



## DỰ BÁO NGẮN HẠN SẢN LƯỢNG ĐIỆN NĂNG ĐIỆN MẶT TRỜI MÁI NHÀ SỬ DỤNG MẠNG NEURON NHÂN TẠO

Nguyễn Phúc Khải\*, Trần Kim Long, Hà Phú Cường, Nguyễn Minh Huy và Hoàng Công Hưng  
Khoa Điện - Điện tử, Trường Đại học Bách khoa, Đại học quốc gia Thành phố Hồ Chí Minh

\*Người chịu trách nhiệm về bài viết: Nguyễn Phúc Khải (email: [phuckhai@hcmut.edu.vn](mailto:phuckhai@hcmut.edu.vn))

### Thông tin chung:

Ngày nhận bài: 31/10/2022

Ngày nhận bài sửa: 06/02/2023

Ngày duyệt đăng: 06/02/2023

### Title:

Short-term forecasting energy of a solar rooftop system using artificial neural networks

### Từ khóa:

Dự báo sản lượng điện mặt trời, mạng neuron nhân tạo, mạng neuron truyền thẳng, mạng neuron hồi quy, mạng neuron bộ nhớ ngắn dài

### Keywords:

Forecasting energy, artificial neural networks, multi-layer feed-forward network, recurrent neural network, long-short term memory

### ABSTRACT

The short-term forecasting of energy for solar rooftop systems is essential in operating the power system effectively. This paper presents a survey on the short-term forecasting energy of a solar rooftop system using artificial neural networks. The data have been collected from the monitoring system with electrical power and solar irradiance from January 1, 2022, to June 1, 2022. Four neural networks have been employed to forecast electrical energy, such as a multi-layer feed-forward network (MLFF), a nonlinear autoregressive exogenous model (NARX), a long-short term memory (LSTM), and a combined NARX-LSTM model. The proposed methods have been evaluated to investigate the effectiveness of 5-minute and 1-hour forecasting. The numerical results show the MLFF is better than other methods in both case studies.

### TÓM TẮT

Dự báo ngắn hạn sản lượng điện năng điện mặt trời mái nhà là công cụ thiết yếu trong quá trình vận hành hệ thống điện một cách hiệu quả. Bài báo này trình bày khảo sát về dự báo ngắn hạn sản lượng điện năng của một hệ thống điện năng lượng mặt trời sử dụng các mạng neuron nhân tạo. Dữ liệu được thu thập từ hệ thống giám sát với công suất điện và bức xạ mặt trời từ ngày 21/04/2022 đến 01/6/2022. Bốn mô hình mạng neuron được sử dụng để dự báo điện năng gồm: mạng neuron lan truyền thẳng nhiều lớp (MLFF), mô hình neuron tự hồi quy phi tuyến tính với đa biến ngoại sinh (NARX), mô hình neuron bộ nhớ dài-ngắn hạn (LSTM) và mô hình kết hợp NARX-LSTM. Các phương pháp đề xuất để kiểm tra hiệu quả cho các bài toán dự báo 5 phút và 1 giờ. Kết quả cho thấy mô hình mạng neuron truyền thẳng nhiều lớp cho kết quả dự báo chính xác hơn so với các phương pháp khác trong cả 2 trường hợp tính toán.

## 1. GIỚI THIỆU

Dự báo sản lượng điện năng đóng vai trò vô cùng quan trọng đối với công tác quy hoạch, đầu tư phát triển và vận hành hệ thống điện. Chúng ta biết rằng nhu cầu tiêu dùng điện năng phụ thuộc vào trình độ phát triển của nền kinh tế quốc dân, vì thế dự báo sản lượng điện là một bộ phận của dự báo phát triển

kinh tế và khoa học kỹ thuật. Nếu chúng ta dự báo sản lượng quá thừa so với nhu cầu sử dụng thì hậu quả là phải huy động nguồn dự phòng đắt tiền lớn hơn mức cần thiết. Ngược lại, nếu dự báo sản lượng quá thấp so với nhu cầu thì sẽ dẫn đến kết quả nguồn dự phòng thấp giảm an toàn cung cấp điện, không đáp ứng đủ nhu cầu điện cho các sản lượng và làm thiệt hại cho nền kinh tế quốc dân.

Phân loại các dạng dự báo phục vụ công tác vận hành hệ thống điện theo thời gian gồm có: dự báo sản lượng điện năng rất ngắn hạn, dự báo sản lượng điện năng ngắn hạn, dự báo sản lượng điện năng trung hạn và dự báo sản lượng điện năng dài hạn. Trong đó, dự báo sản lượng điện năng ngắn hạn được lập cho vài phút đến 24 giờ và được dùng cho điều khiển nguồn phát tự động.

Nhiều nghiên cứu đã được công bố với nhiều phương pháp dự báo khác nhau cho công tác dự báo. Chẳng hạn, Elgarhy et al. (2017) đã trình bày đánh giá và tổng hợp các mô hình toán truyền thống được áp dụng cho bài báo dự báo: hồi quy tuyến tính, trung bình di động, hệ số ngẫu nhiên, làm trơn hàm mũ, logic mờ. Sau đó, họ đề xuất mô hình mạng neuron MLFF cho bài toán dự báo sản lượng 24 giờ tới ở New England, dữ liệu đầu vào là ngày, giờ trong tuần và sản lượng từ 2005 tới 2015 thì kết quả tốt hơn so với các phương pháp truyền thống. Mặt khác, Zhang et al. (2010) đã sử dụng mô hình MLFF để dự báo sản lượng 24 giờ tới ở Ontario, Canada, dựa trên dữ liệu quá khứ về sản lượng, nhiệt độ, độ ẩm, tốc độ gió, hướng gió, ngày trong tuần hay ngày cuối tuần, được huấn luyện và kiểm tra trong 2 năm và kết quả thể hiện sử dụng thuật toán Levenberg-Marquardt cho kết quả tốt hơn so với thuật toán Bayesian regularization. Raza and Khosravi (2015) trình bày một mô hình sử dụng MLFF được huấn luyện với thuật toán giảm độ dốc. Các đầu vào cho mạng bao gồm ngày trong tuần, ngày làm việc, giờ trong ngày, điểm sương, nhiệt độ và sản lượng của ngày dự báo, ngày hôm trước và tuần trước, 20 neuron đã được sử dụng trong lớp ẩn. Độ chính xác của dự báo đạt được được tách biệt theo mùa và nó thay đổi từ 3,81% vào mùa xuân đến 4,59% trong mùa hè. Khác với những nghiên cứu trên, nhóm tác giả Buitrago & Asfour (2017) đã đề xuất một hướng tiếp cận mới để giải quyết bài toán dự báo sản lượng 24 giờ tới. Họ đã đề xuất mô hình mạng NARX được đào tạo theo vòng mở bằng cách sử dụng dữ liệu thời tiết và tải thực tế, sau đó, mạng được đặt trong vòng kín để tạo dự báo bằng cách sử dụng tải dự đoán làm đầu vào phản hồi.

Qua các phân tích tổng quan nêu trên về các mô hình dự báo sản lượng ngắn hạn áp dụng mạng neuron nhân tạo, mô hình MLFFN và NARX được chứng minh có hiệu quả cao đối với dữ liệu thực tế. Với những ưu điểm vượt trội mà mô hình mạng neuron nhân tạo có thể mang lại so với các mô hình dự báo truyền thống khác, việc áp dụng mô hình này vào công tác dự báo sản lượng điện ngắn hạn là một hướng đi hợp lý không chỉ trong tương lai gần mà còn có thể là một bước phát triển lâu dài phù hợp với

xu thế phát triển của thế giới. Vì vậy, bài báo này nhằm khảo sát các mô hình mạng neuron nhân tạo khác nhau cho việc dự báo ngắn hạn sản lượng điện năng của một hệ năng lượng mặt trời áp mái ở khu vực quận 9 cũ, thuộc thành phố Thủ Đức, thành phố Hồ Chí Minh.

## 2. CÁC MÔ HÌNH MẠNG NEURON NHÂN TẠO ĐƯỢC KHẢO SÁT

### 2.1. Mạng neuron truyền thẳng nhiều lớp – MLFF

Mạng neuron truyền thẳng là dạng mạng neuron chỉ gồm một lớp đầu và kết nối tới lớp đầu ra hoặc mạng có thêm các lớp ẩn ở giữa lớp đầu vào và lớp đầu ra (Kürková, 1992). Mạng MLFF phổ biến sử dụng giải thuật lan truyền ngược làm phương pháp huấn luyện. Mô hình toán học của MLFF lan truyền thẳng được trình bày như sau:

$$y(x) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (1)$$

Trong đó:

- $y(x)$ : Giá trị đầu ra theo biến  $x$
- $f$ : Hàm kích hoạt hay hàm truyền
- $w_i$ : Trọng số liên kết của neuron  $x_i$
- $x_i$ : Các giá trị đầu vào

### 2.2. Mạng neuron tự hồi quy phi tuyến tính với đa biến ngoại sinh – NARX:

Mạng NARX là một mạng tự động lặp lại với các kết nối phản hồi bao quanh một số lớp của mạng (Siegelmann et al., 1997). Mô hình NARX dựa trên mô hình ARX tuyến tính, thường được sử dụng trong mô hình chuỗi thời gian. Mô hình mạng được huấn luyện bằng cách sử dụng dữ liệu của các ngày quá khứ liên tiếp trong vòng lặp đóng bằng cách sử dụng thuật toán lan truyền ngược Levenberg – Marquardt. Phương trình xác định cho mô hình NARX là:

$$y(t) = f[x(t), x(t - \Delta t), \dots, x(t - n\Delta t), y(t - \Delta t), \dots, y(t - m\Delta t)] \quad (2)$$

Trong đó:


- $n$  là số bước trễ thời gian ở đầu vào.
- $m$  là số thời gian trễ trên phản hồi (đầu ra)
- $f$  thường là một hàm phi tuyến kết hợp các biến nội sinh  $x(t)$  và các đầu ra trễ  $y(t)$

### 2.3. Mô hình bộ nhớ dài-ngắn hạn – LSTM

Mô hình LSTM là phần mở rộng của mạng neuron hồi quy (Hochreiter & Schmidhuber, 1997). Mạng neuron hồi quy là một dạng mở rộng của

mạng neuron truyền thẳng có khả năng quản lý các chuỗi đầu vào có độ dài khác nhau, mô hình neuron hồi quy cung cấp các công để lưu trữ các đầu vào trước đó và tận dụng thông tin tuần tự của các đầu vào trước đó. Mô hình LSTM về cơ bản mở rộng bộ nhớ của mạng neuron hồi quy để cho phép chúng giữ và học các phụ thuộc dài hạn của đầu vào.

Mô hình LSTM gồm 3 cửa: cửa quên, các cửa đầu vào và đầu ra như Hình 1. Cửa quên thực hiện quyết định giữ hay lưu trữ thông tin hiện có, cửa vào chỉ định mức độ mà thông tin mới sẽ được thêm vào bộ nhớ, và cửa ra kiểm soát xem giá trị hiện có trong ô có đóng góp cho đầu ra hay không.



Hình 1. Một ô của mô hình LSTM

2.4. Mô hình kết hợp NARX-LSTM

Mạng NARX mạnh mẽ trong việc xử lý các vấn đề của các hệ thống phi tuyến phù hợp để dự báo sản lượng năng lượng mặt trời. Tuy nhiên, mạng NARX tương tự như các mạng hồi quy khác gặp vấn đề về việc suy giảm gradient trong quá trình huấn luyện. Mạng NARX sử dụng thuật toán gradient descend và back propagation để cập nhật các trọng số. Qua mỗi vòng lặp, các trọng số được cập nhật theo đạo hàm riêng phần của sai số (Basodi et al., 2020), tuy nhiên có khả năng các gradient sẽ bị suy giảm mạnh từ đó các trọng số sẽ không được cập nhật. Do đó, Massaoudi et al. (2019) đã đề xuất một mô hình mạng neuron nhân tạo mới. Mô hình được đề xuất là một sự kết hợp thuộc tính các các mô hình dự báo khác nhau, để tạo ra một công cụ dự báo mạnh mẽ

Bảng 1. Bảng tóm tắt dữ liệu theo phút trong 1 ngày

Ngày/ giờ	irrPoA W/m <sup>2</sup>	cTemp (°C)	pTemp (°C)	aTemp (°C)	activeE (kWh)
2022-04-26, 05:00	0	28	26,6	27,4	227364000
2022-04-26, 05:05	0	28	26,7	27,4	227364000
...	...	...	...	...	...
...	...	...	...	...	...
2022-04-26, 18:30	0	30,6	29,6	30,7	227895020
2022-04-26, 18:35	0	30,5	29,6	30,6	227895020

hơn, đó là mạng kết hợp NARX-LSTM. Mạng LSTM có khả năng lưu trữ các thông tin quan trọng để dùng ở sau từ đó có thể mạng thông tin đi xa. Sự kết hợp trên sẽ giúp giảm thiểu ảnh hưởng của sự suy giảm gradient trong quá trình huấn luyện làm tăng độ chính xác của kết quả đầu ra. Ngoài ra, mạng NARX với các bước trễ thời gian ở ngõ vào sẽ làm giảm hiện tượng over-fitting thường gặp ở mạng LSTM.

3. DỮ LIỆU THỰC HIỆN PHỤC VỤ DỰ BÁO

3.1. Mô tả dữ liệu


Trong nghiên cứu này, dữ liệu được dùng là dữ liệu trong 41 ngày (1 ngày có 168 mẫu dữ liệu được lấy mẫu cách nhau 5 phút) của khu công nghệ cao quận 9 từ ngày 21 tháng 4 năm 2022 đến ngày 01 tháng 6 năm 2022. Mỗi ngày được thu thập dữ liệu từ 5 giờ sáng đến 6 giờ 55 phút chiều. Số liệu được tóm tắt trong một ngày được trình bày như Bảng 1. Hình 2 mô tả đường đặc tuyến của bức xạ, năng lượng điện, nhiệt độ cell pin, nhiệt độ cả tấm pin và nhiệt độ môi trường, trong đó:

- irrPoA là bức xạ mặt trời lên tấm quang điện (W/m<sup>2</sup>)
- cTemp là nhiệt độ mỗi cell của tấm quang điện (°C)
- pTemp là nhiệt độ cả tấm quang điện (°C)
- aTemp là nhiệt độ môi trường (°C)
- activeE là tổng sản lượng ghi nhận được cộng dồn qua các ngày (Wh)

Ngoài bộ dữ liệu theo giờ, nghiên cứu này còn sử dụng bộ dữ liệu 42 ngày theo giờ (lấy mẫu cách nhau 1 giờ) được tổng hợp bằng cách lấy tổng 12 mẫu số liệu của bộ dữ liệu 5 phút đối với năng lượng và trung bình của 12 trường dữ liệu từ bộ dữ liệu theo phút đối với các thông số khác từ ngày 21 tháng 4 năm 2022 đến hết ngày 01 tháng 6 năm 2022. Số liệu được trình bày tóm tắt trong Bảng 2.

**Bảng 2. Bảng tóm tắt dữ liệu theo giờ trong 1 ngày**

Ngày/ giờ	irrPoA	cTemp	pTemp	aTemp	RactiveE
2022-04-21,05:00	7,133333	24,95833	23,475	25,375	0
2022-04-21,06:00	165,55	31,31667	28,59167	28,41667	9000
...	...	...	...	...	...
...	...	...	...	...	...
2022-04-21,17:00	38,65	32,375	31,45833	31,86667	6000
2022-04-21,18:00	0,666667	29,93333	28,98333	30,21667	0



**Hình 2. Đồ thị dữ liệu theo phút trong một ngày**

**3.2. Các bước xây dựng mô hình dự báo sản lượng điện mặt trời**

Các nghiên cứu và thực nghiệm chứng minh rằng việc tiếp cận bài toán dự báo sản lượng điện mặt trời sử dụng mạng neuron nhân tạo sẽ đảm bảo độ chính xác cao. Để đạt được mục tiêu như trên cần phải thử nghiệm và so sánh để lựa chọn được cấu trúc mạng có độ chính xác cao nhất, tối ưu với các thông số như số lớp ẩn, số neuron mỗi lớp ẩn, dạng hàm truyền,... Bài toán dự báo là một dạng bài toán phức tạp về cả số lượng dữ liệu đưa vào cũng như độ chính xác của kết quả dự báo. Các bước chính để thực hiện bao gồm:

**3.2.1. Bước 1: Lựa chọn biến đầu vào**

Dữ liệu đầu vào bao gồm các thông tin irrPoA, cTemp, pTemp, aTemp và sản lượng điện activeE của các ngày trước đó (Ví dụ: Có 5 ngày dữ liệu thì cần lấy thông tin 4 ngày trước đó để dự báo sản lượng cho 1 ngày tiếp theo)

**3.2.2. Bước 2: Thu thập và tiền xử lý dữ liệu**

Dữ liệu sau khi thu thập cần được kiểm tra và xử lý trước khi sử dụng, loại bỏ hoặc dùng các phép toán trung bình để bổ sung thông tin dữ liệu bị

khuyết. Nếu dữ liệu bị lỗi quá nhiều thì phải loại bỏ hoặc tiến hành thu thập lại.

**3.2.3. Bước 3: Chuẩn hóa dữ liệu**

Dữ liệu đầu vào thực chất là các giá trị của tham số đầu vào và đầu ra để tối thiểu nhiễu. Ta cần chuẩn hóa các dữ liệu trong khoảng [-1;1] hoặc [0;1]. Trong bài toán dự báo sản lượng này, dữ liệu sẽ được chuẩn hóa trong khoảng [0;1] theo công thức:

$$y = \frac{(y_{max} - y_{min})(x - x_{min})}{(x_{max} - x_{min})} + y_{min} \quad (3)$$

**3.2.4. Bước 4: Phân chia dữ liệu**

Để huấn luyện mạng, cần phải phân chia dữ liệu thành các tập huấn luyện (train), tập kiểm chứng (validation) và tập kiểm tra (test). Đối với bài toán dự báo trước 5 phút, tỷ lệ phân chia dữ liệu là 60% để huấn luyện, 20% để kiểm chứng và 20% để kiểm tra. Đối với bài toán dự báo trước 1 giờ, các tác giả sử dụng 34 ngày để huấn luyện, 4 ngày để kiểm chứng và 4 ngày để kiểm tra.

**3.2.5. Bước 5: Xác định cấu trúc mạng**

Xác định cấu trúc mạng là xác định số lớp ẩn, số neuron trong mỗi lớp. Việc xác định cấu trúc mạng được thực hiện dựa theo kinh nghiệm của các tác giả

và áp dụng cho từng mô hình mạng neuron khác nhau. Các tác giả đã thử nghiệm số neuron và số lớp khác nhau cho các mô hình mạng neuron nhân tạo để tìm ra mô hình dự báo tối ưu. Số neuron và số lớp được khảo sát như Bảng 3.

**Bảng 3. Các cấu trúc mạng được khảo sát cho các mô hình**

Số neuron				
<b>1 lớp</b>	4	8	16	32
<b>2 lớp</b>	4-2	8-2	4-4	16-2

3.2.6. Bước 6: Chọn tiêu chuẩn đánh giá

Để đánh giá độ chính xác của bài toán dự báo phụ tải, các tác giả sử dụng hàm trung bình tổng các bình phương sai số:

$$MSE = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n} \quad (4)$$

Trong đó:

- $Y_t$  là sản lượng thực tế
- $\hat{Y}_t$  là sản lượng dự báo
- $n$  là số lượng mẫu tính toán

3.2.7. Huấn luyện mạng và dự báo

Trong quá trình huấn luyện mạng neuron, thuật toán huấn luyện đóng vai trò quan trọng đến kết quả đầu ra. Từ Buitrago and Asfour (2017), chúng ta có thể thấy được thuật toán Levenberg-Marquardt cho kết quả rất tốt. Đề tài này sẽ sử dụng thuật toán Levenberg-Marquardt để huấn luyện mạng cho mạng MLFF và NARX.

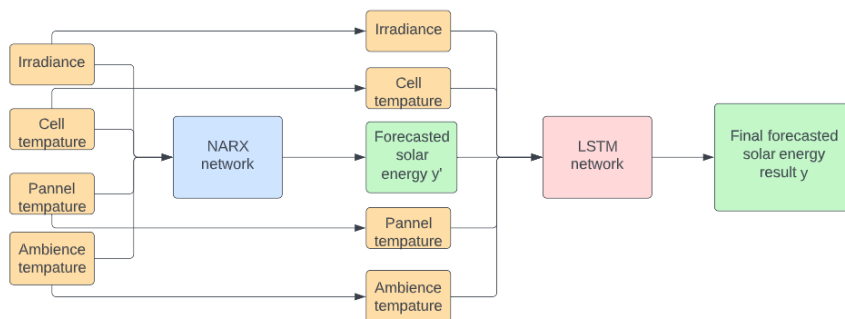
Đối với mạng truyền thẳng và NARX hàm truyền lớp ẩn sử dụng là hàm tansig. Hàm truyền lớp kết quả là hàm linear. Và mạng LSTM và NARX-LSTM có hàm kích hoạt công là hàm sigmoid() và hàm kích hoạt trạng thái là hàm tanh().

Các thông số cơ bản chung cho mạng NARX và MLFF:


- Chu kỳ huấn luyện tối đa là 1000
- Số lần tối đa sai số huấn luyện tăng liên tiếp là 6.
- Hệ số học khởi tạo là 0,001
- Hệ số học tối đa là 1e10

3.2.8. Bước 8: Đánh giá và nhận xét kết quả


Mạng sau khi huấn luyện, tiến hành thực hiện dự báo sản lượng theo yêu cầu.




**Hình 3. Mô hình mạng NARX-LSTM sử dụng để dự báo**




**Hình 4. Đồ thị kết quả dự báo theo 5 phút ngày 30/4/2022 của mạng MLFF**



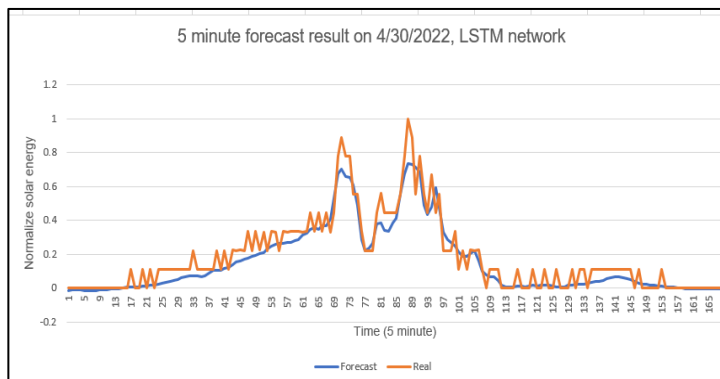
Hình 5. Đồ thị kết quả dự báo theo 1 giờ ngày từ 29/05/2022 – 01/06/2022 của mạng MLFF




Hình 6. Đồ thị kết quả dự báo theo 5 phút ngày 30/4/2022 của mạng NARX



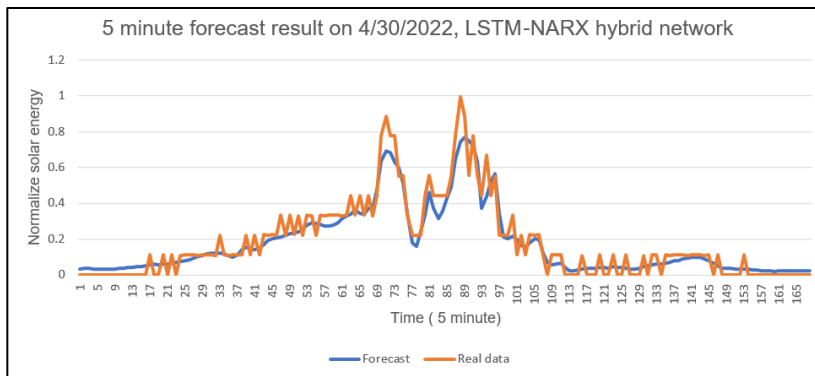
Hình 7. Đồ thị kết quả dự báo theo 1 giờ ngày từ 29/05/2022 – 01/06/2022 của mạng NARX




Hình 8. Đồ thị kết quả dự báo theo 5 phút ngày 30/4/2022 của mạng LSTM



**Hình 9. Đồ thị kết quả dự báo theo 1 giờ ngày từ 29/05/2022 – 01/06/2022 của mạng LSTM**



**Hình 10. Đồ thị kết quả dự báo theo 5 phút ngày 30/4/2022 của mạng NARX-LSTM**



**Hình 11. Đồ thị kết quả dự báo theo 1 giờ ngày từ 29/05/2022 – 01/06/2022 của mạng NARX-LSTM**

**4. KẾT QUẢ DỰ BÁO VÀ PHÂN TÍCH**

Các mô hình mạng neuron được lập trình trên phần mềm Matlab 2021a sử dụng Neural network toolbox. Trong quá trình huấn luyện, mỗi loại mạng neuron (MLFF, NARX, LSTM) sẽ được huấn luyện 30 lần với các cấu trúc mạng khác nhau để tìm cấu trúc cho kết quả tốt nhất. Riêng với mạng kết hợp NARX-LSTM để tiết kiệm thời gian, nhóm nghiên

cứu quyết định kết hợp cấu trúc mạng NARX và LSTM cho kết quả tốt nhất. Cấu trúc mạng kết hợp NARX-LSTM như Hình 3.

**4.1. Mạng neuron truyền thẳng nhiều lớp (MLFF)**

Kết quả sai số MSE các cấu trúc mạng khác nhau của mạng truyền thẳng MLFF với bài toán dự báo 5

phút và 1 giờ được trình bày ở Bảng 4. Qua 30 lần lặp kết quả sai số kiểm tra của mạng truyền thẳng đa lớp khi dự báo theo 1 giờ nhỏ hơn đáng kể so với dự báo theo mỗi 5 phút. Đối với dự báo 5 phút mạng 2 lớp, 4 neuron lớp 1, 2 neuron lớp 2 cho kết quả tốt nhất với MSE trung bình là 0,0044. Đối với dự báo 1 giờ mạng 1 lớp, 16 neuron cho kết quả tốt nhất với MSE trung bình là 0,00161. So sánh giữa kết quả dự báo và kết quả thực tế trong từng trường hợp thể hiện ở Hình 4 và Hình 5.

**Bảng 4. Sai số MSE của MLFF cho bài toán 5 phút và 1 giờ**

	Dự báo 5 phút		Dự báo 1 giờ	
	Trung bình	Cực tiểu	Trung bình	Cực tiểu
4	0,00454	0,0036	0,00164	0,00134
8	0,00465	0,003405	0,00163	0,00124
16	0,00566	0,003465	0,00161	0,00121
32	0,00589	0,003874	0,00174	0,00099
4-2	0,0044	0,00327	0,00174	0,00135
8-2	0,0045	0,00347	0,00176	0,00146
4-4	0,0073	0,00333	0,00173	0,00115
16-2	0,0056	0,00343	0,00179	0,00139

**4.2. Mạng neuron hồi quy với đa biến ngoại sinh (NARX)**

Kết quả sai số MSE các cấu trúc mạng khác nhau của mạng NARX với bài toán dự báo 5 phút và 1 giờ được trình bày ở Bảng 5. Qua 30 lần lặp kết quả sai số dự báo của mạng NARX khi dự báo 1 giờ lớn hơn đáng kể so với dự báo mỗi 5 phút. Mạng NARX 1 lớp, 4 neuron cho kết quả MSE tốt nhất trong cả 2 bài toán dự báo, lần lượt là 0,006215 và 0,01087. Hình 6 và Hình 7 thể hiện sự so sánh giữa kết quả dự báo và kết quả thực tế.

**Bảng 5. Sai số MSE của NARX cho bài toán 5 phút và 1 giờ**

	Dự báo 5 phút		Dự báo 1 giờ	
	Trung bình	Cực tiểu	Trung bình	Cực tiểu
4	0,006215	0,00472	0,01087	0,00836
8	0,006302	0,00487	0,01227	0,00994
16	0,006852	0,00511	0,01127	0,00834
32	0,01116	0,00484	0,01293	0,00927
4-2	0,00669	0,0051	0,01154	0,00837
8-2	0,006964	0,00529	0,01131	0,00811
4-4	0,006622	0,00456	0,01228	0,00864
16-2	0,00697	0,00486	0,01269	0,0086

**4.3. Mạng neuron bộ nhớ dài-ngắn hạn (LSTM)**

Kết quả sai số MSE các cấu trúc mạng khác nhau của mạng LSTM với bài toán dự báo 5 phút và 1 giờ được trình bày ở Bảng 6. Qua 30 lần lặp kết quả sai số dự báo của mạng LSTM khi dự báo 1 giờ nhỏ hơn đáng kể so với dự báo mỗi 5 phút. Đối với dự báo 5 phút, mạng 2 lớp, 4 neuron mỗi lớp, cho kết quả tốt nhất với MSE trung bình là 0,005749. Đối với dự báo 1 giờ, mạng 2 lớp, 16 neuron lớp 1 và 2 neuron lớp 2 cho kết quả tốt nhất với MSE trung bình là 0,00154. So sánh giữa kết quả dự báo và kết quả thực tế trong từng trường hợp thể hiện ở Hình 8 và Hình 9.

**Bảng 6. Sai số MSE của LSTM cho bài toán 5 phút và 1 giờ**

	Dự báo 5 phút		Dự báo 1 giờ	
	Trung bình	Cực tiểu	Trung bình	Cực tiểu
4	0,006037	0,00529	0,001628	0,001355
8	0,006294	0,00542	0,001629	0,001508
16	0,006115	0,00521	0,001627	0,001533
32	0,006302	0,00542	0,001687	0,001574
4-2	0,005859	0,00501	0,001627	0,001407
8-2	0,00593	0,00528	0,001582	0,001473
4-4	0,005749	0,00478	0,00163	0,001492
16-2	0,005985	0,00525	0,00154	0,001466

**4.4. Mạng kết hợp NARX-LSTM**

Đối với mạng kết hợp NARX-LSTM, cấu trúc của từng mạng riêng lẻ được chọn dựa vào kết quả sai số tốt nhất theo mỗi tập dữ liệu đã trình bày ở phần trên. Đối với dự báo 5 phút, mạng NARX có 1 lớp, 4 neuron và mạng LSTM có 2 lớp với 4 neuron mỗi lớp. Đối với dự báo 1 giờ, mạng NARX có 1 lớp 4 neuron và mạng LSTM có 2 lớp, 16 neuron lớp 1, 2 neuron lớp 2. Kết quả dự báo của mạng NARX-LSTM với cấu trúc mạng cụ thể cho từng bài toán như Bảng 7. So sánh kết quả dự báo và dữ liệu thực tế của mô hình mạng NARX-LSTM như Hình 10 và Hình 11.

**Bảng 7. Sai số MSE của NARX-LSTM cho bài toán 5 phút và 1 giờ**

	Trung bình	Cực tiểu
NARX(4)-LSTM(4-4)/ dự báo 5 phút	0,004658	0,004038
NARX(4)-LSTM(16-2)/ dự báo 1 giờ	0,001544	0,001379



**4.5. Nhận xét và đánh giá các mô hình**

Tổng hợp kết quả đánh giá các mô hình mạng neuron tốt nhất của các tập dữ liệu được trình bày ở Bảng 8. Đối với bài toán dự báo 5 phút, mạng MLFF cho kết quả tốt nhất. Mạng NARX và LSTM có sai số dự báo tương đối cao so với mạng MLFF, tuy nhiên sự kết hợp của NARX và LSTM lại cho kết

quả tốt hơn hẳn, sai số gần bằng với mạng MLFF. Có thể thấy được sự hiệu quả của mô hình hỗn hợp NARX-LSTM. Đối với bài toán dự báo 1 giờ, mạng LSTM cho kết quả sai số tốt nhất. Mạng NARX có sai số dự báo cao hơn nhiều so với mạng truyền thẳng và LSTM tuy nhiên sự kết hợp của NARX và LSTM lại cho kết quả sai số tương tự như LSTM.

**Bảng 8. Kết quả sai số MSE tốt nhất của các kiểu mạng với dự báo điện năng 5 phút và dự báo điện năng 1 giờ**

Loại mạng neuron	Dự báo điện năng 5 phút			Dự báo điện năng 1 giờ		
	Cấu trúc mạng tối ưu	Sai số trung bình	Sai số cực tiểu	Cấu trúc mạng tối ưu	Sai số trung bình	Sai số cực tiểu
MLFF	4-2	0,0044	0,00327	16	0,00161	0,00121
NARX	4	0,00622	0,0047	4	0,01087	0,00836
LSTM	4-4	0,00575	0,00478	16-2	0,00154	0,00147
NARX-LSTM	NARX(4)-LSTM(4-4)	0,00466	0,00404	NARX(4)-LSTM(16-2)	0,00154	0,00138

Các kết quả trên cho thấy rằng mạng MLFF vẫn cho kết quả rất tốt với cả 2 bài toán dự báo. Mạng NARX có sai số khá lớn so với các kiểu mạng neuron còn lại vì vậy không phù hợp cho bài toán dự báo ngắn hạn sản lượng điện mặt trời. Mạng LSTM cho kết quả tương đối tốt đối với cả 2 tập dữ liệu. Giá trị dự báo trung bình cho bài toán 1 giờ tốt hơn so với mạng MLFF, nhưng giá trị sai số cực tiểu không tốt bằng mô hình MLFF. Bên cạnh đó, việc kết hợp NARX-LSTM cho thấy hiệu quả hơn hẳn so với từng mô hình NARX và LSTM riêng lẻ.

**5. KẾT LUẬN**

Bài báo đã trình bày toàn diện việc khảo sát các mô hình mạng neuron nhân tạo để dự báo sản lượng điện năng hệ thống điện mặt trời mái nhà. Hai bài toán dự báo ngắn hạn được tính toán gồm dự báo 5 phút và dự báo 1 giờ. Dữ liệu quá khứ phục vụ cho việc dự báo thu thập tự động từ hệ thống giám sát điện mặt trời mái nhà gồm bức xạ mặt trời, nhiệt độ tấm quang điện, nhiệt độ cell quang điện, nhiệt độ môi trường và sản lượng thu nhận được. Bốn mô hình mạng neuron gồm mạng neuron truyền thẳng nhiều lớp (MLFF), mạng neuron hồi quy với đa biến

ngoại sinh (NARX), mô hình bộ nhớ dài-ngắn hạn LSTM và mô hình kết hợp NARX-LSTM. Trong từng mô hình, các tác giả cũng thử nghiệm nhiều cấu trúc mạng neuron để tìm ra cấu trúc tối ưu của từng mô hình mạng neuron. Kết quả cho thấy mô hình MLFF vẫn là mô hình tốt nhất để dự báo sản lượng điện năng. Sai số dự báo nhỏ nhất cho cả bài toán dự báo đều thấp hơn so với các phương pháp khác. Mô hình NARX tỏ ra không phù hợp với bài toán dự báo sản lượng điện mặt trời khi sai số dự báo lớn hơn hẳn các phương pháp còn lại. Tuy nhiên, việc kết hợp hai mô hình NARX-LSTM cho thấy hứa hẹn nhiều cải tiến trong việc dự báo. Sai số dự báo trung bình lẫn sai số dự báo nhỏ nhất đều thấp hơn từng mô hình NARX và LSTM riêng lẻ.

**LỜI CẢM ƠN**

Nghiên cứu này được tài trợ bởi **Trường Đại học Bách khoa - ĐHQG TPHCM** trong khuôn khổ đề tài mã số **To-ĐĐT-2021-02**. Chúng tôi xin cảm ơn Trường Đại học Bách khoa, Đại học Quốc gia Thành phố Hồ Chí Minh đã hỗ trợ cho nghiên cứu này.

**TÀI LIỆU THAM KHẢO**

Basodi, S., Ji, C., Zhang, H., & Pan, Y. (2020). Gradient amplification: An efficient way to train deep neural networks. *Big Data Mining and Analytics*, 3(3), 196-207.

Buitrago, J., & Asfour, S. (2017). Short-term forecasting of electric loads using nonlinear autoregressive artificial neural networks with exogenous vector inputs. *Energies*, 10(1), 40.

Elgarhy, S. M., Othman, M. M., Taha, A., & Hasanien, H. M. (2017, December). Short term load forecasting using ANN technique. In *2017 Nineteenth International Middle East Power Systems Conference (MEPCON)* (pp. 1385-1394). IEEE.

- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Kůrková, V. (1992). Kolmogorov's theorem and multilayer neural networks. *Neural networks*, 5(3), 501-506.
- Massaoudi, M., Chihi, I., Sidhom, L., Trabelsi, M., Refaat, S. S., & Oueslati, F. S. (2019). A novel approach based deep RNN using hybrid NARX-LSTM model for solar power forecasting. *arXiv preprint arXiv:1910.10064*.
- Raza, M. Q., & Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50, 1352-1372.
- Siegelmann, H. T., Horne, B. G., & Giles, C. L. (1997). Computational capabilities of recurrent NARX neural networks. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 27(2), 208-215.
- Zhang, H. T., Xu, F. Y., & Zhou, L. (2010, July). Artificial neural network for load forecasting in smart grid. In 2010 *International Conference On Machine Learning And Cybernetics* (Vol. 6, pp. 3200-3205). IEEE.