

HỌC VIỆN CÔNG NGHỆ BƯU CHÍNH VIỄN THÔNG



NGUYỄN THANH NHÂN

**ỨNG DỤNG CHUỖI THỜI GIAN TRONG DỰ BÁO
NHU CẦU PHỤ TẢI ĐIỆN Ở CÔNG TY
ĐIỆN LỰC TÂY NINH**

TÓM TẮT LUẬN VĂN THẠC SĨ

TP. HỒ CHÍ MINH – NĂM 2022

Luận văn được hoàn thành tại:

HỌC VIỆN CÔNG NGHỆ BƯU CHÍNH VIỄN THÔNG

Người hướng dẫn khoa học: TS. Huỳnh Trọng Thừa

Phản biện 1:

Phản biện 2:

Luận văn sẽ được bảo vệ trước Hội đồng chấm luận văn thạc sĩ
tại Học viện Công nghệ Bưu chính Viễn thông.

Vào lúc: giờ ngày tháng năm

Có thể tìm hiểu luận văn tại:

- Thư viện của Học viện Công nghệ Bưu chính Viễn thông.

I. MỞ ĐẦU

1. Lý do chọn đề tài

Dự báo nhu cầu phụ tải điện là một hoạt động có vai trò quan trọng trong việc quy hoạch, vận hành hệ thống điện. Công ty Điện lực Tây Ninh là một đơn vị phân phối điện bên cạnh nhu cầu dự báo ngắn hạn phục vụ lập phương thức vận hành (điều độ hệ thống điện) thì nhu cầu dự báo phụ tải điện trung hạn nhằm nhằm nâng cao hiệu quả hoạt động, độ tin cậy và đảm bảo cân đối cung cầu phụ tải điện cũng hết sức cần thiết.

Thực hiện chỉ đạo của Tập đoàn Điện lực Việt Nam và triển khai thực hiện Thông tư 19 của Bộ công thương, các Công ty Điện lực phải thực hiện dự báo phụ tải của các nhóm khách hàng, thành phần phụ tải trong hoạt động điều hành, vận hành hệ thống điện hằng tháng. Tuy nhiên việc triển khai thực hiện gặp nhiều khó khăn do chưa có phương pháp dự báo phụ tải phù hợp với nguồn dữ liệu hiện hữu. Hiện nay, chủ yếu các Công ty Điện lực dự báo nhu cầu phụ tải dựa theo phương pháp chuyên gia hoặc mô hình hàm hồi quy đa biến phụ thuộc vào các yếu tố như thời tiết, nhiệt độ, chỉ số kinh tế, ... cho nên kết quả dự báo còn hạn chế.

Nhằm giải quyết các vấn đề trên, luận văn đề xuất phương pháp nghiên cứu dự báo chuỗi thời gian để dự báo nhu cầu phụ tải điện trung hạn (xu thế, tốc độ phát triển và nhu cầu

của phụ tải điện). Từ những lý do trên, tôi xin lựa chọn đề tài nghiên cứu “**Ứng dụng chuỗi thời gian trong dự báo nhu cầu phụ tải điện ở Công ty Điện lực Tây Ninh**”.

2. Mục tiêu nghiên cứu

2.1. Mục đích nghiên cứu

Xây dựng hệ thống dự báo nhu cầu phụ tải điện trung hạn nhằm hỗ trợ ban Lãnh đạo Công ty Điện lực Tây Ninh trong hoạt động điều hành, vận hành hệ thống điện đảm bảo mục tiêu nâng cao hiệu quả, độ tin cậy cung cấp điện và đảm bảo cân đối cung cầu phụ tải điện phục vụ nhu cầu sử dụng điện của khách hàng.

2.2. Mục tiêu tổng quát

Đánh giá thực trạng nhu cầu dự báo phụ tải ở Công ty Điện lực Tây Ninh và nghiên cứu phương pháp dự báo chuỗi thời gian trong dự báo nhu cầu phụ tải điện trung hạn, từ đó đề xuất giải pháp dự báo nhu cầu phụ tải điện trung hạn ở Công ty Điện lực Tây Ninh.

2.3. Mục tiêu cụ thể

- Nghiên cứu các phương pháp dự báo chuỗi thời gian trong dự báo nhu cầu phụ tải điện trung hạn.

- Đánh giá thực trạng dự báo nhu cầu phụ tải điện trung hạn ở Công ty Điện lực Tây Ninh.

- Đề xuất giải pháp dự báo nhu cầu phụ tải điện trung hạn dựa trên phân tích chuỗi thời gian Facebook Prophet ở Công ty Điện lực Tây Ninh.

- Xây dựng hệ thống thực nghiệm và đánh giá hệ thống dự báo nhu cầu phụ tải điện trung hạn ở Công ty Điện lực Tây Ninh.

3. Đối tượng và phạm vi nghiên cứu

3.1. Đối tượng nghiên cứu:

- Thực trạng nhu cầu dự báo phụ tải điện trung hạn ở Công ty Điện lực Tây Ninh.

- Các phương pháp dự báo nhu cầu phụ tải điện trung hạn và phương pháp dự báo đề xuất là dự báo chuỗi thời gian theo mô hình cộng Facebook Prophet.

- Giải pháp hợp lý dự báo nhu cầu phụ tải điện trung hạn ở Công ty Điện lực Tây Ninh.

3.2. Phạm vi nghiên cứu:

Về nội dung: Nhu cầu dự báo phụ tải điện trung hạn và giải pháp đề xuất nhằm dự báo nhu cầu phụ tải trung hạn ở Công ty Điện lực Tây Ninh.

Về thời gian: Các tài liệu nghiên cứu được sử dụng trong luận văn là các tài liệu trong và ngoài nước trong khoảng thời gian từ năm 2010-2020. Dữ liệu nghiên cứu là sản lượng điện tiêu thụ của các nhóm khách hàng, thành phần phụ tải, địa bàn

quản lý hằng tháng từ tháng 01/2009 đến tháng 07/2021 ở Công ty Điện lực Tây Ninh.

Về không gian: Nghiên cứu được thực hiện và ứng dụng ở Công ty Điện lực Tây Ninh.

4. Phương pháp nghiên cứu

Đề tài này sử dụng phương pháp nghiên cứu lý thuyết kết hợp với xây dựng ứng dụng thực nghiệm:

- Nghiên cứu lý thuyết dự báo phụ tải điện dài hạn, các thành phần phụ tải điện và các yếu tố ảnh hưởng đến dự báo.

- Thu thập dữ liệu nhu cầu phụ tải điện của các nhóm thành phần phụ tải điện, theo khu vực và nhóm khách hàng: Sản lượng điện tiêu thụ hàng tháng của các nhóm khách hàng trên địa bàn tỉnh Tây Ninh do Công ty Điện lực Tây Ninh quản lý.

- Xây dựng hệ thống thực nghiệm, đánh giá kết quả thực nghiệm, đưa ra hướng phát triển mở rộng của đề tài để đáp ứng những nhu cầu triển khai thực tế.

5. Cấu trúc luận văn

Ngoài phần mở đầu, mục lục, kết luận và kiến nghị, danh mục hình vẽ, danh mục bảng biểu, tài liệu tham khảo, phụ lục, phần nội dung chính của luận văn gồm 5 chương được trình bày trong 57 trang.

II. NỘI DUNG

CHƯƠNG 1: TỔNG QUAN VỀ DỰ BÁO

CHUỖI THỜI GIAN

1.1. Tổng quan về dự báo

1.2. Các phương pháp dự báo

Các phương pháp dự báo ban đầu hầu như hoàn toàn dựa theo phương pháp thống kê truyền thống nhưng với sự tiến bộ của khoa học hiện đại, các công nghệ dự báo đã phát triển đáng kể. Gần đây, các phương pháp dự báo dựa trên lý thuyết học máy là ngày càng trở nên phổ biến hơn trong dự báo.

1.2.1. Các mô hình thống kê:

- Mô hình Tự hồi quy tích hợp trung bình trượt (ARIMA).
- Mô hình phân rã.

1.2.2. Các mô hình hiện đại dựa trên máy học, khai


phá dữ liệu và trí tuệ nhân tạo:

- Mạng nơ-ron nhân tạo (ANN), học sâu LSTM.
- Máy véc-tơ hỗ trợ (SVM)

CHƯƠNG 2: MÔ HÌNH DỰ BÁO CHUỖI THỜI GIAN VÀ ỨNG DỤNG TRONG DỰ BÁO NHU CẦU PHỤ TẢI ĐIỆN

2.1. Phân tích chuỗi thời gian nhu cầu phụ tải điện

Dữ liệu chuỗi thời gian là một chuỗi các quan sát của một quá trình ngẫu nhiên được lưu trữ theo thứ tự thời gian. Dữ liệu sản lượng điện thương phẩm hàng tháng của người dân hay các cơ quan tổ chức là dữ liệu chuỗi thời gian. Hình 2-1 là biểu đồ minh họa chuỗi thời gian sản lượng điện thương phẩm hàng tháng của một doanh nghiệp có tổng sản lượng tiêu thụ hàng năm trên 1 triệu kWh và tổng hợp của các khách hàng có mức tiêu thụ hàng tháng dưới 1 triệu kWh trên địa bàn Thành phố Tây Ninh.



Hình 2.1: Biểu đồ sản lượng điện thương phẩm hàng tháng của một doanh nghiệp có mức tiêu thụ hàng năm trên 1 triệu kWh

2.2. Mô hình ARIMA

Mô hình trung bình trượt tích hợp tự hồi quy (Autoregressive Integrated Moving Average - ARIMA) là một phương pháp rất phổ biến trong việc lập mô hình chuỗi thời gian, thường được gọi là phương pháp Box-Jenkins (1976). Mô hình ARIMA phân tích tính tự tương quan trong dữ liệu quan sát để đưa ra mô hình dự báo. Mô hình ARIMA được kết hợp bởi 3 thành phần chính: AR (Autoregressive - thành phần tự hồi quy), MA (Moving Average - thành phần trung bình trượt) và I (Integrated – thành phần tích hợp, thực hiện quá trình sai phân để tạo chuỗi dừng).

Các bước xây dựng mô hình ARIMA để dự báo chuỗi thời gian:

- Nhận dạng mô hình
- Ước lượng tham số và lựa chọn mô hình
- Kiểm định mô hình
- Dự báo

2.3. Mô hình SARIMA

Mô hình trung bình trượt tích hợp tự hồi quy theo mùa (SARIMA hoặc ARIMA theo mùa), là một mô hình mở rộng của ARIMA hỗ trợ dữ liệu chuỗi thời gian đơn biến với thành phần theo mùa. SARIMA bổ sung thêm ba tham số mới là thành phần tự hồi quy (AR), tích hợp (I) và trung bình động (MA) cho thành

phần theo mùa của chuỗi thời gian đơn biến, cũng như một tham số xác định khoảng thời gian theo mùa. Việc xác định bộ tham số của mô hình SARIMA yêu cầu chọn các tham số cho cả các yếu tố xu hướng và theo mùa của chuỗi.

Ba tham số xu hướng giống như mô hình ARIMA:

- p : Bậc tự hồi quy xu hướng.
- d : Bậc tích hợp xu hướng
- q : Bậc trung bình động xu hướng.

Bốn tham số theo mùa không phải là một phần của ARIMA phải được xác định:


- P : Bậc tự hồi quy theo mùa.
- D : Bậc tích hợp theo mùa.
- Q : Bậc trung bình động theo mùa.
- m : Số bước thời gian (kỳ) trong một mùa.

2.4. Mô hình mạng LSTM

Mạng LSTM (Long Short Term Memory) là một biến thể của mạng nơ-ron hồi quy (Recurrent Neural Network - RNN) được thiết kế để giải quyết các bài toán về phụ thuộc xa trong RNN do bị ảnh hưởng của vấn đề triệt tiêu gradient (gradient vanishing). LSTM lần đầu tiên được đề xuất bởi Hochreiter và Schmidhuber và được cải tiến bởi nhiều nhà nghiên cứu khác.

Hình 2-4 biểu diễn cấu trúc của một mạng LSTM gồm nhiều tế bào liên kết với nhau thành một chuỗi. Mỗi tế bào LSTM

có 4 tầng (tương ứng với 4 hàm kích hoạt sigmoid, tanh) tương tác với nhau để tạo ra trạng thái tế bào (cell state). Hình 2-6 là cấu trúc bên trong của một tế bào LSTM.




Hình 2.4: Một mạng LSTM và cấu trúc bên trong của tế bào LSTM

Mỗi tế bào có thể ghi nhớ hoặc quên thông tin cần thiết thông qua cơ chế sàng lọc thông tin của các cổng (gate). Một tế bào LSTM có 3 cổng như vậy để duy trì và điều hành trạng thái của tế bào:

- *Cổng quên (forget gate)*: Có nhiệm vụ loại bỏ những thông tin không cần thiết nhận được khỏi trạng thái bên trong tế bào.
- *Cổng vào (input gate)*: Có nhiệm vụ chọn lọc những thông tin cần thiết nào được thêm vào trạng thái bên trong tế bào.

- *Cổng ra (output gate)*: Có nhiệm vụ xác định những thông tin nào từ trạng thái bên trong tế bào được sử dụng như đầu ra.



Hình 2.5: Cấu trúc của một tế bào LSTM

2.5. Mô hình Prophet

Prophet là một mô hình dự báo dữ liệu chuỗi thời gian dựa trên mô hình cộng (Additive model) trong đó các xu hướng phi tuyến tính phù hợp với thời vụ hàng năm, hàng tuần và hàng ngày, cộng với các ảnh hưởng ngày lễ. Cơ sở của mô hình Prophet là phân rã chuỗi thời gian thành 4 thành phần đại diện cho xu hướng, tính chu kỳ, ảnh hưởng của ngày lễ và sai số mô hình theo phương trình:

$$y(t) = g(t) + s(t) + h(t) + \epsilon t \quad (2.8)$$

Trong đó:

- $g(t)$ là hàm đại diện cho xu hướng, sự thay đổi không có tính chu kỳ của chuỗi thời gian.

- $s(t)$ là hàm đại diện cho sự thay đổi có tính chu kỳ của chuỗi thời gian (ví dụ: hàng tuần, hàng tháng, hàng năm)
- $h(t)$ là hàm đại diện cho sự ảnh hưởng của ngày nghỉ (do người dùng cung cấp) xảy ra theo lịch một hoặc vài ngày.
- εt là sai số mang tính ngẫu nhiên không xác định được của mô hình.

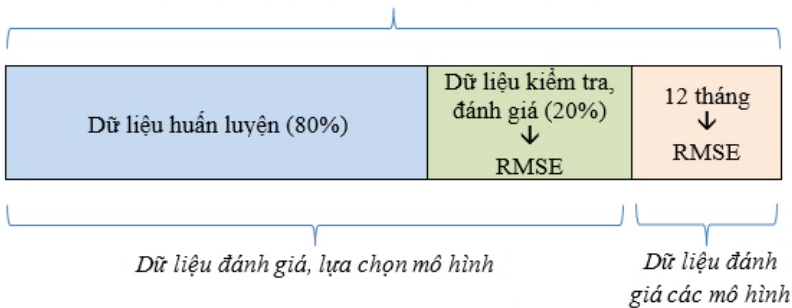
CHƯƠNG 3: XÂY DỰNG MÔ HÌNH DỰ BÁO NHU CẦU PHỤ TẢI ĐIỆN

3.1. Xây dựng mô hình dự báo

Để xây dựng mô hình, chiến lược kiểm tra dự báo góđ đầu, hay còn gọi là chiến lược kiểm tra góđ đầu (walk forward validation) để kiểm tra, đánh giá mô hình dự báo cũng như đánh giá hiệu suất giữa các mô hình.

Trước tiên, toàn bộ dữ liệu đầu vào sản lượng điện thương phẩm (chuỗi dữ liệu thời gian nhu cầu phụ tải điện) được phân chia thành 2 phần, phần dữ liệu đầu là đánh giá, lựa chọn mô hình được phân chia thành dữ liệu huấn luyện và kiểm tra theo tỷ lệ 80% dữ liệu huấn luyện và 20% dữ liệu kiểm tra, đánh giá mô hình thử nghiệm; phần dữ liệu đánh giá các mô hình (12 tháng cuối dùng) dùng đánh giá hiệu suất giữa các mô hình dự báo SARIMA, mạng LSTM và Prophet.

Dữ liệu chuỗi thời gian sản lượng điện thương phẩm



Kế tiếp, chiến lược kiểm tra góid đầu được áp dụng trên các dữ liệu kiểm tra, đánh giá. Chiến lược kiểm tra góid đầu được áp dụng tương tự trên dữ liệu 12 tháng cuối cùng (dữ liệu đánh giá các mô hình) để đánh giá hiệu suất giữa các mô hình dự báo thử nghiệm.

Mã giả chiến lược kiểm tra góid đầu (walk forward validation)

Lấy tất cả dữ liệu đầu vào X_i ($i = 1, 2, 3, \dots, N$)

Phân chia dữ liệu huấn luyện/kiểm tra theo tỷ lệ 70/30, $T = \text{INT}(N * 0.7)$

Train = $[X_i]$ ($i = 1, 2, \dots, T$)

Test = $[X_i]$ ($i = T + 1, \dots, N$)

Forecast = []

Lặp $j = 1$ to $(N - T)$:

Huấn luyện mô hình trên dữ liệu Train

Dự báo 1 kỳ kế tiếp

Ghi nhận kết quả dự báo vào Forecast

Thêm Test[j] vào Train

Tính hiệu suất mô hình theo RMSE (Test, Forecast)

Hình 3.2: Mã giả thuật toán đánh giá mô hình theo chiến lược kiểm tra góid đầu được áp dụng trong lựa chọn mô hình và đánh giá hiệu suất các mô hình.

Các mô hình dự báo SARIMA, mạng LSTM và Prophet được xây dựng với vài tham số. Chi tiết việc đánh giá lựa chọn các tham số từng mô hình SARIMA, mạng LSTM và Prophet được nêu rõ trong các phần sau của chương này.

Độ đo RMSE được áp dụng trong đánh giá lựa chọn các tham số mô hình và trong đánh giá hiệu suất giữa các mô hình thử nghiệm SARIMA, mạng LSTM và Prophet:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (3.1)$$

3.2. Xây dựng mô hình dự báo SARIMA

Một cách tiếp cận thay thế cách tiếp cận Box-Jenkins là tìm kiếm theo lưới (grid search) với một bộ các tham số mô hình và khám phá bộ tham số nào hoạt động tốt nhất cho một chuỗi thời gian đơn biến cụ thể. Với hệ thống máy tính hiện đại ngày, tốc độ xử lý nhanh hơn, cách tiếp cận này có thể khả thi và thực hiện tìm kiếm nhanh hơn.

Mã giả thuật toán tìm kiếm lưới bộ tham số SARIMA

Train = 80% dữ liệu đầu của chuỗi

Test = 20% dữ liệu cuối của chuỗi, dùng đánh giá mô hình

Scores = []

Configs = Tạo tổ hợp các bộ tham số (p,d,q)(P,D,Q)m

For cfg in Configs:

RMSE = WalkforwardValidate(cfg, Train, Test)

Scores.Append([RMSE, cfg])

Sắp xếp Scores với RMSE tăng dần

Return Scores[0]

Hình 3.3: Mã giả thuật toán tìm kiếm lưới khám phá bộ tham số SARIMA cho một chuỗi thời gian đơn biến

Phương pháp tìm kiếm lưới thực chất là vét cạn tổ hợp các 7 tham số $(p,d,q)(P,D,Q)m$ của mô hình SARIMA. Do đó, tốc độ tìm kiếm là một điểm yếu của phương pháp nhưng ưu điểm là không đòi hỏi kỹ năng phân tích.

3.3. Xây dựng mô hình dự báo LSTM

Thư viện Keras được sử dụng để xây dựng mô hình dự báo chuỗi thời gian bằng mạng LSTM. Đoạn mã Python sau đây là mô hình LSTM được xây dựng để dự báo nhu cầu điện thương phẩm trong luận văn. Mô hình sử dụng 1 tầng ẩn LSTM với số lượng tế bào là neurons. Trong đó, các tham số neurons, epochs là các tham số cần phải được xác định.

Mã Python xây dựng mô hình LSTM

```

model = Sequential()

model.add(LSTM(neurons,
               activation='tanh',
               batch_input_shape=(1, 1, 1),
               stateful=True))

model.add(Dense(1))

model.compile(loss='mean_squared_error',
              optimizer='adam')

for i in range(epochs):

    model.fit(X, y, epochs=1, batch_size=1,
             shuffle=False)

    model.reset_states()

```

Hình 3.4: Đoạn mã Python xây dựng mô hình LSTM

3.4. Xây dựng mô hình dự báo Prophet

Thư việc fbprophet được sử dụng để xây dựng mô hình dự báo.

Đoạn mã Python xây dựng mô hình dự báo

```
model = Prophet(
    seasonality_mode = 'multiplicative',
    seasonality_prior_scale = 0.05)

model.fit(data)
```

Hình 3.6: Đoạn mã Python mô hình dự báo Prophet

Prophet có rất ít tham số có thể tinh chỉnh để nâng cao hiệu suất của mô hình, các tham số hầu hết được Prophet xác định tự động. Tuy nhiên, Prophet vẫn cung cấp một vài tham số để hiệu chỉnh mô hình phù hợp với dữ liệu, trong đó có 2 tham số liên quan đến tính chu kỳ theo mùa của dữ liệu chuỗi thời gian đó là:

- *seasonality mode*: có 2 giá trị là additive, multiplicative tương ứng với sự thay đổi của thành phần theo mùa $s(t)$ là tuyến tính hay phi tuyến theo thời gian.
- *seasonality prior scale*: giá trị chỉ mức độ ảnh hưởng thành phần theo mùa $s(t)$ của mô hình. Thông thường có giá trị trong đoạn $[0.01, 10]$

CHƯƠNG 4: KẾT QUẢ DỰ BÁO NHU CẦU PHỤ TẢI ĐIỆN Ở CÔNG TY ĐIỆN LỰC TÂY NINH

4.1. Kết quả dự báo

4.1.1. Dự báo nhu cầu phụ tải 1 tháng

4.1.1.1. Mô hình Prophet

Đánh giá kết quả dự báo nhu cầu phụ tải điện từng tháng của mô hình Prophet trên dữ liệu 9 Điện lực từng tháng từ tháng 8/2020 đến tháng 7/2021:

Bảng 4.1: Giá trị RMSE giữa dữ liệu đánh giá và dự báo của 09 Điện lực khi triển khai dự báo theo mô hình Prophet

Điện lực	RMSE	MAPE
TPTN	872,883	4.3%
GODAU	495,233	2.8%
TRANGBANG	826,265	4.6%
TANCHAU	929,143	6.0%
CHAUTHANH	734,048	3.9%
DUONGMINHCHAU	516,715	3.9%
TANBIEN	408,598	3.9%
HOATHANH	592,019	3.8%
BENCAU	448,668	3.4%

4.1.1.2. Mô hình SARIMA

Đánh giá kết quả dự báo nhu cầu phụ tải điện từng tháng của mô hình SARIMA trên dữ liệu 9 Điện lực từng tháng từ tháng 8/2020 đến tháng 7/2021:

Bảng 4.3: Độ đo RMSE giữa dữ liệu đánh giá và dự báo của 09 Điện lực khi triển khai mô hình SARIMA

Điện lực	RMSE	MAPE
TPTN	1,003,489	4.3%
GODAU	573,863	3.4%
TRANGBANG	698,122	3.4%
TANCHAU	722,059	4.1%
CHAUTHANH	679,315	4.0%
DUONGMINHCHAU	678,385	4.7%
TANBIEN	471,773	4.5%
HOATHANH	633,737	3.8%
BENCAU	541,012	4.9%

4.1.1.4. Mô hình LSTM

Đánh giá kết quả dự báo nhu cầu phụ tải điện từng tháng của mô hình LSTM trên dữ liệu 9 Điện lực từng tháng từ tháng 8/2020 đến tháng 7/2021:

Bảng 4.5: Độ đo RMSE giữa dữ liệu đánh giá và dự báo của 09 Điện lực khi triển khai mô hình mạng LSTM

Điện lực	RMSE	MAPE
TPTN	1,245,483	4.65%
GODAU	1,008,592	5.54%
TRANGBANG	1,260,033	5.60%
TANCHAU	1,125,511	6.07%
CHAUTHANH	1,280,931	7.09%
DUONGMINHCHAU	731,094	4.56%
TANBIEN	576,918	5.08%
HOATHANH	932,367	5.08%
BENCAU	542,478	5.24%

4.1.2. Dự báo nhu cầu phụ tải 12 tháng

4.1.2.1. Mô hình Prophet

Áp dụng mô hình Prophet dự báo nhu cầu điện thương phẩm 12 tháng tới (từ tháng 08/2020 đến tháng 07/2021) trên dữ liệu 9 Điện lực:

Điện lực	RMSE	MAPE
TPTN	916,689	4.3%
GODAU	472,559	2.8%
TRANGBANG	923,371	5.0%
TANCHAU	964,092	6.2%
CHAUTHANH	728,420	3.9%
DUONGMINHCHAU	497,566	3.8%
TANBIEN	400,620	3.9%
HOATHANH	578,297	3.7%
BENCAU	445,886	3.3%

4.1.2.2. Mô hình SARIMA

Áp dụng mô hình SARIMA dự báo nhu cầu điện thương phẩm 12 tháng tới (từ tháng 08/2020 đến tháng 07/2021) trên dữ liệu 9 Điện lực:

Điện lực	RMSE	MAPE
TPTN	1,488,488	7.5%
GODAU	541,559	3.1%
TRANGBANG	667,959	3.0%
TANCHAU	739,631	4.4%
CHAUTHANH	635,139	3.5%
DUONGMINHCHAU	617,175	4.7%
TANBIEN	410,202	3.6%
HOATHANH	830,750	5.1%
BENCAU	537,921	4.9%

4.2. So sánh kết quả khi áp dụng các mô hình

Prophet, SARIMA, LSTM

Kết quả dự báo từng tháng của 3 mô hình SARIMA, Prophet, LSTM trên dữ liệu 9 Điện lực cho thấy có 6/9 điện lực có kết quả mô hình Prophet cho kết quả tốt hơn mô hình SARIMA, mô hình LSTM cho kết quả thấp nhất. 3/9 điện lực cho kết quả SARIMA tốt hơn mô hình Prophet.

Kết quả dự báo nhu cầu điện thương phẩm 12 tháng tới của 2 mô hình SARIMA, Prophet trên dữ liệu 9 Điện lực cho thấy 2 mô hình cho kết quả không khác nhiều so với dự báo từng tháng. Mô hình Prophet vẫn cho kết quả dự báo 12 tháng tốt hơn mô hình SARIMA tại 7/9 điện lực, mô hình SARIMA cho kết quả dự báo tốt hơn mô hình Prophet tại 2/9 điện lực.

4.3. Nhận xét chung

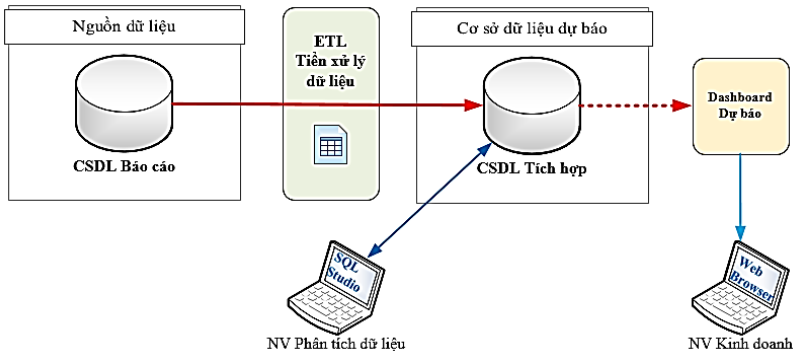
Kết quả thử nghiệm mô hình SARIMA, Prophet và mạng LSTM dự báo điện thương phẩm từng tháng và 12 tháng của dữ liệu điện thương phẩm thuộc 9 điện lực cho thấy mô hình Prophet cho kết quả dự báo với hiệu suất tốt hơn mô hình SARIMA, và mô hình mạng LSTM cho kết quả với hiệu suất thấp nhất (giá trị RMSE lớn nhất).

CHƯƠNG 5: XÂY DỰNG HỆ THỐNG DỰ BÁO NHU CẦU PHỤ TẢI ĐIỆN

5.1. Thiết kế hệ thống

5.1.1. Mô hình hệ thống

Kiến trúc tổng thể mô hình hệ thống dự báo phụ tải điện khách hàng tại Công ty Điện lực Tây Ninh được thể hiện như Hình 5.1 dưới đây.



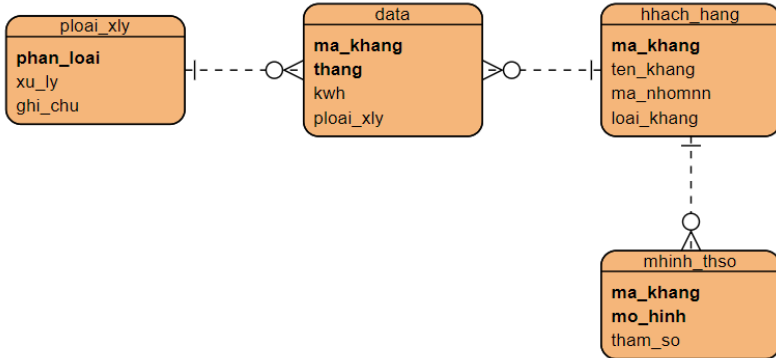
Hình 5.1 Mô hình kiến trúc tổng thể

Ngôn ngữ, thư viện và khung phần mềm được sử dụng trong hệ thống dự báo phụ tải điện khách hàng:

- Ngôn lập trình: Python
- Cơ sở dữ liệu: SQL Lite 3
- Thư viện xây dựng các mô hình dự báo (nền tảng Python): SARIMAX, Keras LSTM và Facebook Prophet.
- Khung xây dựng Dashboard phân tích, dự báo: Streamlit.

5.1.2. Thiết kế cơ sở dữ liệu cho hệ thống

Hình 5.2 là lược đồ ERD của cơ sở dữ liệu tích hợp.



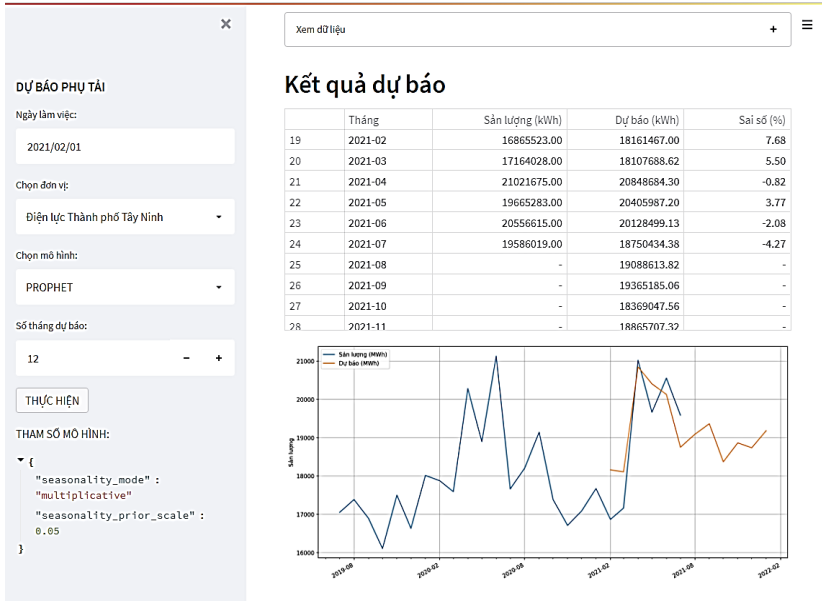
Hình 5.2 Lược đồ ERD cơ sở dữ liệu dự báo

5.1.3. Xây dựng Dashboard phân tích, dự báo

Dashboard phân tích dự báo được xây dựng trên khung phần mềm Streamlit sử dụng ngôn ngữ lập trình Python.

5.2. Kết quả

Thực hiện dự báo phụ tải điện khách hàng 12 tháng tới trên Dashboard với dữ liệu phụ tải điện khách hàng thuộc Điện lực Thành phố Tây Ninh từ tháng 02/2021 sử dụng mô hình dự báo Facebook Prophet.



Hình 5.9 Kết quả dự báo 12 tháng phụ tải điện khách hàng thuộc Điện lực Thành phố Tây Ninh từ tháng 2/2021

Sai số tuyệt đối trung bình của 6 tháng (từ 2/2021 đến 7/2021) trên dữ liệu của Điện lực Thành phố Tây Ninh là 4.02%.

III. KẾT LUẬN

Hiện nay có rất nhiều hướng nghiên cứu để triển khai hệ thống dự báo phụ tải điện đáp ứng nhu cầu điều hành, vận hành hệ thống điện. Luận văn trình bày một hướng tiếp cận có hiệu quả trong việc dự báo nhu cầu phụ tải điện trung hạn phục vụ tốt công tác quy hoạch, điều hành hệ thống điện đáp ứng mục tiêu nâng cao hiệu quả hoạt động, độ tin cậy cung cấp điện và đảm bảo cân đối cung cầu nhằm đáp ứng nhu cầu sử dụng điện của khách hàng, đó là nghiên cứu xây dựng hệ thống dự báo phụ tải điện dựa trên phương pháp dự báo chuỗi thời gian dựa trên thuật toán Facebook Prophet, SARIMA và LSTM. Kết quả thực nghiệm 3 mô hình dự báo trên dữ liệu phụ tải điện khách hàng của 9 Điện lực cho thấy mô hình dự báo chuỗi thời gian dựa trên thuật toán Facebook Prophet cho kết quả dự báo với hiệu suất tốt nhất, kế đến là mô hình SARIMA và sau cùng là mô hình LSTM.

Hướng nghiên cứu mở rộng tiếp theo của đề tài là nghiên cứu ứng dụng thuật toán phân tích chuỗi thời gian Facebook Prophet trong dự báo phụ tải ngắn hạn phục vụ công tác lập phương thức vận hành hệ thống điện (Điều độ hệ thống điện).