

## ỨNG DỤNG MÔ HÌNH N-BEATS CHO DỰ BÁO PHỤ TẢI ĐIỆN NGẮN HẠN Ở VIỆT NAM

### APPLYING N-BEATS MODEL FOR SHORT-TERM LOAD FORECASTING IN VIETNAM

**Nguyễn Anh Tuấn<sup>1</sup>, Lê Anh Ngọc<sup>2</sup>**

<sup>1</sup>Đại học Bách khoa Hà Nội, <sup>2</sup>Đại học FPT

Ngày nhận bài: 02/10/2021, Ngày chấp nhận đăng: 26/05/2022, Phản biện: PGS. TS. Nguyễn Hữu Quỳnh

#### **Tóm tắt:**

Trong ngành năng lượng nói chung, dự báo phụ tải có ý nghĩa vô cùng quan trọng vì điện năng gắn liền và ảnh hưởng trực tiếp đến đời sống sinh hoạt và các ngành kinh tế quốc dân. Hiện nay, đã có nhiều phương pháp dự báo phụ tải được đề xuất và mỗi phương pháp đều có ưu, nhược điểm khác nhau. Khác với các mô hình học sâu hiện nay, mô hình N-BEATS có ưu điểm là thời gian huấn luyện và suy luận nhanh. Mô hình cũng đạt hiệu suất cao trong các cuộc thi dự đoán chuỗi thời gian nổi tiếng trong các lĩnh vực khác nhau. Ngoài ra, mô hình có khả năng diễn giải tính xu hướng và tính mùa của dữ liệu. Bài báo trình bày phương pháp dự báo phụ tải điện ngắn hạn (cụ thể là 48 giờ) ở Việt Nam dựa trên mô hình học sâu N-BEATS. Đồng thời, bài báo phân tích kết quả và ảnh hưởng của tính xu hướng và tính mùa trong chuỗi thời gian phụ tải.

#### **Từ khóa:**

Dự báo phụ tải ngắn hạn, N-BEATS, tính xu hướng, tính mùa, chuỗi thời gian, học sâu.

#### **Abstract:**

In the energy industry in general, load forecasting is extremely important because electricity is directly affecting daily life and national economic sectors. Currently, there are many load forecasting methods, and each method has different its own advantages and disadvantages. Unlike current deep learning models, N-BEATS model has the advantages of fast training and inference time. The model also achieved high performance in famous time-series prediction competitions in different fields. In addition, the model can interpret the trend and seasonality of the data. This paper presents a short-term (specifically 48 hours) electricity load forecasting method in Viet Nam based on the N-BEATS deep learning model. The paper analyzes the results and effects of trend and seasonality in load time series.

#### **Keywords:**

Short-term electricity load forecasting, NBEATS, trend, seasonality, time series; deep learning.

### **1. GIỚI THIỆU CHUNG**

Điện năng là một sản phẩm quan trọng

trong sự phát triển kinh tế - xã hội và môi trường ở bất kì quốc gia nào trên thế giới.

Không giống như các doanh nghiệp sản xuất các sản phẩm khác với mục tiêu là lợi nhuận, điện năng là một sản phẩm đặc biệt không thể thiếu được và ngành điện được coi là một ngành cơ sở hạ tầng trong bất kỳ lĩnh vực nào. Trong giai đoạn phát triển của kinh tế - xã hội ở nước ta hiện nay, nhu cầu sử dụng điện ngày càng tăng. Một bài toán quan trọng được đặt ra đối với ngành điện lực Việt Nam là việc dự báo phụ tải điện.

Các bài toán dự báo với các khoảng thời gian khác nhau sẽ có vai trò và ứng dụng khác nhau đối với chính sách phát triển của công ty phân phối điện. Bài báo tập trung vào bài toán dự báo phụ tải ngắn hạn: Cụ thể từ 240 giờ trước để dự báo phụ tải trong 48 giờ tiếp theo.

Dự báo phụ tải điện ngắn hạn là bài toán phổ biến nhưng giải quyết lại rất khó khăn do chuỗi thời gian phụ tải điện rất phức tạp và diễn biến thất thường. Sở dĩ, phụ tải điện khó dự đoán bởi vì chúng có tính ngẫu nhiên và nhu cầu sử dụng điện của mỗi người ở mỗi vùng và mỗi khoảng thời gian thường khác nhau. Hơn nữa, phụ tải điện còn phụ thuộc vào nhiều yếu tố như thời tiết, nhiệt độ, ngày nghỉ hay các sự kiện bất thường như đại dịch Covid-19. Trước đây, các phương pháp truyền thống, phụ thuộc nhiều vào kinh nghiệm của người điều hành được sử dụng để dự báo. Ngày nay, với sự phát triển của ứng dụng trí tuệ nhân tạo, đặc biệt là các mô hình mạng nơron nhân tạo đang tạo được ưu thế lớn trong các bài toán dự báo, đặc biệt là bài toán dự báo phụ tải điện, kết quả đem lại tương đối khả quan.

Năm 2020, Oreshkin và các cộng sự đã đề xuất mô hình N-BEATS (Neural Basis Expansion Analysis for Interpretable Time Series) [1], là mô hình học sâu mới để giải quyết bài toán dự báo chuỗi thời gian đơn biến. Mô hình đã được sử dụng để dự báo trên các tập dữ liệu bao gồm nhiều lĩnh vực khác nhau trong một số cuộc thi nổi tiếng. Mô hình đã đạt được kết quả cao và đứng đầu trong hầu hết các cuộc thi trên. Trong bài báo này, tác giả nghiên cứu và áp dụng mô hình N-BEATS để dự đoán phụ tải điện ngắn hạn ở Việt Nam. Đồng thời, các kết quả về tính mùa và tính xu hướng của chuỗi kết quả cũng được khảo sát và phân tích.

## 2. TỔNG QUAN TÌNH HÌNH NGHIÊN CỨU

Bài toán dự báo phụ tải điện là một bài toán được quan tâm hàng đầu trong lĩnh vực dự báo. Hiện nay, đã có nhiều mô hình truyền thống và các mô hình học máy được đề xuất để dự báo phụ tải điện và đã đạt được những kết quả nhất định.

Trước đây các mô hình toán học truyền thống hay được áp dụng như: hồi quy tuyến tính, phương pháp tự hồi quy hay quá trình tổng quát ARIMA,... Mbamalu và các cộng sự trong nghiên cứu [2] đã đề xuất mô hình tự hồi quy (AR - Autoregressive) để dự báo phụ tải điện. Tác giả sử dụng phương pháp lặp bình phương nhỏ nhất để tìm các trọng số thích hợp cho mô hình. Khi so sánh kết quả với các thuật toán tìm trọng số khác, phương pháp đề xuất đạt kết quả tốt hơn khi giảm

đáng kể sai số tuyệt đối. Tuy nhiên, mô hình đề xuất khá đơn giản, sai số khi dự đoán vẫn cao và tăng lên khi mở rộng khoảng dự đoán. Trong [3], các tác giả đề xuất một phương pháp thích nghi trực tuyến có thể tự động điều chỉnh tham số dựa trên các điều kiện thay đổi của chuỗi thời gian. Mô hình được dự đoán phụ tải theo ngày và theo tuần trên bộ dữ liệu phụ tải tại bang Kansas, Hoa Kỳ năm 1992. Mô hình có ưu điểm là có thể tự động điều chỉnh các tham số theo các điều kiện thay đổi theo thời gian của chuỗi dự đoán. Tuy nhiên, các điều kiện thay đổi phải được cài đặt cẩn thận bởi các chuyên gia. Ngoài ra, mô hình cũng nhạy cảm với nhiễu trong chuỗi thời gian. Trong [4], các tác giả đề xuất kết hợp hai mô hình tự hồi quy để dự báo phụ tải theo giờ.

Ngày nay, với sự phát triển của trí tuệ nhân tạo, đặc biệt là các mô hình mạng nơron nhân tạo đang giành được ưu thế lớn trong các bài toán dự báo, đặc biệt là bài toán dự báo phụ tải điện. Trong [5], Yi Wang và các cộng sự đã đề xuất một phương pháp dự báo phụ tải sử dụng mạng LSTM với hàm lỗi Pinball. Các thí nghiệm được thực hiện trên tập dữ liệu phụ ở Ireland và cho kết quả vượt trội hơn so với các phương pháp truyền thống. Tuy nhiên, mô hình có thời gian chạy khá chậm nên khó có thể đưa vào ứng dụng thực tế.

N-BEATS lần đầu được đề xuất trong bài báo [1] là một mô hình học sâu được xây dựng chỉ bởi các lớp kết nối đầy đủ để giải quyết vấn đề dự báo chuỗi thời gian.

Mô hình đạt hiệu suất tốt với dữ liệu chuỗi thời gian trong nhiều lĩnh vực như công nghiệp, tài chính, nhân khẩu của các cuộc thi nổi tiếng như M3 ([6]), TOURISM ([7]) và có kết quả cao hơn so với mô hình chiến thắng trong cuộc thi M4 ([8]). Mô hình có một số ưu điểm như đào tạo nhanh, có thể diễn giải được tính xu hướng, tính mùa từ dữ liệu từ kết quả đầu ra.

### 3. MÔ HÌNH DỰ BÁO N-BEATS

#### 3.1. Dữ liệu đầu vào

Xét bài toán dự báo đơn chuỗi thời gian:

Từ chuỗi thời gian có độ dài  $t$  là  $\mathbf{x} = [\mathbf{y}_{T-t+1}, \mathbf{y}_{T-t+2}, \dots, \mathbf{y}_T] \in \mathbf{R}^T$  ta cần dự báo giá trị của  $\mathbf{H}$  bước tiếp theo là  $\mathbf{y} = [\mathbf{y}_{T+1}, \mathbf{y}_{T+2}, \dots, \mathbf{y}_{T+H}] \in \mathbf{R}^H$ . Ta kí hiệu  $\hat{\mathbf{y}}$  là dự đoán của mô hình cho vectơ  $\mathbf{y}$ . Kích thước của dữ liệu đầu vào là  $\mathbf{t} = \mathbf{nH}$  ( $\mathbf{n}$  thường nằm trong khoảng từ [2, 7]) được gọi là khoảng thời gian xem lại (lookback period). Mô hình N-BEATS sẽ học và tìm hiểu chuỗi thời gian từ khoảng thời gian xem lại để dự đoán giá trị của  $\mathbf{H}$  điểm tiếp theo.

#### 3.2. Kiến trúc tổng quát của mô hình

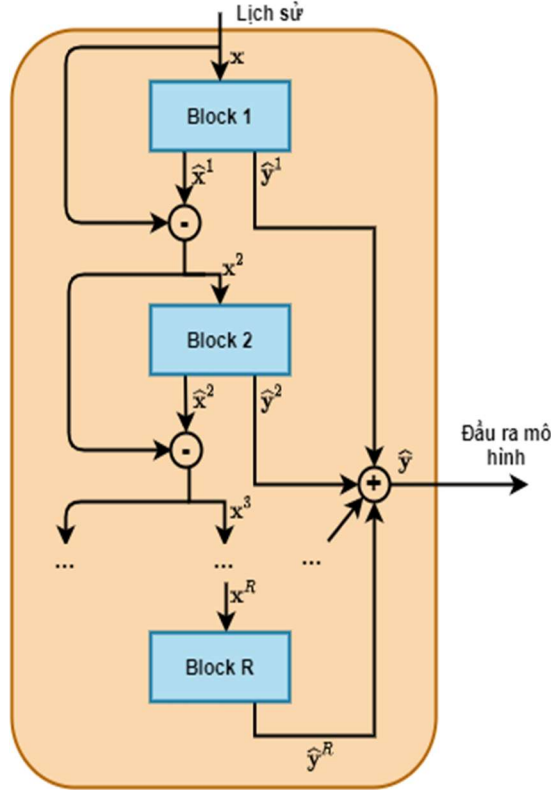
Kiến trúc tổng quát của mô hình N-BEATS được mô tả như trong hình 1. Mô hình bao gồm các block được xếp chồng lên nhau. Đầu vào của block đầu tiên là đầu vào tổng thể của mô hình hay còn gọi là khoảng thời gian xem lại  $\mathbf{x}$ . Mỗi block có hai đầu ra. Một đầu ra (backcast) sẽ được làm đầu vào cho block

tiếp theo. Đầu ra còn lại (forecast) sẽ được tổng hợp để đưa ra kết quả cuối cùng.

$$\hat{y} = \sum_{i=1}^R \hat{y}^i \quad (2)$$

Từ đây, ta thấy được đầu vào của block sẽ không chứa mà block trước đó đã dự đoán được. Điều này giúp các block sau tập trung vào những phần thông tin chưa được dự đoán.

### 3.2. Kiến trúc của block



Hình 1. Kiến trúc tổng quát của N-BEATS

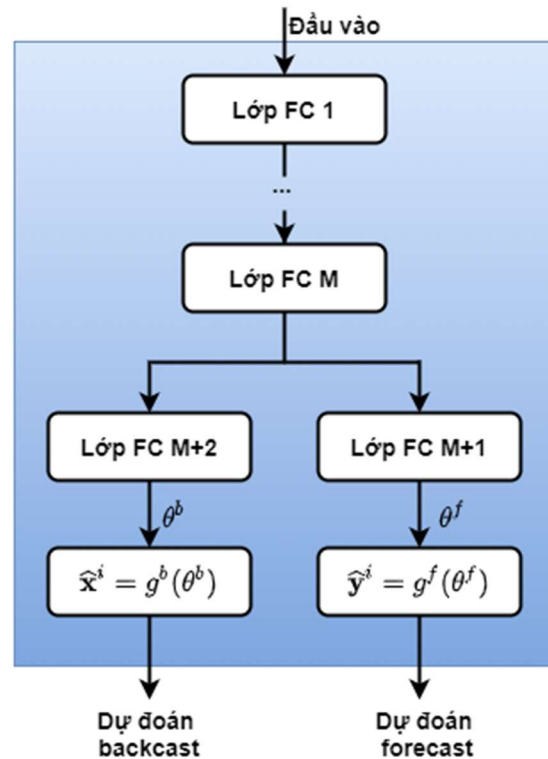
Chi tiết hơn, với block thứ  $i$  trong mô hình:

- Nếu  $i = 1$ , tức là block đầu tiên, đầu vào chính là cửa sổ dữ liệu  $x$ ;
- Nếu  $i > 1$ , đầu vào của block thứ  $i$  là:  

$$x^i = x^{i-1} - \hat{x}^{i-1} \quad (1)$$

Block thứ  $i$  gồm hai đầu ra:

- Đầu ra backcast  $\hat{x}^i$  được làm đầu vào cho block tiếp theo.
- Đầu ra forecast  $\hat{y}^i$  dùng để tổng hợp cho kết quả dự đoán cuối cùng:



Hình 2. Kiến trúc của block

Hình 2 mô tả kiến trúc trong block thứ  $i$  của mô hình. Kiến trúc của block đơn giản chỉ bao gồm các lớp kết nối đầy đủ FC (fully connected). Các lớp kết nối đầy đủ đơn giản là một lớp ánh xạ tuyến tính với hàm kích hoạt RELU. Ví dụ:

$$\mathbf{FC}(x^i) = \mathbf{RELU}(\mathbf{W}x^i + \mathbf{b}) \quad (3)$$

trong đó  $\mathbf{W}$  và  $\mathbf{b}$  lần lượt là các ma trận số

được học trong quá trình huấn luyện. Hàm RELU là hàm  $f(x) = \max(0, x)$ . Block bao gồm M lớp FC chung (M thường là 4). Sau đó, sẽ có hai lớp FC là M+1 và M+2 để chia đầu ra thành 2 nhánh. Đầu ra của hai lớp trên lần lượt là hai vectơ hệ số  $\theta^f$  và  $\theta^b$ . Cuối cùng, ta sẽ ánh xạ hai vectơ trên thành các đầu ra backcast và forecast thông qua các hàm  $g^b$  và  $g^f$ . Tùy vào dạng hàm  $g$  khác nhau mà chúng ta sẽ có các loại block với vai trò khác nhau. Cụ thể, mô hình N-BEATS giới thiệu ba loại block: trend block, seasonality block, generic block.

Generic block là kiến trúc không mang tính diễn giải được trong chuỗi thời gian. Generic block đơn giản đặt các ánh xạ  $g^b$  và  $g^f$  là các ánh xạ tuyến tính đối với đầu ra của lớp trước.

Trend block là loại block để nhận biết và phân tích được tính xu hướng của dữ liệu. Một đặc điểm của xu hướng thường phần lớn là các hàm đơn điệu hoặc thay đổi chậm. Để tìm hiểu được tính xu hướng của dữ liệu, các hàm  $g^b$  và  $g^f$  sẽ là các hàm đa thức với bậc  $p$  nhỏ theo thời gian. Khi đó, các hệ số  $\theta^f$  và  $\theta^b$  đóng vai trò là các hệ số của đa thức. Ví dụ đầu ra forecast của trend block thứ  $i$  là:

$$\hat{y}^i = \sum_{j=0}^p \theta_j^f t^j \quad (4)$$

Trong đó  $\theta_j^f$  là phần tử thứ  $j$  trong vectơ hệ số  $\theta^f$  và  $t$  là phần tử trong vectơ lưới thời gian  $t = \frac{[0,1,2,\dots,H-2,H-1]^T}{H}$

Cuối cùng, loại seasonality block dùng để nhận biết tính mùa của dữ liệu. Đặc điểm chính của tính mùa là dữ liệu thường có tính chu kỳ. Do đó, để mô phỏng tính mùa, các hàm  $g^b$  và  $g^f$  sẽ là các loại hàm tuần hoàn, ví dụ  $y_t = y_{t+\Delta}$  trong đó  $\Delta$  là chu kỳ mùa. Sử dụng chuỗi Fourier để xây dựng các hàm tuần hoàn trên, ta có đầu ra forecast của seasonality block thứ  $i$  là:

$$\hat{y}^i = \sum_{j=0}^{\lfloor \frac{H}{2}-1 \rfloor} \theta_j^f \cos(2\pi i t) + \theta_{j+\lfloor \frac{H}{2} \rfloor}^f \sin(2\pi i t) \quad (5)$$

Sau khi giới thiệu ba loại block trên, mô hình N-BEATS được xây dựng dựa trên số lượng và thứ tự của mỗi loại block.

#### 4. THÍ NGHIỆM VÀ KẾT QUẢ

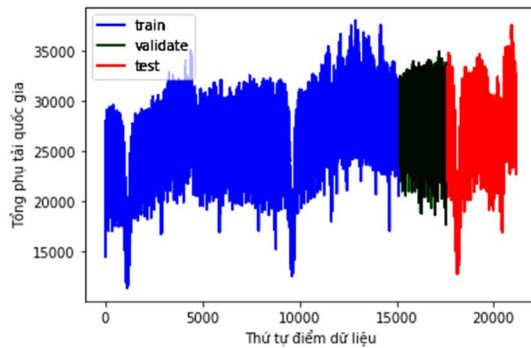
Trong phần này, bài báo trình bày về phương pháp xây dựng thí nghiệm, mô hình đề xuất và kết quả của thí nghiệm. Mục tiêu của bài toán là từ giá trị quan sát 240 giờ trước để dự đoán giá trị phụ tải tại 48 giờ tiếp theo.

##### 4.1. Dữ liệu và tiền xử lý

Bộ dữ liệu bao gồm thông tin phụ tải theo giờ tại Việt Nam từ ngày 01/01/2018 đến ngày 01/06/2020 gồm 21169 điểm dữ liệu (độ phân giải 1 giờ). Để huấn luyện và kiểm thử mô hình, ta cần chia dữ liệu thành ba bộ: dữ liệu huấn luyện (train dataset), dữ liệu kiểm định (validation dataset) và dữ liệu kiểm tra (test dataset). Bảng 1 và hình 3 mô tả thông tin chia ba bộ dữ liệu cho quá trình huấn luyện và kiểm tra:


**Bảng 1. Thông tin ba tập dữ liệu**

| Tập dữ liệu | Bắt đầu    | Kết thúc   | Số điểm dữ liệu |
|-------------|------------|------------|-----------------|
| Huấn luyện  | 01/01/2018 | 24/09/2019 | 15169           |
| Kiểm định   | 25/09/2019 | 02/01/2020 | 2400            |
| Kiểm thử    | 03/01/2020 | 01/06/2020 | 3600            |



**Hình 3. Dữ liệu phụ tải**

Vì mục tiêu của ta là từ quan sát của  $T = 240$  giờ để dự đoán giá trị phụ tải tại  $H = 48$  giờ tiếp theo, ta cần tạo dữ liệu để phù hợp với đầu vào của mô hình. Hình 4 mô tả cách tạo dữ liệu đầu vào và đầu ra để huấn luyện và kiểm thử mô hình.



**Hình 4. Sử dụng của sổ trượt để tạo dữ liệu**

Cụ thể, ta sẽ sử dụng một cửa sổ trượt với kích thước là  $T + H = 288$  để trượt lần lượt với bước trượt là 1 trên tập dữ liệu. Mỗi lần trượt ta thu được một bản ghi dữ liệu. Với mỗi bản ghi thu được từ cửa sổ

trượt, đầu vào  $X$  của mô hình tương ứng  $T = 240$  giờ đầu tiên trên cửa sổ trong khi đầu ra  $Y$  là giá trị phụ tải tại  $H = 48$  giờ tiếp theo trên cửa sổ trượt. Ví dụ cửa sổ trượt đầu tiên trong tập huấn luyện sẽ thu được là:

$X_0 = [y_1, y_2, \dots, y_{240}]$  trong đó  $y_t$  là giá trị phụ tải cần dự đoán tại giờ thứ  $t$ . Giá trị đầu ra tương ứng thu được từ cửa sổ trượt trên là  $Y_0 = [y_{241}, y_{242}, \dots, y_{288}]$ . Tương tự, cửa sổ trượt thứ hai thu được:

$X_1 = [y_2, y_3, \dots, y_{241}]$  và  $Y_1 = [y_{242}, y_{243}, \dots, y_{289}]$ . Từ cách tạo dữ liệu trên, với các tập huấn luyện, tập kiểm định, tập kiểm tra, số lượng cặp quan sát - dự đoán  $(X, Y)$  lần lượt là 14882, 2113, 3313 cặp.

#### 4.2. Các metric đánh giá

Để đánh giá hiệu suất của dự báo, ta sử dụng hai tiêu chí đánh giá là Mean Absolute Percentage Error (MAPE) và Root Mean Square Error (RMSE).

Tiêu chí thứ nhất, MAPE là một thước đo thống kê về mức độ chính xác của hệ thống dự báo. Công thức tính sai số MAPE:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y_{real}(t) - y_{forecast}(t)|}{y_{real}(t)}$$

Tiêu chí thứ hai, RMSE là độ lệch chuẩn của các sai số dự đoán (phần dư). RMSE là thước đo mức độ phân tán của những phần dư này. Công thức tính sai số RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_{real}(t) - y_{forecast}(t))^2}$$

#### 4.2. Các kịch bản

Để có thể áp dụng thực tế mô hình N-BEATS cho dự báo phụ tải điện, tác giả đề xuất một mô hình N-BEATS có cấu trúc nhỏ hơn so với bài báo gốc. Mô hình chỉ gồm 3 trend block, 3 seasonality block và 1 generic block. Để chứng minh hiệu quả của mô hình đề xuất, trong bài báo này tác giả xây dựng các kịch bản thử nghiệm:

- **Kịch bản 1:** Mô hình N-BEATS đơn giản được cấu tạo bởi lần lượt 1 trend block, 1 seasonality block và 1 generic block.
- **Kịch bản 2:** Mô hình N-BEATS gồm các block theo thứ tự: 3 seasonality block, 3 trend block và một generic block.
- **Kịch bản 3:** Mô hình LSTM + hàm lỗi Pinball trong bài báo [5]
- **Kịch bản 4: Mô hình đề xuất.** Mô hình N-BEATS bao gồm các block theo thứ tự: 3 trend block để dự đoán tính xu hướng, 3 seasonality để dự đoán tính mùa và cuối cùng là 1 generic block.

#### 4.3. Kết quả thí nghiệm

Các kịch bản trên đều được huấn luyện sử dụng phương pháp tối ưu Adam, tốc độ học khởi tạo là 0.004, hàm mất mát là hàm MSE và được huấn luyện trong 100 epoch, kích thước batch size là 512. Bộ tham số tối ưu của mô hình trong mỗi

kịch bản được chọn thông qua hàm mất mát trên tập kiểm định đạt giá trị tối ưu nhất. Kết quả RMSE, MAPE và thời gian suy luận trên một bản ghi thu được như trong bảng 2.

**Bảng 2. Kết quả thí nghiệm**


| Kịch bản          | RMSE           | MAPE         | Thời gian (ms) |
|-------------------|----------------|--------------|----------------|
| Kịch bản 1        | 1733.08        | 4.48%        | <b>0.22</b>    |
| Kịch bản 2        | 1657.35        | 4.10%        | 0.44           |
| Kịch bản 3        | 1701.28        | 4.20%        | 115            |
| <b>Kịch bản 4</b> | <b>1599.35</b> | <b>3.83%</b> | 0.45           |

Từ bảng trên, ta có một số nhận xét sau: Mô hình trong kịch bản 1 có thời gian suy luận trên một bản ghi là nhanh nhất. Tuy nhiên kịch bản 1 có độ chính xác kém nhất do mô hình còn quá đơn giản (chỉ gồm 1 trend block, 1 seasonality block, 1 generic block) nên không thể dự đoán được tốt dữ liệu. Mô hình đề xuất trong kịch bản 4 đạt kết quả tốt nhất so với 3 kịch bản trên. Mô hình trong kịch bản 2 có số lượng các loại tương đương với mô hình đề xuất trong kịch bản 3 nhưng độ chính xác lại không bằng khi thay đổi thứ tự các block. Từ đây, ta thấy rằng thứ tự các block cũng ảnh hưởng đến hiệu suất của mô hình. Ngoài ra ta thấy rằng mô hình 4 đạt kết quả tốt hơn so với mô hình LSTM trong kịch bản 3. Các mô hình N-BEATS đều chạy nhanh hơn nhiều lần so với mô hình LSTM (115 ms). Một điều lưu ý nữa là các mô hình trên đều chạy trên cấu hình máy tính với Intel(R) Core(TM) i5-7400 CPU @ 3.00 GHz là

cấu hình không quá mạnh. Do đó, ứng dụng các mô hình đề xuất vào thực tế là hoàn toàn khả thi.

Hình 5 là một ví dụ về tính diễn giải xu hướng và tính mùa từ dữ liệu với mô hình đề xuất trong kịch bản 3. Trục hoành chỉ thời gian trong đó giá trị từ -248 đến -1 là

giá trị quan sát và giá trị từ 0 đến 47 là giá trị phụ tải phải dự đoán. Trục tung là giá trị phụ tải (đã lấy logarit cơ số tự nhiên với giá trị phụ tải thực). Đường màu lá cây trong hình bên dưới chỉ xu hướng của biến phụ tải tiếp theo và đường màu đỏ thể hiện quy luật mùa của biến phụ tải.



Hình 5. Ví dụ về tính diễn giải của mô hình đề xuất

Trong khi đó, đường màu cam và đường màu xanh lam ở hình trái trong hình 5 lần lượt là giá trị dự đoán và giá trị thực tế. Từ kết quả trên, ta thấy rằng xu hướng dữ liệu phụ tải của bản ghi trên là sẽ giảm trong thời 48 giờ tiếp theo (theo hình giữa). Ngoài ra ta cũng thấy được yếu tố mùa và chu kì của bản ghi cũng được thể hiện rõ (theo hình phải). Trong bản ghi trên, ta thấy giá trị phụ tải sẽ đạt điểm cực đại sau khoảng 24 giờ.

Hướng nghiên cứu tiếp theo là nghiên cứu sự ảnh hưởng và tối ưu thứ tự các block trong mô hình. Ngoài ra, một số hướng nghiên cứu khác như thêm biến ngoại lai để cải thiện hiệu suất của mô hình cũng được xem xét.

## 5. KẾT LUẬN

Bài báo đã trình bày phương pháp đề xuất dự trên mô hình học sâu N-BEATS để dự đoán phụ tải điện Việt Nam. Mô hình có một số ưu điểm như khả năng tính toán nhanh, có thể diễn giải được tính xu hướng, tính mùa từ dữ liệu. Điều này đã được thể hiện thông qua quá trình thực nghiệm.



## TÀI LIỆU THAM KHẢO

- [1] Boris N. Oreshkin et al. "N-BEATS: neural basis expansion analysis for interpretable time series forecasting", 8th International Conference on Learning Representations, ICLR(2020).
- [2] G.A.N. Mbamalu. "Load Forecasting Via Suboptimal Seasonal Autoregressive Models And Iteratively Reweighted Least Squares Estimation", IEEE Transaction on Power System 8 (1992), pp. 343–348.
- [3] L.D. Paarmann and M.D. Naja. "Adaptive Online Load Forecasting via Time Series Modeling", Electric Power Systems Research 32 (1995), pp. 219–225.
- [4] S.R. Huang. "Short-Term Load Forecasting Using Threshold Autoregressive Models", IEEE Generation, Transaction and Distribution 144 (1997), pp. 477–481.
- [5] Yi Wang and Chongqing Kang. "Probabilistic individual load forecasting using pinball loss guided LSTM", Applied Energy 235 (2019), pp. 10–20.
- [6] S. Makridakis, E. Spilioti, and V. Assimakopoulos. "Statistical and machine learning forecasting methods: Concerns and ways forward.", PLoS One, 13(3)(2018).
- [7] G. Athanasopoulos et al. "The tourism forecasting competition", International Journal of Forecasting 27 (2011), pp. 882–844.
- [8] S. Makridakis, E. Spilioti, and V. Assimakopoulos. "The M4 competition: 100,000 time series and 61 forecasting methods", International Journal of Forecasting, 36 (2020), pp. 54–74

### Giới thiệu tác giả:



Tác giả Lê Anh Ngọc tốt nghiệp đại học ngành toán và tin học tại Trường Đại học Vinh và Trường Đại học Khoa học tự nhiên – Đại học Quốc gia Hà Nội các năm 1996 và 1998. Nhận bằng Thạc sĩ Công nghệ thông tin tại Trường Đại học Bách Khoa Hà Nội năm 2001; nhận bằng Tiến sĩ tại Đại học Quốc gia Kyungpook – Hàn Quốc, chuyên ngành kỹ thuật thông tin và truyền thông năm 2009. Hiện nay tác giả là giảng viên và Giám đốc Swinburne Innovation Space tại Swinburne Việt Nam.

Hướng nghiên cứu chính: Hệ thống thời gian thực, mạng truyền thông, Internet of Things, các hệ thống thông minh và IoT.



Tác giả Nguyễn Anh Tuấn tốt nghiệp đại học ngành toán ứng dụng và tin học tại Trường Đại học Bách khoa Hà Nội năm 2021. Hiện nay tác giả đang là nghiên cứu sinh tại Đại học Quốc gia Jeju, Hàn Quốc.

Hướng nghiên cứu chính: Tính toán thông minh và trí tuệ nhân tạo.