

## SO SÁNH MỘT SỐ LOẠI MẠNG NƠ RON NHÂN TẠO TRONG DỰ BÁO SIÊU NGẮN HẠN CÔNG SUẤT PHÁT CỦA TUA BIN GIÓ: ỨNG DỤNG CHO NHÀ MÁY ĐIỆN GIÓ THÁI HÒA, BÌNH THUẬN

### A COMPARISON OF NEURAL NETWORK ARCHITECTURES FOR ULTRA SHORT TERM WIND POWER FORECASTING: A CASE STUDY OF THAI HOA WIND FARM IN BINH THUAN

**Đặng Thành Trung**

Trường Đại học Điện lực

Ngày nhận bài: 05/6/2025; Ngày chấp nhận đăng: 11/8/2025

#### **Tóm tắt:**

Bài báo này đề xuất so sánh 3 loại mạng nơ ron nhân tạo bao gồm mạng nơ ron truyền thẳng – MLP, mạng nơ ron RBF, mạng nơ ron Elman để dự báo siêu ngắn hạn công suất phát của tua bin gió. Sau khi chạy thử nghiệm trên số liệu của tua bin gió 5MW của nhà máy điện gió Thái Hòa, Bình Thuận cho kết quả mạng nơ ron truyền thẳng – MLP đảm bảo được tốc độ tính toán và sai số tốt nhất. Nghiên cứu này giúp đưa ra phương pháp phù hợp cho bài toán dự báo siêu ngắn hạn công suất phát của tua bin gió trong trường hợp giới hạn năng lực tính toán của máy tính và số liệu đầu vào.

#### **Từ khóa:**

Dự báo công suất phát siêu ngắn hạn của tua bin gió, mạng nơ ron truyền thẳng MLP, mạng nơ ron RBF, mạng nơ ron Elman.

#### **Abstract:**

This paper proposes a comparison of three types of artificial neural networks, including the multilayer perceptron neural network (MLP), the radial basis function (RBF) neural network, and the Elman neural network, for ultra-short-term forecasting of wind turbine power generation. Experimental results, based on the power generation data from the 5MW wind turbines at the Thai Hoa, Binh Thuan wind farm, indicate that the multilayer perceptron neural network achieves optimal computational speed and accuracy. This research helps to provide a suitable method for the ultra-short-term forecasting of wind turbine power generation in cases with limited computational capacity and input data.

#### **Keywords:**

Ultra short term wind power forecasting, multilayer perceptron neural network, radial basis function (RBF) neural network, Elman neural network.

## 1. GIỚI THIỆU CHUNG

Ở Việt Nam, năng lượng gió ngày càng được đầu tư phát triển và tăng dần tỷ trọng trong cơ cấu nguồn điện. Theo quy hoạch điện VIII, tính đến năm 2030, tổng công suất điện gió đạt 26.066 – 38.029 MW. Tuy nhiên, do tính biến thiên liên tục của nguồn điện gió nên sẽ ảnh hưởng lớn đến vận hành hệ thống điện. Do đó dự báo siêu ngắn hạn (khoảng thời gian dưới 4 giờ) công suất phát của tua bin gió là điều rất quan trọng nhằm giúp cho cập nhật kế hoạch vận hành và cung cấp thông tin cho thị trường mua bán điện cạnh tranh theo thời gian thực. Có nhiều phương pháp để dự báo siêu ngắn hạn như sử dụng phân tích chuỗi thời gian, học máy và học sâu như đã trình bày chi tiết trong nghiên cứu [1] trong đó sử dụng mạng nơ ron nhân tạo là một giải pháp mang nhiều tính ưu việt. Nghiên cứu [2] dự báo siêu ngắn hạn và ngắn hạn công suất phát của tua bin gió bằng phương pháp trung bình trượt tự hồi quy - ARMA (Autoregressive Moving Average), mạng nơ ron nhân tạo - ANN (Artificial Neural Networks), mạng nơ ron mờ thích ứng - ANFIS (Adaptive Neuro-Fuzzy Inference Systems). Trong đó, với dự báo siêu ngắn hạn, sử dụng mạng nơ ron nhân tạo cho kết quả tốt nhất trong 3 phương pháp đề xuất. Nghiên cứu [4] đề xuất sử dụng mô hình dự báo dựa trên kết hợp mạng nơ ron tích chập – CNN (Convolutional neural network) và LightGBM, mạng nơ ron tích chập để dự báo siêu ngắn hạn công suất phát của tua bin gió với đầy đủ các thông số đầu vào gồm nhiệt độ, trạng thái của tua bin, tốc độ gió, tốc độ quay motor, hướng gió, điện

năng của tua bin gió tạo ra trong 5 phút trước, góc dọc, công suất phát tức thời của tua bin. Mặc dù nghiên cứu này cho sai số tốt, tuy nhiên yêu cầu nhiều thông số đầu vào và hệ thống máy tính tốc độ cao để đào tạo và dự báo. Nghiên cứu [5] sử dụng tốc độ gió từ kết quả dự báo thời tiết -NWP (Numerical Weather Prediction) kết hợp phương pháp phân tích đa phân giải, [7] kết hợp phương pháp học máy – ELM (Extreme learning machine) và mạng bộ nhớ dài ngắn hạn – LSTM (Long short-term memory network), [8] sử dụng mạng nơ ron niềm tin sâu – DBN (Deep belief network), [11] kết hợp bộ nhớ dài ngắn hạn – LSTM và thuật toán lừng mật ong cải tiến – HBA (Honey Badger Algorithm) để dự báo siêu ngắn hạn công suất phát của tua bin gió. Nghiên cứu [3], [6], [9], [10], [12] [13], [14] sử dụng mạng nơ ron truyền thẳng, mạng nơ ron RBF, mạng nơ ron Elman để dự siêu ngắn hạn công suất phát của tua bin gió, của giàn pin mặt trời, công suất tiêu thụ của phụ tải điện.

Các nghiên cứu trên cho thấy, phương pháp mạng nơ ron nhân tạo có thể giúp dự báo siêu ngắn hạn công suất phát của tua bin gió và đảm bảo thời gian tính toán với khả năng tính toán của các bộ máy tính cá nhân. Trong đó mạng nơ ron truyền thẳng, mạng nơ ron RBF, mạng nơ ron Elman thường được sử dụng cho bài toán dự báo này.

## 2. MỘT SỐ LOẠI MẠNG NƠ RON NHÂN TẠO SỬ DỤNG CHO DỰ BÁO

### 2.1. Mạng nơ ron truyền thẳng

Sơ đồ của mạng nơ ron truyền thẳng như trong hình 2. Cấu tạo chung của mạng nơ

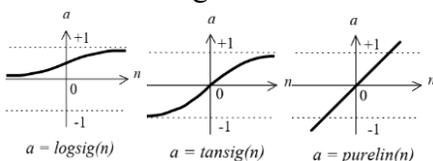
ron truyền thẳng thường gồm đầu vào, lớp ẩn và lớp đầu ra. Trong đó, mạng nơ ron có thể có một hoặc nhiều lớp ẩn. Với các bài toán dự báo thì mạng nơ ron sẽ bao gồm lớp đầu vào, 1 lớp ẩn và 1 lớp đầu ra. Trên hình vẽ 2, mạng nơ ron có  $n_{in}$  đầu vào,  $n_{hid}$  nơ ron lớp ẩn và  $n_{out}$  đầu ra. Như vậy véc tơ các trị đầu vào IP gồm  $n_{in}$  phần tử, véc tơ các giá trị đầu ra OP gồm  $n_{out}$  phần tử. Các giá trị đầu vào sẽ được kết nối với các nơ ron lớp ẩn bằng các trọng số  $iw_{lj}$  của ma trận trọng số đầu vào IW, trong đó  $j$  là số thứ tự của đầu vào (số thứ tự từ 1 đến  $n_{in}$ ),  $l$  là số thứ tự của nơ ron lớp ẩn (số thứ tự từ 1 đến đến  $n_{hid}$ ). Tổng các giá trị kết nối này sẽ được đưa vào các nơ ron lớp ẩn. Sau khi qua hàm truyền của các nơ ron lớp ẩn, các giá trị đầu ra này sẽ được kết nối với các nơ ron lớp đầu ra bằng các trọng số  $w_{ml}$  của ma trận trọng số đầu ra OW, trong đó  $m$  là số thứ tự của đầu ra (số thứ tự từ 1 đến  $n_{out}$ ). Tại các nơ ron sẽ bổ sung thêm các tham số  $b_i$  cho lớp ẩn và  $b_o$  cho lớp đầu ra. Đầu vào cho hàm truyền nơ ron thứ  $l$  của lớp ẩn là  $si_l$  được tính theo công thức 2.1:

$$si_l = \sum_{j=1}^{n_{in}} iw_{lj} \cdot ip_j + bi_l \quad (2.1)$$

Giá trị  $si_l$  sẽ trở thành đầu vào cho hàm truyền của nơ ron lớp ẩn :

$$yi_l = f_h(si_l) \quad (2.2)$$

Các hàm truyền thường được sử dụng cho mạng nơ ron truyền thẳng là tansig, logsig và purelin như trong hình 1



Hình 1. Hàm logsig, tansig và purelin

Các giá trị đầu ra của hàm truyền sẽ được

kết nối với các nơ ron lớp đầu ra. Xét với nơ ron thứ  $m$  của lớp đầu ra, tổng các kết nối và tham số đến nơ ron là  $so_m$  được tính theo công thức 2.3:

$$so_m = \sum_{l=1}^{n_{hid}} ow_{m,l} \cdot yi_l + bo_m \quad (2.3)$$

Giá trị  $so_m$  sẽ trở thành đầu vào cho hàm truyền của nơ ron lớp đầu ra:

$$yo_m = f_o(so_m) \quad (2.4)$$

Giá trị này chính ra giá trị đầu ra thứ  $m$  của mạng  $op_m$ .

Sai số được tính dựa trên giá trị đầu ra  $op_m$  của mạng và giá trị đầu ra tương ứng của bộ số liệu thu thập được  $tg_m$ . Sai số tại bộ số thứ  $k$  của đầu ra thứ  $m$  được tính như sau:

$$er_m^{(k)} = tg_m^{(k)} - op_m^{(k)} \quad (2.5)$$

Ngoài ra, khi đào tạo và đánh giá mạng nơ ron thì hàm sai số còn tính theo các công thức từ 2.13 đến 2.16 ở mục 2.4. Thông thường sẽ sử dụng giá trị sai số bình phương trung bình (theo công thức 2.13) để đào tạo mạng.

Đào tạo mạng nơ ron truyền thẳng chính là tìm giá trị trọng số  $iw_{l,j}$ ;  $ow_{m,l}$  và tham số  $bi_l$ ;  $bo_m$  để giá trị sai số nhỏ nhất. Bằng cách cho các đạo hàm riêng của hàm sai số (mse) theo các biến trọng số và tham số bằng 0, ta sẽ tính được các giá trị tương ứng của trọng số và tham số để hàm sai số nhỏ nhất.

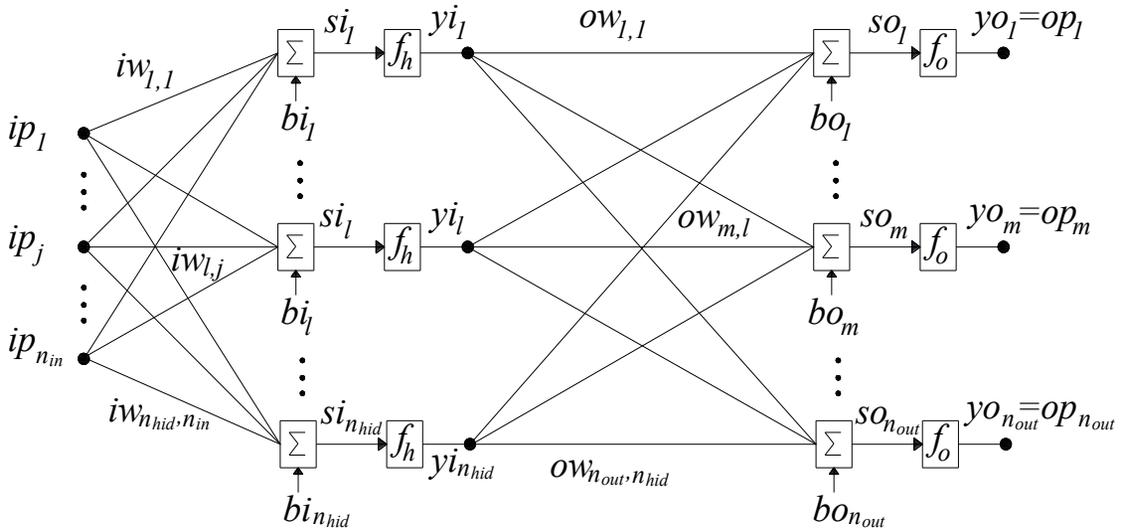
Trong quá trình đào tạo thực tế, người ta sẽ dùng các phép lặp để tiến tới giá trị tham số và trọng số tối ưu theo phương trình (2.6)

$$Wb^{(k+1)} = Wb^{(k)} + \alpha^{(k)} \cdot G^{(k)} \quad (2.6)$$

Trong đó  $Wb^{(k)}$ ,  $Wb^{(k+1)}$  là ma trận gồm các giá trị trọng số  $iw_{l,j}$ ;  $ow_{m,l}$  và các tham số  $bi_l$ ;  $bo_m$  cần tìm tại bước lặp thứ

$k$  và thứ  $k+1$ ;  $\alpha^{(k)}$  là tốc độ học ;  $G^{(k)}$  là ma trận độ dốc tính toán được xác định dựa

trên đạo hàm của hàm sai số (mse) theo các biến trong ma trận  $Wb$ .



Hình 2. Sơ đồ cấu tạo mạng nơ ron truyền thẳng (Multilayer perceptron neural network)

Giá trị của các trọng số và tham số sau khi đào tạo sẽ được sử dụng để tính các giá trị đầu ra dựa vào các giá trị đầu vào tương ứng theo các công thức từ 2.1 đến 2.4.

## 2.2. Mạng nơ ron RBF (RBF neural network)

Sơ đồ của mạng nơ ron RBF như trong hình 4. Tương tự như mạng nơ ron truyền thẳng, cấu tạo của mạng nơ ron RBF gồm lớp vào, lớp ẩn và lớp đầu ra. Trên hình vẽ 4, mạng nơ ron RBF có  $n_{in}$  đầu vào,  $n_{hid}$  nơ ron lớp ẩn và  $n_{out}$  đầu ra. Các giá trị đầu vào sẽ được kết nối với các nơ ron lớp ẩn bằng các trọng số  $iw_{lj}$  của ma trận trọng số đầu vào  $IW$ , trong đó  $j$  là số thứ tự của đầu vào (số thứ tự từ 1 đến  $n_{in}$ ),  $l$  là số thứ tự của nơ ron lớp ẩn (số thứ tự từ 1 đến  $n_{hid}$ ). Các giá trị đầu vào ( $ip$ ) và các giá trị trọng số ( $iw$ ) sẽ được đưa qua một hàm khoảng cách véc tơ (dist) để tính khoảng cách trong không gian giữa véc tơ giá trị đầu vào và véc tơ trọng số. Khoảng cách

tại nơ ron thứ  $l$  so với các giá trị trọng số tương ứng được tính theo công thức 2.7:

$$d_{il} = \sqrt{\sum_{j=1}^{n_{in}} (ip_j - iw_{lj})^2} \quad (2.7)$$

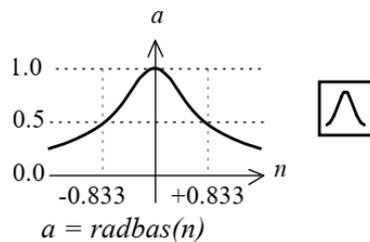
Sau khi qua hàm tính khoảng cách, giá trị khoảng cách tính được sẽ được nhân với tham số tại nơ ron đó ( $bi_l$ ) theo công thức 2.8 :

$$m_{il} = d_{il} \cdot bi_l \quad (2.8)$$

Giá trị  $m_{il}$  sẽ là đầu vào của hàm radbad theo công thức 2.9.

$$y_{il} = radbas(m_{il}) = e^{-m_{il}^2} \quad (2.9)$$

Đặc tính hàm radbad được thể hiện trong hình vẽ 3



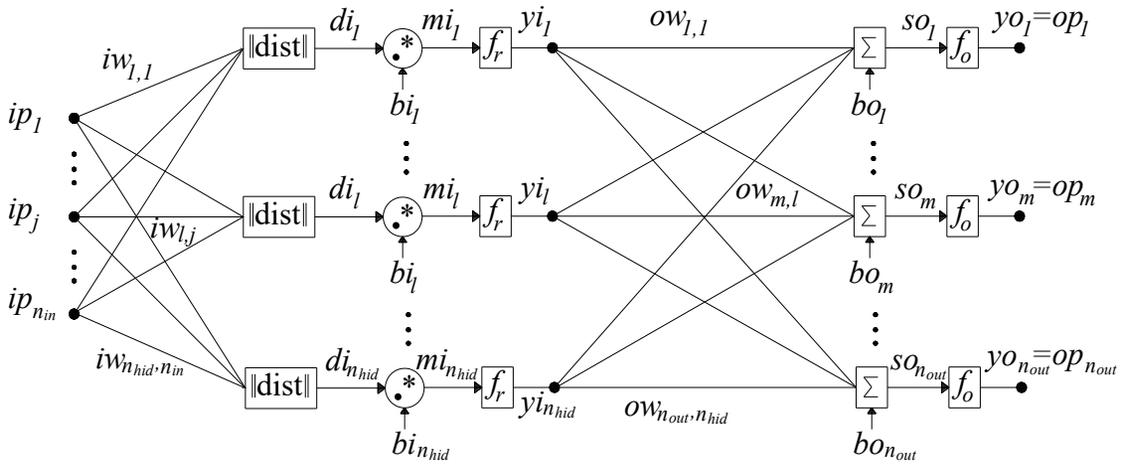
Hình 3. Hàm radial basis (radbab)

Các giá trị đầu ra của hàm radbad sẽ được kết nối với các nơ ron lớp đầu ra. Xét với

nơ ron thứ  $m$  của lớp đầu ra, tổng các kết nối và tham số đến nơ ron là  $so_m$  được tính theo công thức 2.3 tương tự như mạng nơ ron truyền thẳng. Giá trị  $so_m$  sẽ trở thành đầu vào cho hàm truyền của nơ ron lớp đầu ra theo công thức 2.4 tương tự như mạng nơ ron truyền thẳng. Với mạng nơ ron RBF thường sử dụng hàm tuyến tính purelin cho nơ ron lớp đầu ra. Giá trị này chính ra giá trị đầu ra thứ  $m$  của mạng  $op_m$ .

Sai số là kết quả so sánh giữa giá trị đầu ra tương ứng và giá trị đầu ra thu thập được từ bộ số liệu. Mạng RBF thường sử dụng sai số bình phương trung bình theo công thức 2.13 để làm sai số chuẩn khi đào tạo và đánh giá hiệu quả của mạng. Quá trình đào tạo mạng RBF gồm 2 bước :

- + Bước 1 : Chọn tâm và xác định độ rộng bán kính.
- + Bước 2 : Huấn luyện trọng số lớp đầu ra.



Hình 4. Sơ đồ cấu tạo mạng nơ ron RBF (Radial basis network)

Chọn tâm chính là lựa chọn các giá trị của ma trận IW (gồm các giá trị  $iw_{lj}$ ) được thực hiện theo các bước sau:

+ Bước 1.a : Lựa chọn ngẫu nhiên các giá trị  $IW^{(l)}$  bao gồm các trọng số nối từ đầu vào 1 đến năm  $n_{in}$  đến nơ ron thứ  $l$  ( $iw_{lj}$ ) trong bộ số liệu đầu vào (ví dụ chọn giá trị đầu vào thứ  $u$  -  $IP^{(u)}$  trong bộ số liệu) gọi là tâm IW. Số lượng tâm chính là số nơ ron lớp ẩn  $n_{hid}$  đặt trước.

+ Bước 1.b : Tính khoảng cách mỗi điểm dữ liệu  $IP^{(u)}$  đến tất cả các tâm theo công thức 2.10 và gán giá trị  $IP^{(u)}$  vào tâm có khoảng cách gần nhất.

$$d(IP^{(u)}, IW^{(l)}) = \|IP^{(u)} - IW^{(l)}\| \quad (2.10)$$

+ Bước 1.c : Với mỗi nhóm tâm thứ  $l$  vừa

gán, tính lại tâm  $IW^{(l)}$  bằng trung bình cộng của tất cả các điểm thuộc nhóm đó.

Lặp lại bước 1.a, 1.b đến khi hội tụ hoặc vượt quá số lần lặp đặt trước. Sau khi chọn được tâm, tính độ rộng theo công thức 2.11. Trong đó  $d_{maxl}$  là khoảng cách lớn nhất từ tâm thứ  $l$  đến các số liệu đầu vào tính theo công thức 2.10

$$\sigma_l = \frac{d_{maxl}}{\sqrt{2 \cdot n_{hid}}} \quad (2.11)$$

Sau khi chọn được tâm và khoảng cách sẽ tính được giá trị đầu ra của nơ ron lớp ẩn theo công thức 2.7 đến 2.9. Kết hợp giá trị đầu ra của nơ ron lớp ẩn và giá trị đầu ra của bộ số liệu tương ứng ta sẽ tính được các trọng số của lớp đầu ra OW để sai số

bình phương trung bình nhỏ nhất tương tự như đào tạo mạng nơ ron truyền thẳng. Trong quá trình đào tạo, khi sai số không đảm bảo ta sẽ tăng số nơ ron lớp ẩn lên đến khi sai số nằm trong giá trị cho phép hoặc số nơ ron lớp ẩn lớn hơn giá trị cho phép đặt trước.

### 2.3. Mạng nơ ron Elman (Elman network)

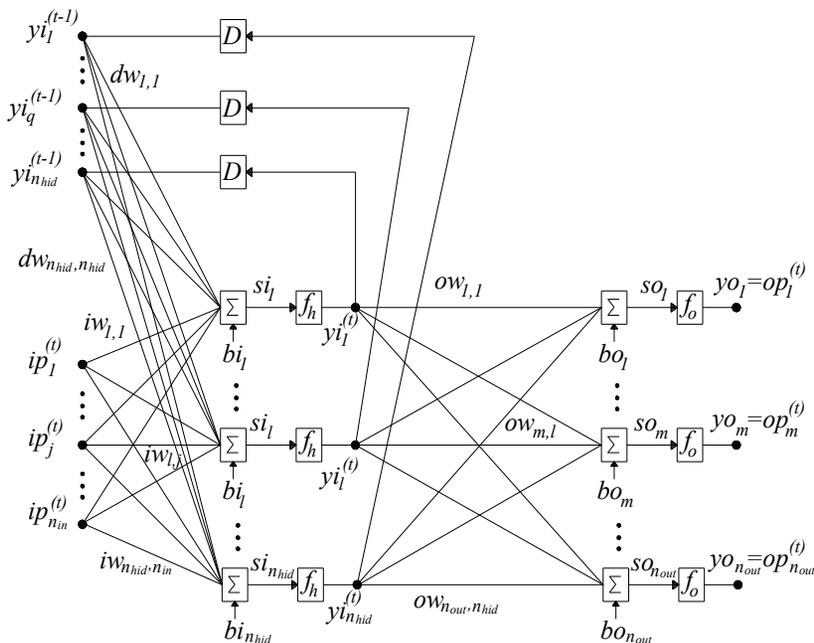
Sơ đồ của mạng nơ ron Elman như trong hình 5. Tương tự mạng nơ ron truyền thẳng, mạng Elman cũng có lớp đầu vào, lớp ẩn và lớp đầu ra. Tuy nhiên, mạng nơ ron Elman có thêm một lớp hồi quy lấy tín hiệu đầu ra hàm truyền lớp ẩn từ dữ liệu đầu vào của số liệu thời gian trước và đưa trở lại thành đầu vào mạng qua trọng số DW. Giả thiết giá trị đầu vào tại thời điểm  $t$  là  $ip_1^{(t)}, \dots, ip_j^{(t)}, \dots, ip_{n_{in}}^{(t)}$ . Các giá trị đầu vào này sẽ kết hợp với các trọng số ma trận đầu vào IW để đưa đến đầu vào của nơ ron

lớp ẩn. Ngoài ra, đầu ra của nơ ron lớp ẩn từ các giá trị đầu vào tại thời điểm ngay trước đó  $t-1$  sẽ được kết hợp với ma trận hồi quy DW để đưa ngược trở lại thành giá trị đầu vào của nơ ron lớp ẩn theo công thức 2.12

$$s_{i_l} = \sum_{n_{in}}^{j=1} iw_{l,j} \cdot ip_j^{(t)} + \sum_{n_{hid}}^{q=1} dw_{l,q} \cdot yi_q^{(t-1)} + bi_l \quad (2.12)$$

Giá trị  $s_{i_l}$  sẽ được đưa vào hàm truyền lớp ẩn và tiếp tục được đưa đến lớp đầu ra tương tự như mạng nơ ron truyền thẳng theo công thức 2.2 đến 2.4.

Đào tạo mạng nơ ron Elman là tìm các giá trị trọng số  $iw_{lj}$ ,  $dw_{lk}$ ,  $ow_{ml}$  và các tham số  $bi_l$ ,  $bo_m$  để sai số bình phương trung bình theo công thức 2.13 cực tiểu. Các giá trị trọng số này được tính theo công thức 2.6 trong đó  $Wb^{(k)}$  là ma trận các giá trị trọng số  $iw_{lj}$ ,  $dw_{lq}$ ,  $ow_{ml}$  và các tham số  $bi_l$ ,  $bo_m$ .



Hình 5. Sơ đồ cấu tạo mạng nơ ron Elman

## 2.4. Đánh giá sai số

Trong bài toán sử dụng mạng nơ ron nhân tạo để dự báo, sai số thường được đánh giá dựa trên các chỉ tiêu sau đây:

+ MSE (Mean Square Error) : Sai số bình phương trung bình

$$MSE = \frac{1}{n} \cdot \sum_{i=1}^n (tg_i - op_i)^2 \quad (2.13)$$

trong đó: n: số mẫu thực hiện trong dự báo;  
 $tg_i, op_i$ : giá trị thực tế và giá trị đầu ra dự báo của mạng nơ ron trong bộ số liệu;

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (tg_i - op_i)^2}{n}} \quad (2.14)$$

+ MAE (Mean Absolute Error) : Sai số tuyệt đối trung bình

$$MAE = \frac{\sum_{i=1}^n |tg_i - op_i|}{n} \quad (2.15)$$

+ MAPE (Mean Absolute Percentage Error) : Sai số phần trăm tuyệt đối trung bình

$$MAPE = \frac{\sum_{i=1}^n \frac{|tg_i - op_i|}{tg_i} \times 100}{n} \quad (2.16)$$

Các công thức 2.13 đến 2.16 sẽ được sử dụng để đánh giá sai số khi thử nghiệm kết quả ở mục 3.

## 3. KẾT QUẢ THỬ NGHIỆM

Nhà máy điện gió Thái Hòa tại xã Hòa Thắng, huyện Bắc Bình, tỉnh Bình Thuận. Tổng công suất đặt của nhà máy là 90 MW gồm 18 tuabin gió do hãng Siemens cung cấp, mỗi tua bin gió công suất 5000 kW. Số liệu thu thập được từ ngày 01 tháng 07 năm 2023 đến ngày 30 tháng 09 năm 2023 bao gồm 12348 số liệu công suất phát của tua bin gió số 5, mỗi lần ghi số liệu cách nhau 10 phút. Dựa trên bộ số liệu thu thập được, nghiên cứu sử dụng các mô hình

mạng nơ ron ở mục 2 để dự báo công suất phát của tua bin gió đó ở thời điểm 10 phút tiếp theo. Trong bộ số liệu gồm 12348 số liệu sẽ được chia ngẫu nhiên thành 20% sử dụng để kiểm tra, 80% được sử dụng để đào tạo. Với mạng nơ ron truyền thẳng sẽ sử dụng 10% để ước lượng và dừng sớm và 70% để đào tạo.

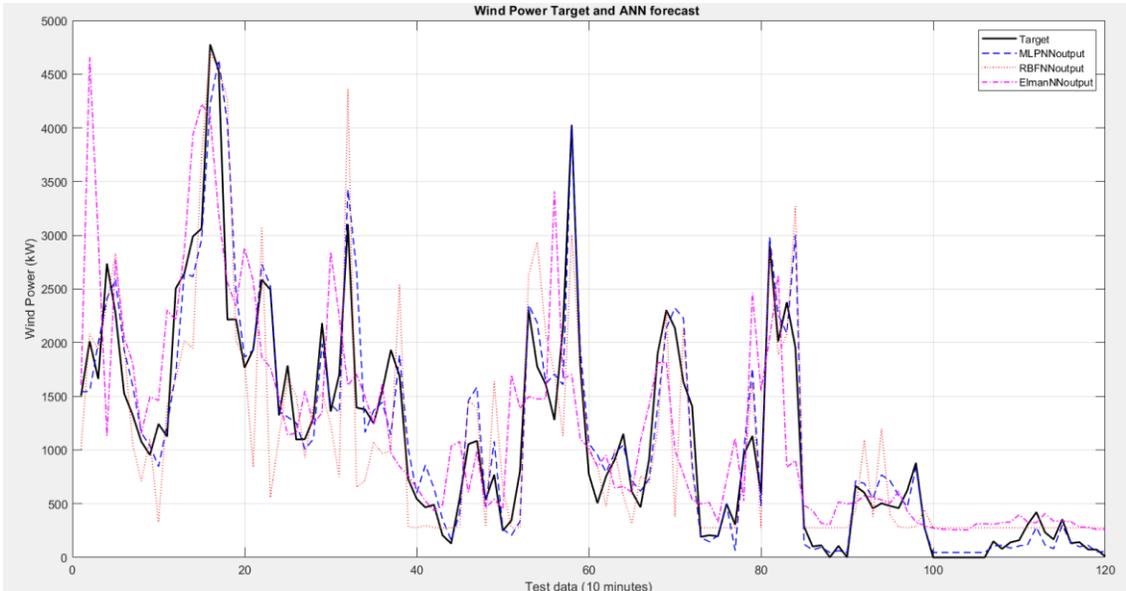
Do việc thu thập số liệu chỉ bao gồm công suất phát nên mỗi mạng nơ ron chỉ có 1 đầu vào và 1 đầu ra là công suất phát của tua bin ở thời điểm cần dự báo và công suất phát của tua bin trước đó 10 phút.

Dựa vào số đầu vào và đầu ra nên chọn số nơ ron lớp ẩn của mạng nơ ron truyền thẳng, mạng nơ ron Elman sử dụng cho tính toán thử nghiệm được chọn là 10 nơ ron. Còn đối với mạng nơ ron RBF, do giới hạn về tốc độ tính toán và thời gian tính toán nên chọn số nơ ron tối đa là 2000 nơ ron. Hàm truyền nơ ron lớp ẩn là 'tansig', hàm truyền nơ ron lớp đầu ra là 'purelin'. Đồ thị kết quả dự báo theo mạng nơ ron truyền thẳng, mạng nơ ron RBF, mạng nơ ron Elman so với mục tiêu thực tế trong tập số liệu kiểm tra như trong hình 6. Bảng kết quả sai số của tập đào tạo (train) và tập dự báo (test) khi sử dụng các mạng nơ ron ở mục 2.1-2.3 như trong bảng 1 theo các đánh giá sai số trong mục 2.4.

Từ bảng 1 ta thấy rằng mạng nơ ron truyền thẳng MLP sẽ cho kết quả sai số tốt nhất so với mạng nơ ron RBF và mạng nơ ron Elman. Ngoài ra, sai số dự báo còn cao do nhà máy điện gió Thái Hòa có tham gia chương trình tự động sa thải nguồn – AGC (Automatic Generation Control). Khi công suất đường dây truyền tải bị quá tải hoặc

công suất phát lớn hơn công suất tiêu thụ thì trung tâm điều độ có thể điều khiển không cho tua bin gió phát điện. Do đó dẫn tới một số thời điểm, công suất phát của tua bin gió đang rất lớn đột ngột giảm về 0 làm tăng sai số dự báo.

Để tăng độ chính xác dự báo, nhà máy cần thu thập các số liệu về tốc độ gió, hướng gió tại điểm đặt tua bin và các vùng lân cận, số liệu thời tiết và dự kiến sa thải nguồn của trung tâm điều độ.



Hình 6. Kết quả sai số khi của 120 dữ liệu trong tập dự báo  
Bảng 1. Kết quả sai số khi đào tạo và dự báo

Mạng	Tập số liệu	mse ( $kW^2$ )	rmse (kW)	mae (kW)	mape (%)	Thời gian
MLP	Train	182421	427,11	286,55	35,93	0,672 s
	Test	188105	433,71	289,15	29,65	
RBF	Train	161124,6	401,4	298,08	65,54	3h38min 51s
	Test	136536,8	369,51	122,98	74,07	
Elman	Train	3508382	1873,07	1203,59	89,81	1,104 s
	Test	667392	816,94	570,51	132,56	

## TÀI LIỆU THAM KHẢO

- [1] Yulong Chen, Xue Hu, Lixin Zhang, "A review of ultra-short-term forecasting of wind power based on data decomposition-forecasting technology combination mode," Energy Reports 8 (2022) pp.14200–14219, 2022.
- [2] Qin Chen, Komla A Folly, "Comparison of Three Methods for Short-Term Wind Power Forecasting," 2018 International Joint Conference on Neural Networks (IJCNN), 2018.
- [3] Cao Gao-cheng, Huang Dao-huo, "Ultra-Short-Term wind speed prediction using RBF Neural Network," International Symposium on Computers & Informatics (ISCI 2015), 2015.
- [4] Yun Ju, Guangyu Sun, Quanhe Chen, Min Zhang, Huixuan Zhu, Mujeeb Ur Rehman, "A Model Combining Convolutional Neural Network and LightGBM Algorithm for Ultrashort-term Wind Power Forecasting," IEEE Access ( Volume: 7), pp. 28309 - 28318, 2019.
- [5] Lei Dong, Liang Ren, Shuang Gao, Yang Gao, Xiaozhong Liao, "Studies on Wind Farms Ultra-short Term NWP Wind Speed Correction Methods," 25th Chinese Control and Decision Conference (CCDC), pp. 1576-1579, 2013.
- [6] Yimei Wang, Yongqian Liu, Jie Yan, Shuang Han, "Research on Applicability of Ultra-short Term Wind Power Forecasting Models," 3rd Renewable Power Generation Conference (RPG 2014), 2014.
- [7] Pan Guangxu, Zhang Haijing, Ju Wenjie, Yang Weijin, Qin Chenglong, Pei Liwei, Sun Yuan, Wang Ruiqi, "A Prediction Method for Ultra Short-Term Wind Power Prediction Basing on Long Short -Term Memory Network and Extreme Learning Machine," Chinese Automation Congress (CAC), pp. 7608 - 7612, 2020.
- [8] Wanxing Ma, Zhimin Chen, Qing Zhu, "Ultra-Short-Term Forecasting of Photo-Voltaic Power via RBF Neural Network," Electronics October 2020 Vol 9, 2020.
- [9] Jinxuan LI, Jiandong MAO, "Ultra-Short-Term Wind Power Prediction Using BP Neural Network," 9th IEEE Conference on Industrial Electronics and Applications, pp. 2001-2006, 2014.
- [10] Zihan Sun, Yanlong Liu, Mingyu Xu, Wanlin Guan, "Wind power prediction based on Elman neural network model optimized by improved genetic algorithm," IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE 2021), pp. 413-416, 2021.
- [11] Lei Guo, Chang Xu, Tianhang Yu, Tuerxun Wumaier, Xingxing Han, "Ultra-short-term wind power forecasting based on long short-term memory network with modified honey badger algorithm," Energy Reports 12, pp. 3548–3565, 2024.
- [12] Sen Wang, Yonghui Sun, Suwei Zhai, Dongchen Hou, Peng Wang, Xiaopeng Wu, "Ultra-Short-Term Wind Power Forecasting Based on Deep Belief Network," Proceedings of the 38th Chinese Control Conference July 27-30, 2019, Guangzhou , pp. 7479–7483, 2019.
- [13] Ma Guozhen, Hu Po, Wang Yunjia, Wang Yongli, Cai Chengcong, Sun Yaling, Zhang Xinya, "Research on Ultra-Short-Term Load Forecasting of Distribution Network Based on Fuzzy Clustering and RBF Neural Network," E3S Web of Conferences 213 (ACIC 2020), 2020.
- [14] Liang Yongchun, "Application of Elman Neural Network in Short-Term Load Forecasting," International Conference on Artificial Intelligence and Computational Intelligence, 2010.



**Giới thiệu tác giả:**

Tác giả TS. Đặng Thành Trung tốt nghiệp đại học và nhận bằng Thạc sĩ tại Trường Đại học Bách khoa Hà Nội, nhận bằng Tiến sĩ tại Học viện khoa học và công nghệ, viện Hàn Lâm Khoa học và Công nghệ Việt Nam vào các năm 2006, 2008 và 2023. Hiện nay tác giả công tác tại Trường Đại học Điện lực.

Hướng nghiên cứu chính: Tính toán điều khiển tối ưu hệ thống điện, tích hợp năng lượng tái tạo vào lưới điện, dự báo công suất phát nguồn năng lượng tái tạo, công suất phụ tải, tính độ tin cậy hệ thống điện...