

# MÔ HÌNH DỰ BÁO PHỤ TẢI NGẮN HẠN SỬ DỤNG THUẬT TOÁN BỘ NHỚ NGẮN HẠN CÓ TRỄ

## THE SHORT-TERM LOAD FORECAST MODEL USING LONG – SHORT TERM ALGORITHM

**Vũ Thị Anh Thơ**

Trường Đại học Điện lực

Ngày nhận bài: 16/08/2021, Ngày chấp nhận đăng: 14/09/2021, Phản biện: TS. Nguyễn Đức Tuyên

### **Tóm tắt:**

Trong bài báo này, mô hình dự báo phụ tải ngắn hạn sử dụng thuật toán bộ nhớ ngắn hạn có trễ (Long Short-Term Memory - LSTM) được miêu tả một cách chi tiết. Đây là một trong các phương pháp dự báo phụ tải dựa trên mạng nơ ron nhân tạo (Artificial Neural Network – ANN). Bộ số liệu sử dụng trong nghiên cứu này là dữ liệu phụ tải của Đài Loan được thu thập trong giai đoạn từ ngày 1/6/2014 đến 30/6/2014. Kết quả dự báo của mô hình LSTM được so sánh với kết quả dự báo bằng thuật toán mạng nơ ron lan truyền ngược (Back Propagation Neural Network – BPNN) cho thấy hiệu quả cao hơn rõ rệt.

### **Từ khóa:**

Dự báo phụ tải ngắn hạn, dự báo phụ tải hàng ngày, mạng nơ ron nhân tạo, thuật toán bộ nhớ ngắn hạn có trễ, thuật toán lan truyền ngược.

### **Abstract:**

In this paper, a short-term load forecast model using the Long Short-Term Memory (LSTM) algorithm is described in detail. This is one of load forecast methods based on the Artificial Neural Network (ANN). The input data using in this research is the load data of Taiwan, collected from 01/6/2014 to 30/6/2014. The load forecasting result using LSTM model is compared to the result obtained from forecasting model using the Back-Propagation Neural Network (BPNN) algorithm show a visibly better efficacy.

### **Keywords:**

Short-term load forecast, daily load forecast, Artificial Neural Network, Long Short-Term Memory Algorithm, Back Propagation Algorithm.

## **1. GIỚI THIỆU CHUNG**

Dự báo phụ tải, bao gồm dự báo phụ tải dài hạn, trung hạn và ngắn hạn, là công cụ hỗ trợ đắc lực trong các công việc liên quan đến hệ thống điện; từ quy hoạch, phát triển cơ sở hạ tầng, đưa ra quyết định mua bán điện đến vận hành lưới điện [1] [2], [3]. Dự báo phụ tải ngắn hạn có phạm

vi dự báo từ khoảng 1h cho đến 1 tuần chịu ảnh hưởng của nhiều yếu tố, như thời gian (ngày trong năm, ngày trong tuần, giờ trong ngày...); thời tiết (nhiệt độ, độ ẩm, ánh sáng, mùa hè/ mùa đông...) và cả các yếu tố ngẫu nhiên như biến đổi đột ngột của phụ tải công nghiệp hoặc cả yếu tố địa lý [4]. Thực hiện dự báo phụ tải

ngắn hạn chính xác cho phép thực hiện cấu trúc/ tái cấu trúc lưới điện tối ưu, đồng thời lập kế hoạch phát điện đối với các nhà máy điện hay vận hành thị trường điện hiệu quả. Nhiều phương pháp và mô hình toán học khác nhau đã được nghiên cứu sử dụng để giải bài toán dự báo phụ tải ngắn hạn [5].

Mô hình mạng nơ ron nhân tạo (Artificial Neural Network – ANN) được phát triển từ thập niên cuối của thế kỷ 20 và được ứng dụng rộng rãi trong việc giải bài toán dự báo phụ tải ngắn hạn và làm cơ sở để phát triển nhiều mô hình dự báo phụ tải khác nhau [6]. Mạng nơ ron truyền thống có đặc điểm là các đầu vào và đầu ra độc lập với nhau và không liên kết thành chuỗi. Mạng nơ ron hồi quy (Recurrent Neural Network – RNN) dựa trên việc sử dụng các chuỗi thông tin, cho phép thực hiện cùng một tác vụ cho tất cả các phần tử của một chuỗi với đầu ra phụ thuộc vào cả các phép tính trước đó. RNN được sử dụng với mong muốn học được các tham số cài đặt sử dụng trong thuật toán dự báo một cách khéo léo để có thể xử lý được các phụ thuộc xa, tuy nhiên có nhiều nguyên nhân khiến thuật toán này không đạt được mục đích mong muốn [7].


Thuật toán bộ nhớ ngắn hạn có trễ (Long Short-Term Memory Networks – LSTM) - là một dạng đặc biệt của RNN được giới thiệu bởi Hochritter và Schmiduher vào năm 1997 [8]. LSTM có khả năng học được các phụ thuộc xa và hoạt động rất hiệu quả trên nhiều lĩnh vực khác nhau [9].

Trong nghiên cứu này, tác giả dự báo phụ tải của Đài Loan trong khoảng thời gian

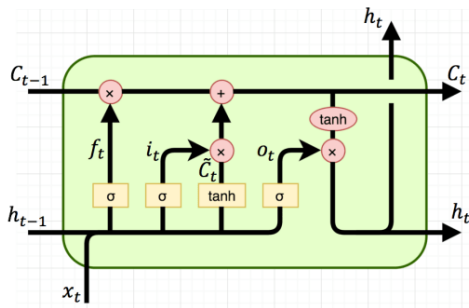
từ 01/06/2014 đến 30/06/2014 sử dụng thuật toán LSTM với kỳ vọng thu được sai số tốt hơn so với các nghiên cứu trước đó [10][11]. Các dữ liệu được đo và ghi nhận mỗi 15 phút một lần. Trong đó, phần dữ liệu thu thập từ 01/06/2014 đến 21/06/2014, chiếm 75% tổng lượng dữ liệu thu thập, được sử dụng để đào tạo, huấn luyện mô hình để dự báo các kết quả trong tương lai. Phần dữ liệu còn lại thu thập từ ngày 22/06/2014 đến 30/6/2014 được sử dụng để kiểm tra và đánh giá kết quả của mô hình dự báo phụ tải. Kết quả dự báo được so sánh với kết quả sử dụng thuật toán mạng nơ ron lan truyền ngược (Back Propagation Neural Network).

## 2. MÔ HÌNH DỰ BÁO PHỤ TẢI SỬ DỤNG THUẬT TOÁN LSTM

Thuật toán bộ nhớ ngắn hạn có trễ LSTM là một cải tiến của mạng nơ ron hồi quy RNN nhằm giải quyết vấn đề nhớ các bước dài của mạng nơ ron hồi quy. Bản thân LSTM cũng có kiến trúc dạng chuỗi các mô đun lặp đi lặp lại của các mạng hồi quy [8], nhưng thay vì chỉ có một tầng mạng nơ ron như mạng RNN chuẩn, LSTM có 4 tầng tương tác với nhau (Hình 1 và Hình 2).



Hình 1: Mô hình mô đun lặp lại của một LSTM



Hình 2: Sơ đồ cấu trúc bên trong của LSTM

Sơ đồ cấu trúc bên trong của một LSTM được thể hiện trong Hình 2. Một mô đun LSTM gồm một ô nhớ, một cổng đầu vào, một cổng đầu ra và một cổng quên, cho phép tạo ra khả năng bỏ đi hoặc thêm các thông tin cần thiết cho trạng thái tế bào.

Cụ thể ở trạng thái thứ  $t$  của mô hình LSTM có:

- Các đầu ra  $c_t$ ;  $h_t$  trong đó  $c$  là trạng thái tế bào và  $h$  là trạng thái ẩn.
- Các đầu vào  $c_{t-1}$ ;  $h_{t-1}$ ;  $x_t$  trong đó  $x_t$  là đầu vào của trạng thái thứ  $t$  của mô hình, còn  $c_{t-1}$ ;  $h_{t-1}$  là các đầu ra của trạng thái  $t-1$  trước đó.

Nguyên lý hoạt động của LSTM gồm 4 bước:

**Bước 1:** tầng cổng quên (tầng *sigmoid*) quyết định thông tin cần bỏ đi trạng thái tế bào. Cổng quên lấy đầu vào  $h_{t-1}$ ;  $x_{t-1}$  và đưa ra giá trị trong khoảng  $[0,1]$  cho mỗi trạng thái tế bào  $c_{t-1}$ . Giá trị 1 cho thấy toàn bộ thông tin được giữ lại, còn giá trị 0 nghĩa là toàn bộ thông tin sẽ bị loại bỏ. Phương trình đặc trưng cho bước thứ nhất:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Trong đó:

- $W_f$  là ma trận trọng số

- $h_{t-1}$  là đầu ra của trạng thái tế bào trước

- $x_t$  là trạng thái đầu vào

- $b_f$  là ma trận thiên vị

**Bước 2 :** lựa chọn thông tin mới được lưu lại đưa vào trạng thái tế bào. Đầu tiên một tầng cổng vào (tầng *sigmoid*) quyết định giá trị nào được cập nhật sau đó và một tầng *tanh* tạo ra véc tơ giá trị mới  $C_t$  thêm vào cho trạng thái. Hai giá trị này kết hợp tạo thành một cập nhật cho trạng thái.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\underline{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

**Bước 3:** trạng thái tế bào cũ  $C_{t-1}$  được cập nhật sang trạng thái tế bào mới  $C_t$  theo phương trình:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \underline{C}_t \quad (4)$$


**Bước 4:** giá trị đầu ra tiếp tục được sàng lọc và đưa ra. Một tầng *sigmoid* được sử dụng để xác định phần nào của trạng thái tế bào được xuất ra, sau đó trạng thái tế bào được đưa qua một hàm *tanh* để nhận giá trị của hàm này trong khoảng  $[-1,1]$  và nhân nó với đầu ra của hàm *sigmoid* để có được giá trị đầu ra mong muốn:

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (6)$$

Có thể thấy rằng LSTM đảm bảo thông tin được truyền đi thông suốt và tương tác tuyến tính bằng cách sử dụng trạng thái tế bào (cell-state) chạy xuyên suốt qua tất cả các nút mạng và tương tác tuyến tính. Nhờ vậy có thể nhớ được thông tin trong thời gian dài mà không cần thực hiện thao tác huấn luyện hay can thiệp khác, qua đó tránh được vấn đề phụ thuộc xa.

Mô hình dự báo phụ tải được đề xuất sử dụng thuật toán LSTM (Hình 3).



Hình 3: Mô hình LSTM cho dự báo phụ tải

Ở trạng thái thứ  $k$ , mô hình có 3 thông số đầu vào  $x(k)$  gồm:

- giá trị phụ tải tại bước thời gian trước **Load(t-1)**
- giá trị phụ tải một ngày trước cùng thời điểm **Load(t-24)**
- giá trị nhiệt độ hiện tại **Temp(t)**

Ngoài ra, có  $h(k-1)$  là đầu vào trạng thái ẩn thu được từ bước dự báo  $k-1$  trước đó, sử dụng cho các bước tính toán tại bước  $k$ . Sau bước tính toán thứ  $k$ , đầu ra  $h(k)$  được sử dụng làm đầu vào trạng thái ẩn trong bước tính toán  $k+1$  tiếp sau. Kết quả đầu ra  $y(k)$  là yêu cầu phụ tải được dự báo cho thời điểm  $t$ , mang giá trị **Load(t+)**.

Bảng 1: Các thông số của mô hình dự báo phụ tải bằng mô hình LSTM

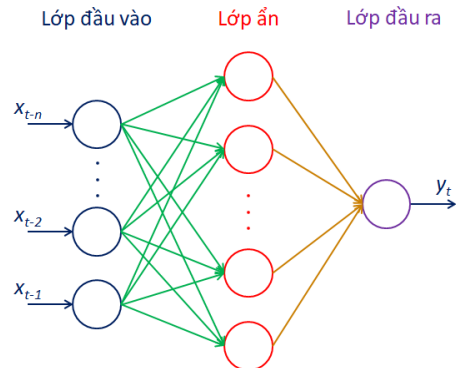
Đầu vào	LSTM
Đầu vào	Load (t-1) Load (t-24) Temp(t)
Số nơ ron lớp ẩn	80
Tốc độ học tập	0,01
Số vòng lặp	250
Kích thước Mini Batch	75
Hàm chuyển	'Adam'
Sai số	0,0001
Hệ số giảm tỉ lệ	0,02

Các thông số tổng quát của mô hình dự báo sử dụng phần mềm Matlab thể hiện trong Bảng 1.

Hàm chuyển “*Ước tính thời điểm thích ứng – Adaptive Moment Estimation*” (**‘Adam’**) trong Matlab được sử dụng cho phép tính toán tỉ lệ thích ứng cụ thể cho các thông số khác nhau. Hàm chuyển này lưu trữ bình phương của tốc độ trung bình di chuyển  $v(t)$  và giữ một động lượng  $m(t)$  nhằm giảm biến động của độ dốc.

Trong quá trình đào tạo, mô hình dự báo có thể bị **quá khớp** (over fitting) hoặc **chưa đủ khớp** (under fitting) do cập nhật trọng số bị dao động mạnh. Do đó, kỹ thuật giảm độ dốc (mini-batch gradient descent) được đề xuất để giải quyết vấn đề này. Mini - batch có kích thước là 75, nhỏ hơn tổng số dữ liệu  $N$  rất nhiều. Dữ liệu được xáo trộn ngẫu nhiên, sau đó được chia thành các mini-batch, mỗi mini-batch có  $n$  điểm dữ liệu (trừ mini-batch cuối có thể có ít hơn nếu  $N$  không chia hết cho  $n$ ). Mỗi lần cập nhật, thuật toán này lấy ra một mini - batch để tính toán đạo hàm rồi cập nhật.

### 3. MÔ HÌNH DỰ BÁO PHỤ TẢI SỬ DỤNG THUẬT TOÁN BP




Hình 4: Sơ đồ cấu trúc của BPNN

Mô hình thuật toán BP sử dụng phương pháp giảm độ dốc (gradient descent) để tìm được sai số nhỏ nhất thông qua việc tối ưu hóa các trọng số [12] thể hiện như Hình 4.

Cấu trúc cụ thể của BPNN sử dụng để giải bài toán dự báo phụ tải được thể hiện như trong Hình 5. Cấu trúc BPNN đơn giản gồm 3 lớp được sử dụng. Lớp đầu vào gồm có 3 nơ ron gồm giá trị phụ tải tại bước thời gian trước  $Load(t-1)$ ; giá trị phụ tải cùng thời điểm của một ngày trước  $Load(t-24)$  và giá trị nhiệt độ hiện tại  $Temp(t)$ . Lớp tiếp theo là lớp ẩn với 5 nơ ron và cuối cùng là lớp đầu ra với 1 nơ ron duy nhất.

Hàm chuyển giữa lớp đầu vào và lớp ẩn là hàm ‘*tan-sigmoid*’ trong khi hàm chuyển giữa lớp ẩn và lớp đầu ra được chọn là một hàm tuyến tính ‘*pureline*’ [13].



Hình 5: Cấu trúc cụ thể của BPNN cho bài toán dự báo phụ tải

Hàm đào tạo của mạng là thuật toán Levenberg – Marquardt [12]. Thuật toán này bao gồm chức năng đào tạo, giảm độ dốc với trọng số động (momentum weight) và hệ số học tập thiên vị (bias). Hàm đào tạo cập nhật weight và bias dựa trên tối ưu hóa Levenberg – Marquest.

Các thông số của mạng được trình bày trong Bảng 2.

Bảng 2: Các thông số của mô hình dự báo phụ tải bằng mô hình BPNN

ĐẦU VÀO	BPNN
Đầu vào	Load (t-1) Load (t-24) Temp(t)
Số lớp ẩn	1
Số nơ ron lớp ẩn	5
Tốc độ học tập	0,01
Số vòng lặp	250
Hàm chuyển	‘tansig’; ‘pureline’
Sai số	0,0001
Tốc độ học tập	0,01

#### 4. CÁC THÔNG SỐ ĐÁNH GIÁ HIỆU SUẤT CỦA MÔ HÌNH DỰ BÁO PHỤ TẢI

Để đánh giá hiệu suất mô hình dự báo phụ tải, tác giả lựa chọn các thông số:

- Căn bậc hai của sai số bình phương trung bình (Root Mean Square Error - RMSE)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (W_{forecast} - W_{true})^2} \quad (7)$$

- Sai số RMSE dưới dạng phần trăm (Normalized Root Mean Square Error - nRMSE)

$$nRMSE = \frac{RMSE}{W_{max} - W_{min}} \cdot 100\% \quad (8)$$

- Sai số trung bình tuyệt đối (Mean Absolute Error – MAE)

$$MAE = \frac{1}{N} \sum_{i=1}^N |W_{forecasted} - W_{true}| \quad (9)$$

- Số phần trăm sai số tuyệt đối (Mean Absolute Percentage Error – MAPE)

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|W_{forecasted} - W_{true}|}{W_{true}} \cdot 100\% \quad (10)$$


Trong đó:

- $W_{forecasted}$  là giá trị tải dự báo đầu ra của mô hình dự báo
- $W_{true}$  là giá trị tải thực tế
- $W_{max}$  và  $W_{min}$  lần lượt là giá trị lớn nhất và nhỏ nhất của phụ tải điện
- $N$  là số lượng mẫu

Các sai số dự báo này càng nhỏ thì độ chính xác của mô hình càng cao

## 5. ĐÁNH GIÁ KẾT QUẢ DỰ BÁO PHỤ TẢI

### 5.1 Mối tương quan giữa nhiệt độ môi trường và nhu cầu phụ tải điện



Hình 6: Mối tương quan tuyến tính giữa nhiệt độ và phụ tải


Mối tương quan giữa nhiệt độ môi trường và nhu cầu phụ tải điện trong phần này cho phép xác nhận lại một lần nữa mức độ ảnh hưởng của các yếu tố thời tiết tới nhu cầu phụ tải và dự báo phụ tải ngắn hạn.

Theo kết quả thu được (Hình 6), khi nhiệt độ môi trường tăng lên thì lượng điện năng tiêu thụ cũng tăng lên theo và ngược lại. Do vậy, việc sử dụng các dữ liệu về thời tiết trong dự báo phụ tải là cần thiết để cải thiện mức độ chính xác của mô hình dự báo phụ tải.


### 5.2 Đánh giá hiệu suất dự báo phụ tải của mô hình LSTM và BPNN

Bên cạnh yếu tố nhiệt độ môi trường, yếu tố yếu tố thời gian, cụ thể là yếu tố “**loại ngày**”, cụ thể là ngày làm việc và ngày cuối tuần cũng cần được xem xét do sự khác biệt lớn giữa sự biến thiên của phụ tải giữa những ngày này. Vào cuối tuần, nhu cầu phụ tải ít hơn rất nhiều so với ngày làm việc vì các toàn nhà, nhà máy và các cơ sở sản xuất kinh doanh đóng. Dữ liệu đầu vào được chia thành hai nhóm, được đào tạo độc lập trong cả hai mô hình dự báo và so sánh với kết quả thu được từ thực tế:

- Nhóm các ngày trong tuần: từ thứ Hai đến thứ Sáu
- Nhóm các ngày cuối tuần: gồm thứ Bảy và Chủ nhật.
- Kết quả dự báo phụ tải sử dụng thể hiện ở Hình 7 (mô hình BPNN) và Hình 8 (mô hình LSTM). Các thông số đánh giá hiệu quả mô phỏng của hai mô hình được tổng hợp trong Bảng 3.



Hình 7: Giá trị phụ tải điện dự báo và thực tế của mô hình BPNN



Hình 8: Giá trị phụ tải điện dự báo và thực tế của mô hình LSTM

Kết quả so sánh hiệu quả của hai phương pháp dự báo phụ tải được thể hiện (**Bảng 3**). Đối với cả hai phương pháp, sai số của dự báo cho nhóm các ngày cuối tuần (đồ thị dưới) luôn cao hơn sai số dự báo cho các ngày trong tuần (đồ thị trên). Cụ thể đối với phương pháp BPNN sai số nRMSE = 2,93% và sai số tuyệt đối là 0,9%, còn đối với ngày cuối tuần, các giá trị tương ứng lần lượt là 2,94% và 1,22%; còn đối với phương pháp LSTM, sai số nRMSR là 1,42% và sai số tuyệt đối là 1,42% cho ngày trong tuần, trong khi đối với ngày cuối tuần, các giá trị tương ứng lần lượt là 1,93% và 0,66%. Một số nguyên nhân có thể dẫn ra gồm:

- Chênh lệch về số lượng mẫu trong dữ liệu đào tạo: nhóm ngày cuối tuần có 576 mẫu, nhỏ hơn nhiều so với số lượng mẫu của ngày trong tuần (1440 mẫu), dẫn đến khả năng học tập yếu hơn và dự báo kém chính xác hơn.

Sự biến động trong hành vi, hoạt động sinh hoạt của con người vào cuối tuần: ở nhà, thực hiện các hoạt động trong nhà: nấu ăn, xem TV..., hoặc ra ngoài mua sắm, vui chơi... Điều này dẫn đến phụ tải ngày cuối tuần có nhiều biến động và thay đổi qua từng tuần so với ngày trong tuần và khó dự báo chính xác hơn.

So sánh sai số dự báo của hai phương pháp cho thấy thuật toán LSTM đem lại hiệu quả dự báo tốt hơn hẳn so với thuật toán BPNN nhờ vào việc sử dụng được các phụ thuộc xa trong ước lượng.

**Bảng 3: Các thông số đánh giá mô hình dự báo phụ tải**

Các thông số	BPNN		LSTM	
	Trong tuần	Cuối tuần	Trong tuần	Cuối tuần
RMSE (MW)	387,41	389,71	187,71	254,72
nRMSE (%)	2,93	2,94	1,42	1,93
MAE (MW)	243,88	315,99	115,44	173,52
MAPE (%)	0,9	1,22	0,43	0,66

Sai số nRMSE và sai số tuyệt đối của thuật toán BPNN thu được đều cao gấp đôi so với LSTM. Tuy nhiên, cũng do đặc điểm này, nhóm nghiên cứu ghi nhận được là thời gian tính toán của mô hình LSTM khá lâu so với mô hình BPNN.

### 5.3. Kết luận

Phương pháp dự báo phụ tải sử dụng thuật toán bộ nhớ ngắn hạn có trễ (LSTM) có hiệu quả dự báo tốt hơn rõ rệt so với sử dụng thuật toán BPNN, cho phép xác định giá trị phụ tải điện sử dụng trong khoảng thời gian một vài giờ cho đến 1 tuần và có thể sử dụng trong các ứng dụng để dự báo phụ tải của một khu vực cũng như một quốc gia. Hiệu quả này đạt được nhờ vào đặc điểm của thuật toán LSTM cho phép giữ lại dữ liệu của các bước tính toán trước đó, giải quyết được vấn đề phụ thuộc xa. Tuy nhiên cũng do đặc điểm này, nó có thể dẫn đến thời gian tính toán kéo dài với các cơ sở dữ liệu tính toán lớn hơn.

Hai thuật toán đều cho phép sử dụng nhiều giá trị đầu vào khác nhau. Trong nghiên cứu này, cả hai mô hình dự báo đều chỉ rõ sự phụ thuộc của phụ tải điện tiêu thụ với nhiệt độ môi trường. Các yếu tố môi trường khác như yếu tố mùa, gió, độ ẩm, lượng mưa... cũng có thể được xem xét sử dụng để đánh giá ảnh hưởng của các yếu tố này đến phụ tải điện một cách độc lập hoặc trong tổng thể.

Số lượng mẫu trong dữ liệu đào tạo cũng có ảnh hưởng lớn tới hiệu quả dự báo phụ tải. Việc sử dụng mô hình dự báo trong thời gian dài cộng với việc so sánh với giá trị phụ tải tiêu thụ thực tế có thể tăng lượng mẫu dữ liệu đào tạo hứa hẹn việc nâng cao hiệu quả dự báo phụ tải.

Để nâng cao hiệu suất dự báo phụ tải, cũng có thể xem xét sử dụng các thuật toán tối ưu như thuật toán di truyền (Generic Algorithm), thuật toán tối ưu bầy đàn (Particle Swarm Optimisation) ... để xác định các thông số cho mô hình dự báo.

## TÀI LIỆU THAM KHẢO

- [1] P. E. McSharry, S. Bouwman and G. Bloemhof, "Probabilistic forecasts of the magnitude and timing of peak electricity demand", IEEE Transactions on Power Systems, vol. 20, no. 2, pp. 1166-1172, May 2005.
- [2] E. Gonzalez-Romera, M. A. Jaramillo-Moran and D. Carmona-Fernandez, "Monthly Electric Energy Demand Forecasting Based on Trend Extraction," in IEEE Transactions on Power Systems, vol. 21, no. 4, pp. 1946-1953, Nov. 2006.
- [3] J. W. Taylor and P. E. McSharry, "Short-Term Load Forecasting Methods: An Evaluation Based on European Data," in IEEE Transactions on Power Systems, vol. 22, no. 4, pp. 2213-2219, Nov. 2007.
- [4] Fikru, M. G., & Gautier, L., "The impact of weather variation on energy consumption in residential houses," Applied Energy, 144, 2015.
- [5] L. Zhuang, H. Liu, J. Zhu, S. Wang and Y. Song, "Comparison of forecasting methods for power system short-term load forecasting based on neural networks," 2016 IEEE International Conference on Information and Automation (ICIA), 2016.
- [6] R. Rojas, Neural Networks - A Systematic Introduction, Springer-Verlag, Berlin, New-York, 1996.
- [7] Y. Bengio, P. Simard and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," in IEEE Transactions on Neural Networks, vol. 5, no. 2, pp. 157-166, March 1994.
- [8] Sepp Hochreiter, Jürgen Schmidhuber, "Long Short-Term Memory", Neural Computation 9, 1735–1780, 1997
- [9] Tian, Chujie, Jian Ma, Chunhong Zhang, and Panpan Zhan., "A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network," Energies 11, no. 12, 2018.
- [10] M. Pham et al., "An Effective Approach to ANN-Based Short-Term Load Forecasting Model Using Hybrid Algorithm GA-PSO", 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), pp. 1-5, 2018.
- [11] Pham, M.-H.; Vu, T.-A.-T.; Nguyen, D.-Q.; Dang, V.-H.; Nguyen, N.-T.; Dang, T.-H.; Nguyen, T.V. "Study on Selecting the Optimal Algorithm and the Effective Methodology to ANN-Based Short-Term Load Forecasting Model for the Southern Power Company in Vietnam", Energies 2019, 12, 2283.
- [12] Rumelhart, D., Hinton, G. & Williams, R., "Learning representations by back-propagating errors", Nature 323, 533–536, 1986.
- [13] Sibi P., Jones S. A. and Siddarth P. (2013). "Analysis of different activation functions using back propagation neural networks." Journal of Theoretical and Applied Information Technology 47 (3): 1264-1268.
- [14] Jorge J. Moré, "The Levenberg-Marquardt algorithm: Implementation and theory", Numerical Analysis, Volume 630, ISBN: 978-3-540-08538-6, 1978.

### Giới thiệu tác giả:



Tác giả Vũ Thị Anh Thơ tốt nghiệp đại học tại Trường Đại học Bách khoa Hà Nội năm 2006. Năm 2007 và năm 2011 nhận bằng thạc sĩ và Tiến sĩ ngành kỹ thuật điện tại Trường Đại học Grenoble, Cộng hòa Pháp. Hiện nay tác giả công tác tại Trường Đại học Điện lực. Hướng nghiên cứu chính: dự báo phụ tải, Tự động hóa hệ thống đi