vậy, phát hiện sớm mất ổn định HTĐ trở thành yếu tố then chốt đảm bảo vận hành HTĐ ổn định.

Trong những năm gần đây, phương pháp nhận dạng được áp dụng như là một phương pháp thay thế để giải quyết những vấn đề khó khăn mà những phương pháp phân tích truyền thống không giải quyết được về tốc độ tính toán [1]. Bằng quá trình học cơ sở dữ liệu vào ra giữa những thông số vận hành HTĐ, trạng thái ổn định HTĐ có thể tính toán một cách nhanh chóng [2], [3]. Ma trận

cơ sở dữ liệu ổn định HTĐ bao gồm biến và mẫu như Hình 1, trong đó  $x$  là biến đầu vào gồm  $n$  biến,  $N$  mẫu. Biến đầu ra  $y$  có  $N$  mẫu gán nhãn nhị phân.

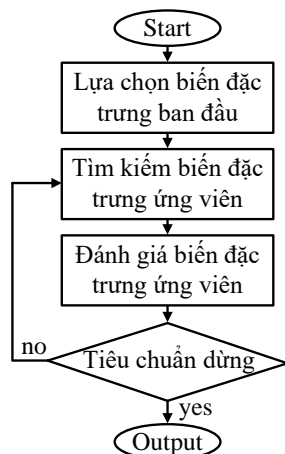
$$\begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{N1} & x_{N2} & \dots & x_{NN} \end{bmatrix}$$

Hình 1. Ma trận cơ sở dữ liệu

Bài toán đánh giá ổn định HTĐ là bài toán phi tuyến phức tạp. Nhiều công trình công bố áp dụng mạng nơ-rôn để thiết kế bộ phân lớp đánh giá ổn định HTĐ [2]–[4]. Tuy nhiên, áp dụng mạng nơ-rôn gặp phải vấn đề khó khăn trong huấn luyện là dễ bị rơi vào cực trị địa phương. Để giải bài toán phân lớp phi tuyến cao, bộ phân lớp SVM là lựa chọn hứa hẹn cho đánh giá ổn định HTĐ. Bài báo đề nghị áp dụng bộ phân lớp SVM vào đánh giá ổn định HTĐ. Bài báo đã so sánh độ chính xác nhận dạng ổn định HTĐ của SVM và mạng nơ-rôn MLP. Kết quả cho thấy bộ phân lớp SVM đạt độ chính xác nhận dạng cao hơn bộ phân lớp MLP.

## 2. LỰA CHỌN BIẾN ĐẶC TRƯNG

Trong các giai đoạn thiết kế mô hình đánh giá ổn định HTĐ dùng phương pháp nhận dạng, lựa chọn biến hay giảm biến có lợi ích trong việc giảm không gian dữ liệu, giúp giảm dung lượng lưu trữ bộ nhớ. Quy trình lựa chọn biến được giới thiệu trong [5], [6], và được trình bày ở Hình 2.




Hình 2. Quy trình lựa chọn biến

## 3. Bộ phân lớp MLP và SVM

### 3.1. MLP

Cấu trúc MLP cơ bản như Hình 3 gồm có lớp ngõ vào, một hay nhiều lớp ẩn và lớp ngõ ra.

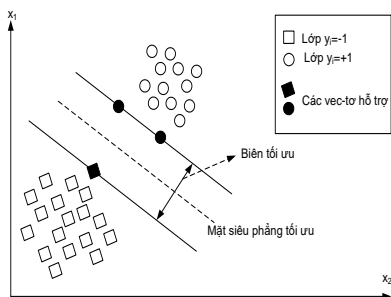


Hình 3. Mạng MLP

Số lớp ẩn có thể thay đổi trong quá trình huấn luyện tùy thuộc dữ liệu bài toán. Các nút ngõ ra có giá trị thay đổi phụ thuộc vào lớp ngõ ra mục tiêu. Huấn luyện phổ biến là học có giám sát với giải thuật lan truyền ngược. Có nhiều giải thuật huấn luyện, trong đó thuật toán Levenberg-Marquardt có hiệu suất cao hơn và tốc độ hội tụ nhanh hơn [7]. Thông số mạng ban đầu là ngẫu nhiên, quá trình huấn luyện dừng khi số vòng lặp đạt giá trị tối đa cài đặt, sai số đạt một mức cho phép hoặc sai số không tăng nữa.

### 3.2. SVM

Thuật toán bộ nhận dạng SVM là thực hiện phân lớp các mẫu dựa trên phương pháp tiếp cận lý thuyết học thống kê do Vanipk và Chervonenkis đề nghị [8]. SVM nhằm cực tiểu hóa độ phân lớp sai với một đối tượng dữ liệu mới thông qua cực đại hóa biên giữa siêu phẳng phân cách và dữ liệu. Ý tưởng cơ bản của các SVM là xây dựng một siêu phẳng như là một mặt phẳng quyết định. Mặt phẳng này tách biệt lớp dương (+1) và lớp âm (-1) với biên lớn nhất. Xét tập dữ liệu huấn luyện  $T = \{x_i, y_i\}_{i=1}^N$ , trong đó,  $x_i$  là vectơ dữ liệu đầu vào kích thước  $n$  biến và  $N$  mẫu, và  $y_i \in \{+1, -1\}$  là nhãn lớp của mẫu  $x_i$ . Các SVM thực thi cho bài toán phân lớp có hai lớp được minh họa như Hình 4. Siêu phẳng tối ưu phân tách các mẫu dương và các mẫu âm của hai lớp với độ tách biệt cực đại. Độ tách biệt hay là biên xác định bằng khoảng cách giữa các mẫu dương và mẫu âm gần mặt siêu phẳng nhất.



Hình 4. Sơ đồ thuật toán SVM

Mặt siêu phẳng trong không gian mẫu có phương trình (1):

$$g(x) = w^T \cdot x + b = 0 \quad (1)$$

Mục đích của huấn luyện là tìm ra một siêu phẳng tách biệt dữ liệu huấn luyện tốt nhất. Mặt siêu phẳng tách rời các mẫu âm và dương thỏa điều kiện (2) và (3).

$$w^T \cdot x_i + b \geq 0, \text{ nếu } y_i = +1 \quad (2)$$

$$w^T \cdot x_i + b \leq 0, \text{ nếu } y_i = -1 \quad (3)$$

Siêu phẳng tối ưu như phương trình (1) là siêu phẳng duy nhất tách tập dữ liệu học với biên cực đại. Nó xác định hướng  $w/|w|$  mà khoảng cách từ hình chiếu các vector học của 2 lớp là lớn nhất. Khoảng cách từ một điểm đến siêu phẳng được tính theo phương trình

$$(4), \text{ với biên là } \frac{2}{\|w\|}.$$

$$z = \frac{|g(x)|}{\|w\|} \quad (4)$$

Với mỗi điểm  $x_i$  tương ứng thuộc nhãn lớp  $y_i$ , cần xác định tập thông số ( $w$ ,  $b$ ) của siêu phẳng theo (5).

$$\text{Min}_w \quad \Phi(w) = \frac{1}{2} \|w\|^2 \quad (5)$$

$$y_i(w^T x_i + b) \geq 1$$

Trong trường hợp dữ liệu bài toán phức tạp và bị chồng lấn, nhiều, khó tách biệt thì bài toán (5) trở thành bài toán (6).

$$\text{Min}_w \quad \Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i$$

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad (6)$$

$$\xi_i \geq 0$$

Trong đó,  $w$  là trọng số của mặt siêu phẳng.  $C$  là hệ số phạt định nghĩa giá trị ràng buộc.  $\phi(\cdot)$  là hàm ánh xạ,  $b$  là hệ số ngưỡng,  $\xi_i$  là biến nới lỏng,  $\xi_i \geq 0$ .

### 3.3. Đánh giá mô hình nhận dạng

Phần trăm độ chính xác nhận dạng của mô hình được tính theo phương trình (7).

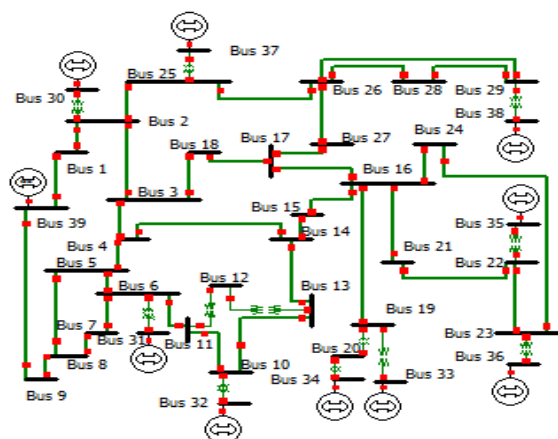
$$\text{CR}\% = \frac{R}{D} \cdot 100 \quad (7)$$

Trong đó:  $R$  là số mẫu đúng trong tập mẫu,  $D$  là tổng số mẫu của tập mẫu.

## 4. ÁP DỤNG NHẬN DẠNG ỔN ĐỊNH ĐỘNG HTĐ IEEE 10 MÁY 39-BUS

### 4.1. Sơ đồ IEEE 10 máy 39-bus

HTĐ IEEE 39-bus gồm có 39 bus, trong đó 10 bus máy phát, 12 máy biến áp, 10 máy phát, 34 đường dây truyền tải và 19 tải. 10 máy phát được kết nối từ bus 30 đến bus 39, trong đó bus 39 được coi là bus Slack, 9 bus được gọi là bus PV, 29 bus còn lại được gọi là bus PQ, có 2 cấp điện áp là 345kV và 20kV. Hệ thống được cho như ở Hình 5.



Hình 5. HTĐ IEEE 39-bus

### 4.2. Tạo cơ sở dữ liệu

Có hai dạng biến cho chế độ hệ thống điện là biến chứa dữ liệu ở chế độ xác lập và ở chế độ sự cố. Biến ở chế độ xác lập hay tiền sự cố là thông tin giúp hệ thống nhận dạng biết tình trạng mất ổn định xảy ra để phát tín hiệu đến hệ thống điều khiển ngăn chặn trước, giúp hệ thống điều khiển ra quyết định đưa hệ thống điện vào vùng vận hành an toàn, phòng khi sự cố xảy ra gây mất ổn định

hệ thống điện, mặc dù thực tế là sự cố có thể không xảy ra. Hẳn nhiên, việc điều khiển này phải chịu chi phí tổn thất cho việc điều chỉnh lại lịch trình phát của các máy phát điện. Đặc trưng cho chế độ tiền sự cố là các điểm vận hành hệ thống điện gồm điện áp tại các bus, công suất các máy phát điện, dòng công suất trên các nhánh, công suất của các tải,... Biến ở chế độ động hay chế độ sự cố là thông tin cho biết tình trạng mất ổn định xảy ra để phát tín hiệu đến hệ thống điều khiển khẩn cấp và lệnh điều khiển ngay lập tức phải được thi hành để đưa hệ thống trở về trạng thái ổn định, cứu hệ thống điện khỏi nguy cơ tan rã. Đặc trưng chế độ sự cố gồm độ lệch điện áp tại các bus, độ lệch công suất phát, độ lệch công suất trên các nhánh, độ lệch công suất các tải,... Trong thực tế phân tích ổn định hệ thống điện thì độ sụt điện áp và độ thay đổi công suất tác dụng chứa thông tin rất cao và liên quan trực tiếp đến trạng thái ổn định hệ thống điện. Đây là các biến có chứa thông tin cao được lựa chọn làm biến đầu vào cho bộ nhận dạng. Biến đầu ra đại diện cho điều kiện ổn định động của hệ thống điện được gán nhãn biến nhị phân cho lớp ổn định và lớp không ổn định.

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 off-line để thu thập dữ liệu cho đánh giá ổn định động HTĐ, trong nghiên cứu này xét hệ thống điện ở chế độ vận hành đầy đủ các máy phát và các đường dây truyền tải, mức tải 100% tải cơ bản, thời gian cắt ngắn mạch cài đặt là 50ms. Bài báo này xem xét các sự cố ngắn mạch ba pha, một pha chạm đất, hai pha tại tất cả các thanh góp và dọc các đường dây truyền tải với mỗi khoảng cách 5% chiều dài đường dây. Biến đầu vào là:  $x \{ \Delta V_{bus}, \Delta P_{load}, \Delta P_{flow} \}$ . Tổng số biến đầu vào là 104(39+19+46), 1 biến đầu ra. Tổng số mẫu là 310 mẫu, trong đó có 158 mẫu ổn định và 152 mẫu không ổn định.

#### 4.3. Biến đầu vào và biến đầu ra

Để chọn tập biến, trong bài báo này tác giả đề xuất áp dụng phương pháp xếp hạng với hàm mục tiêu chọn biến F (Fisher) [5] và

phương pháp tìm kiếm tuần tự tiến lùi (SFFS) với hàm mục tiêu SM (Scatter-Matrice) [9]. Đây là hai phương pháp đã được áp dụng chọn biến và công bố trong bài báo [5], [6].

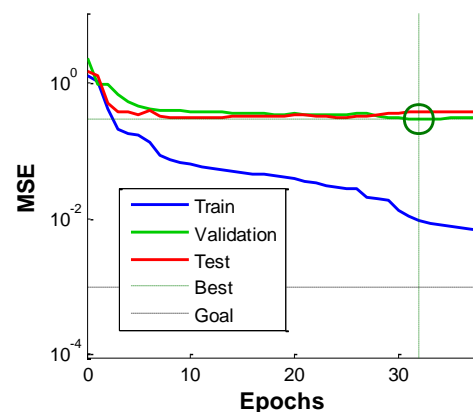
Để tiến hành chọn biến, tập dữ liệu được chia ngẫu nhiên làm 10 tập con có kích cỡ bằng nhau. Mỗi lần huấn luyện với chín tập con và một tập con còn lại làm tập kiểm tra. Kết quả huấn luyện và kiểm tra được tính toán trung bình cho 10 lần thực hiện. Bài báo áp dụng bộ nhận dạng K-Nearest Neighbor (1-NN, K=1) để thực hiện đánh giá độ chính xác chọn tập biến nhờ vào tính đơn giản của nó. Độ chính xác kiểm tra khi chọn biến theo phương pháp xếp hạng và SFFS là 93,5% và 95,8% tương ứng với số biến là 15 và 14 biến. Kết quả số biến được chọn là 14 biến theo phương pháp SFFS. Kết quả chọn biến này sẽ được sử dụng để xây dựng mô hình bộ nhận dạng hay bộ phân lớp ở phần trình bày tiếp sau.

#### 4.4. Xây dựng mô hình mạng bộ phân lớp

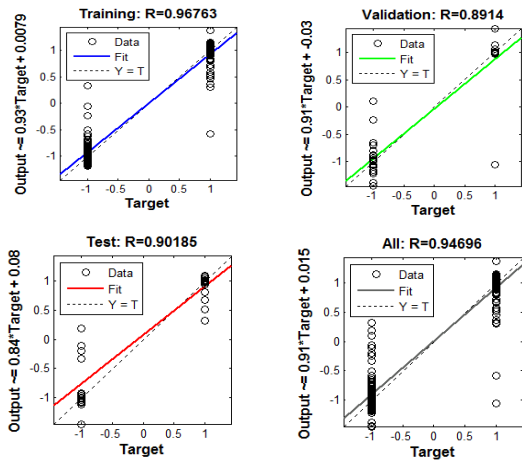
##### Phân chia dữ liệu:

Tập dữ liệu xây dựng mô hình có 310 mẫu với 14 biến đầu vào, một biến ngõ ra. Tập mẫu huấn luyện có 230 mẫu, trong đó 118 mẫu ổn định và 112 mẫu không ổn định. Tập mẫu kiểm tra có 80 mẫu, trong đó có 40 mẫu ổn định và 40 mẫu không ổn định. Trong bài báo này sử dụng các công cụ nhận dạng được hỗ trợ của phần mềm Matlab.

##### Xây dựng mô hình mạng MLP:



Hình 6. Đặc tuyến hội tụ huấn luyện mạng MLP




Hình 7. Hệ số tương quan

Cấu hình và thông số mạng nơ-rôn perceptron gồm 3 lớp: lớp vào, lớp ẩn và lớp ra. Giải thuật cập nhật trọng số và bias được chọn là Levenberg-Marquardt nhờ tính toán nhanh. Số chu kỳ huấn luyện là 1000, sai số huấn luyện cài đặt  $1e-3$ , các thông số khác mặc định. Cấu trúc mạng sử dụng hàm kích hoạt purelin, hàm ẩn logsig với số nơ-rôn  $N_h$  ẩn bằng 10, lớp ra có một nơ-rôn. Mạng có 14 biến đầu vào và một biến ra  $y \in \{1,0\}$ . Kết quả huấn luyện mạng được trình bày ở Hình 6. Trong Hình 6 số chu trình huấn luyện là 32. Hệ số tương quan giữa đầu ra của mạng và đích được trình bày ở Hình 7.

#### Xây dựng mô hình bộ phân lớp SVM:

SVM được hỗ trợ trong phần mềm Matlab [7], hàm nhân với hàm bán kính cơ sở (RBF Kernel) được chọn để xây dựng mô hình SVM. Xây dựng mô hình bộ phân lớp SVM trong công cụ hỗ trợ của phần mềm Matlab là thông qua việc tìm kiếm thông số C và thông số Kernel (K) tốt nhất sao cho bộ phân lớp đạt kết quả nhận dạng cao nhất. Trong bài báo này tác giả đề nghị phương pháp chia lưới để tìm kiếm cặp thông số (C, K). Trong xây dựng mô hình SVM, giá trị kinh nghiệm của C và K từ  $2^{-15}$  đến  $2^{15}$  được lựa chọn. Trong đó, bước khoảng cách của lưới được đề nghị là 0,1. Như vậy, lưới được chia là lưới vuông, có 301 điểm chia cho một cạnh lưới, hay tổng cộng có 90601 điểm trong lưới tìm kiếm. Kết quả đường đồng mức hay đồng giá trị độ chính xác kiểm tra được trình bày như Hình 8.



Hình 8. Đồ thị cặp thông số (C, K) và đường mức độ chính xác kiểm tra

Giá trị cặp thông số (C, K) được chọn và kết quả đánh giá được trình bày ở Bảng 1.

Bảng 1. Kết quả xây dựng các bộ phân lớp

	$N_h$	(C, K)	Huấn luyện (%)	Kiểm tra (%)
MLP	10		96,95	95,00
SVM		((8,8),(6,6))	98,62	98,75

#### 4.5. Bàn luận

Hình 7, hệ số tương quan tổng thể giữa đầu ra của bộ phân lớp MLP với đích là 0,94696. Kết quả cho thấy kết quả giữa đầu ra của bộ phân lớp MLP với đích có tính tương quan cao. Kết quả độ chính xác kiểm tra của bộ phân lớp MLP là 95%, đây là kết quả chấp nhận được trong bài toán đánh giá ổn định HTĐ [3]–[5].

Bảng 1 kết quả độ chính xác kiểm tra của bộ phân lớp SVM đạt đến 98,75%. Như vậy, SVM cho độ chính xác kiểm tra cao hơn 3,75% so với MLP.

#### 5. KẾT LUẬN

Bài báo đã đề nghị áp dụng bộ phân lớp SVM để nhận dạng ổn định động HTĐ do các sự cố ngắn mạch gây ra và so sánh kết quả với bộ phân lớp MLP. Kết quả kiểm tra cho thấy, bộ phân lớp SVM đạt độ chính xác cao hơn MLP. Việc nâng cao độ chính xác nhận dạng giúp tăng cơ hội can thiệp sớm khi HTĐ gặp sự cố gây mất ổn định, giúp giảm bớt rủi ro mất điện lưới xảy ra. Kết quả nhận dạng với độ chính xác cao, có thể khẳng định SVM là thích hợp để khuyến nghị áp dụng trong xây dựng bộ phân lớp đánh giá ổn định động HTĐ.

## TÀI LIỆU THAM KHẢO

- [1] R. Zhang, Y. Xu, Z. Y. Dong, K. Meng, and Z. Xu, “Intelligent systems for power system dynamic security assessment: Review and classification,” *2011 4th Int. Conf. Electr. Util. Deregul. Restruct. Power Technol.*, pp. 134–139, 2011.
- [2] 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.
- [3] A. Karami and S. Z. Esmaili, “Transient stability assessment of power systems described with detailed models using neural networks,” *Int. J. Electr. Power Energy Syst.*, vol. 45, no. 1, pp. 279–292, 2013.
- [4] A. M. A. Haidar, M. W. Mustafa, F. A. F. Ibrahim, and I. A. Ahmed, “Transient stability evaluation of electrical power system using generalized regression neural networks,” *Appl. Soft Comput. J.*, vol. 11, no. 4, pp. 3558–3570, 2011.
- [5] Z. Y. Dong, Z. Rui, and Y. Xu, “Feature selection for intelligent stability assessment of power systems,” *IEEE Power and Energy Society General Meeting*, pp. 1–7, 2012.
- [6] N.N.Au, Q.H.Anh, and P.T.T.Binh, “Feature Subset Selection in Dynamic Stability Assessment Power System Using Artificial Neural Networks,” *Sci. Technol. Dev. Vol.18, No.K3*, 2015.
- [7] M. H. Beale, M. T. Hagan, and H. B. Demuth, “Neural Network Toolbox™ User’s Guide R 2014 a,” 2014.
- [8] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Proc. Mach. Learn.*, vol. 20, pp. 273–297, 1995.
- [9] A. R. Webb and K. D. Copsey, “Statistical Pattern Recognition”, Third Edition, A John Wiley & Sons. Inc. Publication, 2011.

**Tác giả chịu trách nhiệm bài viết:**

Nguyễn Ngọc Âu

Trường Đại học Sư phạm Kỹ thuật TP.HCM

Email: aunn@hcmute.edu.vn