

Previsão de geração de energia elétrica renovável em curto prazo no estado do Ceará utilizando modelo de regressão prophet

Short-term renewable electric energy generation forecast in the state of Ceará using prophet regression

Pronóstico generación de energía eléctrica renovable a corto plazo en el estado de Ceará mediante modelo de regresión prophet

Recebido: 25/04/2022 | Revisado: 08/05/2022 | Aceito: 13/05/2022 | Publicado: 18/05/2022

Francisco Eduardo Mendes da Silva

ORCID: <https://orcid.org/0000-0002-5164-213X>
Universidade Federal do Ceará, Brasil
E-mail: eduardomendess@hotmail.com

Lincoln Moura de Oliveira

ORCID: <https://orcid.org/0000-0001-6016-745X>
Universidade Federal do Ceará, Brasil
E-mail: lincolnsobral@yahoo.com.br

Fernando Luiz Marcelo Antunes

ORCID: <https://orcid.org/0000-0002-0564-4564>
Universidade Federal do Ceará, Brasil
E-mail: fantunes@dee.ufc.br

Edilson Mineiro Sá Junior

ORCID: <https://orcid.org/0000-0002-7388-229X>
Instituto Federal do Ceará: Sobral, Brasil
E-mail: edilson.mineiro@ifce.edu.br

Resumo

O Brasil passou por um período de crise energética no último ano de 2021, devido às baixas dos rios que abastecem as hidrelétricas, sendo obrigado a acionar as usinas térmicas para o abastecimento de energia elétrica da população brasileira. Essa crise energética trás vários aspectos negativos, que podem ser evitados ou parcialmente evitados com a utilização de previsões que podem ajudar na tomada de decisões por parte dos Operadores do Sistema de Energia Elétrica. Dentro desta perspectiva este trabalho tem como objetivo principal prever a geração de energia elétrica renovável do estado do Ceará (CE) em um período de três dias à frente, através do modelo de previsão Prophet, algoritmo utilizado em grande escala pela rede social Facebook, utilizando dados de geração de energia elétrica extraído do site do Operador Nacional do Sistema (ONS). Os dados foram coletados de 01 de novembro de 2018 a 01 de março de 2021, totalizando 852 medições considerando intervalos diários. As previsões foram avaliadas pelas métricas de avaliação de modelos: RMSE, MSE e MAPE. Os dados foram divididos em 75% de dados de treinamento e 25% em dados de testes. Como resultado, observou-se que o modelo obteve um erro 5,5% levando em consideração a métrica MAPE.

Palavras-chave: Geração de energia elétrica; Energia renovável; Modelos de previsão.

Abstract

Brazil went through a period of energy crisis in the last year of 2021, due to low rivers that supply hydroelectric plants, being forced to activate thermal plants to supply electricity to the Brazilian population. This energy crisis brings several negative aspects, which can be avoided or partially avoided with the use of forecasts that can help in the decision making by the Electric Energy System Operators. Within this perspective, this work has as main objective to predict the generation of renewable electricity in the state of Ceará (CE) in a period of three days ahead, through the Prophet prediction model, an algorithm used on a large scale by the social network Facebook, using electricity generation data extracted from the website of the National System Operator (ONS). Data were collected from November 1, 2018 to March 1, 2021, totaling 852 measurements considering daily intervals. The forecasts were evaluated by the model evaluation metrics: RMSE, MSE and MAPE. The data was divided into 75% training data and 25% testing data. As a result, it was observed that the model obtained an error of 5.5% taking into account the MAPE metric.

Keywords: Electric power generation; Renewable energy; Forecast models.

Resumen

Brasil atravessó un período de crisis energética en el último año de 2021, debido al bajo nivel de los ríos que abastecen a las centrales hidroeléctricas, viéndose obligado a activar centrales térmicas para abastecer de electricidad a la población brasileña. Esta crisis energética trae varios aspectos negativos, que pueden ser evitados o evitados parcialmente con el uso de pronósticos que pueden ayudar en la toma de decisiones por parte de los Operadores del Sistema de Energía Eléctrica. En esa perspectiva, este trabajo tiene como principal objetivo predecir la generación de energía eléctrica renovable en el estado de Ceará (CE) en un plazo de tres días, a través del modelo de predicción Prophet, un algoritmo utilizado a gran escala por la red social Facebook, utilizando datos de generación eléctrica extraídos del sitio web del Operador Nacional del Sistema (ONS). Los datos fueron recolectados del 1 de noviembre de 2018 al 1 de marzo de 2021, totalizando 852 mediciones considerando intervalos diarios. Los pronósticos fueron evaluados por las métricas de evaluación del modelo: RMSE, MSE y MAPE. Los datos se dividieron en un 75 % de datos de entrenamiento y un 25 % de datos de prueba. Como resultado se observó que el modelo obtuvo un error del 5,5% teniendo en cuenta la métrica MAPE.

Palabras clave: Generación de electricidad; Energías renovables; Modelos de pronóstico.

1. Introdução

O Brasil está passando por uma crise energética provocada pela falta de chuvas e consequentemente a baixa dos reservatórios das hidrelétricas, acarretando no aumento da conta de luz ao recorrer pelas usinas térmicas, ao qual tem um custo maior e trás grandes impactos ambientais (Soares & Costa, 2022). De acordo com o Operador Nacional do Sistema Elétrico (ONS) o Brasil passa pela pior crise hidrológica desde 1930 e nos últimos sete anos os reservatórios das hidrelétricas receberam um volume de água inferior à média histórica (ONS, 2021a).

Ao mesmo tempo em que esse cenário crítico da escassez hídrica se desenvolve, uma outra realidade desponta de forma positiva. De acordo com o (ONS, 2021b):

“O segundo semestre chegou trazendo raios solares potentes e bons ventos no Nordeste. Os índices são do ONS que identificou em julho dez recordes de produção de energia oriundos de fontes renováveis. Foram quatro recordes de geração eólica média e quatro de geração instantânea (pico), além de dois recordes de energia solar fotovoltaica. O mais relevante deles foi registrado em 22 de julho, quando pela primeira vez a força dos ventos foi capaz de abastecer 102% do Nordeste durante 24 horas. Neste dia, foram produzidos 11.399 MW médios de energia eólica.”

Especialistas falam de preocupações com o ano de 2022, onde a expectativa é que as chuvas continuem abaixo da média histórica devido ao fenômeno climático EL Niña (Veiga et al., 2022). Devido a essas preocupações é de grande importância um devido planejamento por parte do ONS, já que temos 70,9% da matriz elétrica brasileira composta por hidrelétricas (58,1%), eólica (10,5%) e solar (2,3%). No caso das hidrelétricas há essa preocupação pela falta de chuvas, e nos casos da eólica e solar por serem fontes não controláveis.

Observa-se que um sistema fortemente dependente de uma única fonte, como é o caso de fonte hídrica para o Brasil, proporciona um ambiente sensível para a economia, sendo necessário investir e fortalecer outras formas de geração, sendo que a energia solar e eólica apresentam-se cada vez mais sólidas na complementariedade da geração (Pinto et al., 2017); (Jurasz et al., 2019).

Ao fim de 2020, o estado do Ceará (CE) obteve uma geração de energia elétrica renovável (eólica e solar) de 891 MW médio de energia elétrica, sendo 830 MW médio em energia eólica e 61 MW médio em energia solar (ONS, 2021a). Segundo a ABSOLAR, o ranking estadual de geração distribuída trás o estado do Ceará na 9ª posição em potência instalada de energia solar com 254,7 MW, o equivalente a 3,5%. Em geração centralizada o Ceará se mantém em 5º lugar em potência instalada com 2.130 MW em operação (ABSOLAR, 2021). Com relação à energia eólica, o setor gerou 57 TWh de energia elétrica em 2020, sua capacidade atual instalada é de 20,1 GW, e segundo a ABEÓLICA, o Brasil terá cerca de 32,23 GW de capacidade instalada em 2026 (ABEÓLICA, 2021).

Ao mesmo tempo que este cenário energético se desenvolve uma outra tecnologia vem tomando espaço no mercado mundial com resultados promissores. A chamada Inteligência Artificial (IA) reuni um conjunto de ferramentas computacionais e matemáticas, de forma que os modelos computacionais possam se ajustar aos dados, assim, os modelos possuem a capacidade de aprender padrões (Ludermir, 2021). De acordo com o relatório de tendências estratégicas para 2021 da empresa de consultoria em tecnologia da informação Gartner (Gartner, 2021), o conceito de “Hyperautomação” é indicado como uma tendência e implica na ideia que tudo que pode ser automatizado em uma organização deve ser automatizado. A IA pode ser uma ferramenta fundamental neste processo, uma vez que sua capacidade de adaptar-se a novos cenários é fundamental para mercados em constante evolução, como é o caso dos mercados de energia (CCEE, 2022).

Do ponto de vista da literatura científica, a integração entre tecnologias de inteligência artificial (IA) e Redes Inteligentes (consumo e geração de energia integrados, planejados e controlados) tem se mostrado eficiente e até necessária, uma vez que a geração e o consumo inteligente de energia têm relação indissociável com a necessidade de gestão eficiente de serviços e recursos (Khan et al, 2018), principalmente no caso de inserção de fontes renováveis de energia no sistema elétrico que exijam a necessidade de modelos de previsão que possam mitigar os efeitos característicos de intermitência inerentes às condições climáticas (Divya, 2019).

Os modelos de inteligência artificial apresentam um novo paradigma de programação onde o processo de modelagem é orientado por dados e tem sido utilizado em modelos de previsão de geração e consumo de energia elétrica em micro-redes, modelos de previsão de energia solar, eólica, ondas e outras fontes ou sistemas com modelos para escalas de tempo de curto, médio e longo prazo (Ni et al., 2018); (Aslam et al., 2018); (Mehrzadi et al., 2020).

Para manter a demanda da carga com essas condições, ou seja, com a crise energética e a intermitência das fontes eólica e solar, um bom planejamento é necessário, haja vista que o mau planejamento das previsões de demanda e carga trás impactos negativos no custo operacional das empresas de energia (Haida & Muto, 1994). Para isso, umas das ferramentas que podem ajudar nesse planejamento é a previsão de geração de energia elétrica. A previsão pode trazer informações fundamentais para determinar com maior precisão o quanto de energia é necessário para equilibrar a geração e a carga. Dentro desta perspectiva, este trabalho trás um estudo de caso ao qual aborda a previsão de geração de energia renovável em curto prazo no estado do Ceará utilizando modelo de regressão modular *Prophet*.

2. Modelo, Base de Dados e Métricas

2.1 Regressão modular – *Prophet*

Segundo Taylor e Letham (2017), o *Prophet* é um pacote para *R* e *Python* que implementa o algoritmo de previsão de séries temporais usado em produção no *Facebook*. A previsão é uma importante tarefa de ciências de dados que permite tomar decisões essenciais. Este algoritmo foi programado para detectar automaticamente os padrões sazonais de uma série de entradas, sem precisar de ajustes manuais. Contudo, é possível customizar algumas entradas de parâmetros, como indicar a presença de períodos sazonais (semanal ou anual), feriados e pontos de mudança como mostra a Equação 1 (Taylor & Letham, 2017); (Lyla, 2019).

$$y_t = g(t) + s(t) + h(t) + e(t) \quad (1)$$

Onde,

$g(t)$ refere-se à tendência (mudanças ao longo de um longo período de tempo);

$s(t)$ refere-se à sazonalidade (mudanças periódicas ou de curto prazo);

$h(t)$ refere-se a efeitos de feriados para a previsão;

$e(t)$ refere-se às mudanças incondicionais que são específicas a um negócio, pessoa ou circunstância, também chamado de termo de erro;
 $y(t)$ refere-se a previsão.

O algoritmo é essencialmente útil para conjuntos de dados que contém um longo período de tempo (hora, diário ou semanal), tenha sazonalidades fortes, evento importante conhecidos anteriormente, mais irregular, ponto de dados ausentes ou grandes exceções e mostrem tendências de crescimento não lineares que estão se aproximando de um limite.

O *Prophet* é um modelo de regressão aditiva com uma parte linear ou curva de tendência de crescimento logístico. Ela inclui um componente sazonal anual usando *Série de Fourier* e um componente sazonal semanal usando variáveis fictícias. De natureza, o *Prophet* é um modelo de regressão aditivo com quatro componentes principais:

- Uma tendência de curva de crescimento linear ou logística por partes. Ele detecta automaticamente mudanças nas tendências, selecionando os pontos de mudança dos dados;
- Uma componente sazonal anual usando a série de *Fourier*;
- Uma componente sazonal semanal usando variáveis *dummy*;
- Uma lista fornecida pelo usuário de feriados importantes.

2.2 Base de dados

A coleta de dados de geração de energia elétrica renovável foi feita através do site do ONS, o mesmo disponibiliza os resultados históricos da operação do Sistema Interligado Nacional (SIN), onde o usuário pode selecionar as variáveis desejadas, o período de visualização e a escala de discretização temporal, bem como o nível de detalhamento das informações, que podem ser agregados em nível de sistema ou apresentadas por subsistema, estado ou usina.

Os dados considerados neste trabalho são de geração de energia elétrica renovável do estado do Ceará, esses dados são armazenados em planilha do Excel, e podem ser coletados em intervalos de hora, dia, semana operativa, mês e ano. Os dados foram coletados de 01 de novembro de 2018 a 01 de março de 2021, totalizando 852 medições considerando intervalos diários.

2.3 Métricas de avaliação de modelos

Para a avaliação do desempenho do método, foram utilizadas as métricas de erro apresentadas nas equações 2, 3 e 4 (Alura, 2021).

- **Mean Squared Error (MSE)**

O MSE é uma métrica dependente de escala, ela é calculada através do erro quadrático médio entre o previsto e o realizado. Esta medida é definida pela Equação 2.

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

- **Root Mean Squared Error (RMSE)**

O RMSE é uma métrica independente de escala, ela é calculada através do desvio padrão da amostra entre o previsto e o realizado, esta métrica entra como uma forma de melhorar a interpretabilidade da métrica MSE. O RMSE é definida pela Equação 3.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (3)$$

- **Mean Absolute Percentage Error (MAPE)**

O MAPE é uma métrica independente de escala, ela é calculada através da diferença absoluta percentual de erro da amostra entre o previsto e o realizado, diferente das métricas anteriores, é uma medida representada em porcentagem. A métrica MAPE é definida pela Equação 4.

$$MPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \quad (4)$$

3. Metodologia

No presente trabalho foi utilizado o método de regressão *Prophet* para prever a geração de energia renovável (eólica e solar) no estado do CE, 3 dias a frente, através de dados históricos de geração de energia elétrica obtidos por meio do site do ONS. Os dados foram processados no ambiente de programação *Python* com o intuito de conhecer a série histórica da geração de energia, na qual será possível observar a tendência da geração e também a sazonalidade da série histórica.

Segundo os autores que descreveram o método (Taylor & Letham, 2017), por padrão, a tendência é calculada por um modelo linear onde há um ponto máximo atingível chamado de *carrying capacity*, onde a previsão deve saturar. Um modelo de tendência de crescimento logístico com *carrying capacity* específico também é possível. A sazonalidade é estimada usando a soma parcial de *Fourier*, é um parâmetro que determina a rapidez que a sazonalidade pode mudar. Valores padrão geralmente são apropriados, porém, caso precise de ajustes para alterações de maior frequência esses valores podem ser aumentados, esse valor padrão tem como ordem de *Fourier* igual a 10.

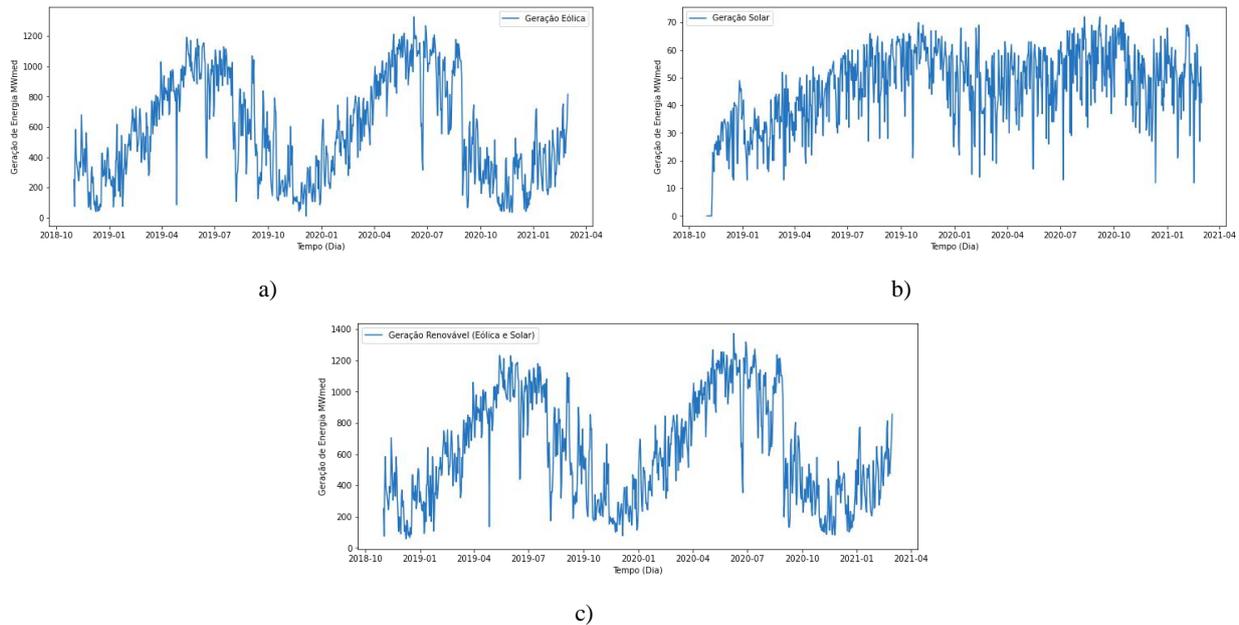
Os dados de geração de energia foram usados para treinar o modelo, o conjunto de dados foi dividido em dados de treino e teste, ou seja, 75 % em dados de treinamento representando 639 medições e 25 % em dados de teste representando 213 medições em escala diária dadas em MWh. Nesta etapa serão avaliados a precisão e o desempenho do modelo usando as métricas de avaliação apresentados no item 2.3 para comparar os resultados do método. Depois de o modelo treinado, a próxima etapa, será a etapa de previsão ao qual será predito 3 dias a frente, ou seja, o período de 01 a 03 de março de 2021. Na sequência, serão calculados os erros RMSE, MSE e MAPE, esses erros são calculados através dos valores preditos e reais de geração de energia renovável do estado do CE.

4. Resultados e Discussão

4.1 Série histórica

A série histórica é composta apenas por dados de geração de energia elétrica do estado do CE. A série contém dados de energia solar e eólica ao qual pode ser visto através da Figura 1.

Figura 1: Série histórica: a) Geração eólica; b) Geração solar; c) Geração renovável.



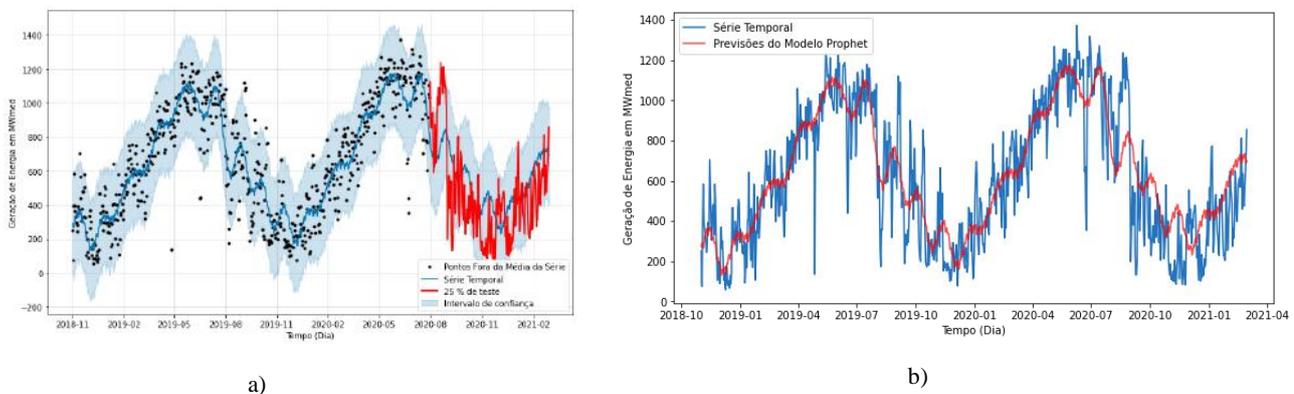
Fonte: Autores.

Observa-se da Figura 1 (a), o gráfico de geração eólica, é possível verificar a sazonalidade da série, assim como uma leve tendência de crescimento. Verifica-se da Figura 1 (b), o gráfico de geração solar, observar-se através da curva que há um crescimento e isso pode ser observado também pela quantidade de usinas que está sendo injetadas nos últimos anos no SIN (ABSOLAR, 2022). Por fim, a Figura 1 (c), mostra o que chamamos de geração renovável (o somatório de geração solar e eólica), a curva mantém o mesmo perfil da curva de geração eólica pela mesma ter maior capacidade instalada no SIN e consequentemente maior geração.

4.2 Dados de treino e teste

Os dados da série temporal de geração de energia renovável foram divididos em 75 % de dados treinamento e 25 % em dados de teste. Através desta simulação foi possível observar o erro do modelo com relação à série real com os 25 % de teste. A Figura 2 mostra a previsão na fase de teste.

Figura 2: Fase de teste: a) Todos os parâmetros da série temporal; b) Série temporal x previsão.



Fonte: Autores.

A Figura 2 (a) apresenta a série predita em linha azul, à previsão com os 25 % de dados de teste em linha vermelha, o intervalo de confiança, ao qual indica 95 % de tendência similar a tendência atual, e por fim os dados pontilhados sinalizando os dados reais. A Figura 2 (b) mostra apenas a curva da série real em azul versus a curva da série prevista pelo modelo em linha vermelha. A Tabela 1 apresenta os valores de erros usados para avaliar o modelo na fase de teste.

Tabela 1: Erros obtidos pelo método na fase de teste.

Métrica	RMSE (MWmed)	MSE (MWmed)	MAPE (%)
Modelo <i>Phophet</i>	226.63	51360.15	71.57

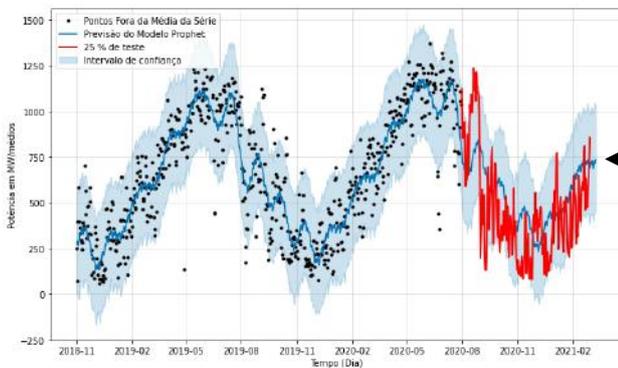
Fonte: Autores.

Os valores de erro que o modelo apresenta na fase de teste são altos, isso devido ao período de análise ser muito longo, ou seja, 25 % dos dados e aos valores de geração variar muito devido à intermitência das fontes envolvidas. Quando é feita uma previsão com o curto prazo, observa-se que o erro diminui, podendo ser observado na seção 4.3.

4.3 Previsão

A Figura 3 mostra a previsão (indicado pela seta) de geração de energia 3 dias a frente no período de 01 a 03 de março de 2021.

Figura 3: Previsão de 3 dias a frente.



Fonte: Autores.

Tabela 2: Valores de geração real e prevista.

Data	Geração real (MW médio)	Geração prevista (MW médio)
01/03/2021	756,80	700,46
02/03/2021	669,50	723,74
03/03/2021	700,40	707,80

Fonte: Autores.

Tabela 3: Erros obtidos pelo método 3 dias a frente.

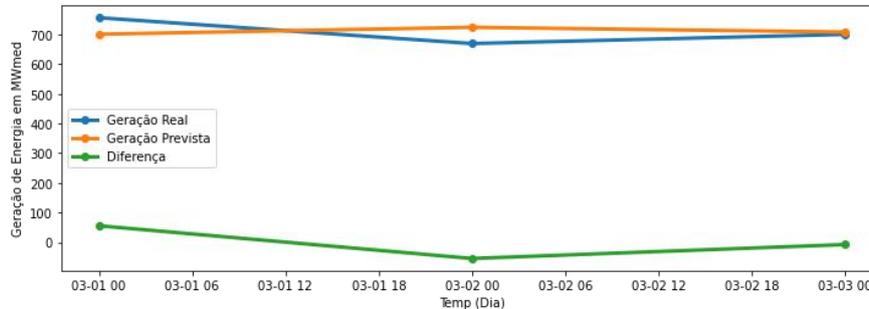
RMSE (MWmed)	MSE (MWmed)	MAPE (%)
45,24	2.047,1	5,55

Fonte: Autores.

Na Figura 3 é possível observar o gráfico de previsão de geração de energia 3 dias a frente, assim como os valores de geração real e previsto pelo modelo (Tabela 2). Com relação ao desempenho do modelo, a Tabela 3 mostra os erros obtidos pelo modelo com relação ao valor real. Apesar do modelo não se comportar como o esperado na fase de teste, na etapa de

previsão com o curto prazo, o modelo melhorou e apresentou bons resultados. No gráfico da Figura 4 é possível observar em maior escala os dados de geração real e prevista.

Figura 4: Geração real x geração prevista.



Fonte: Autores.

O gráfico da Figura 4 apresenta os dados de geração real e previstos 3 dias a frente, em cor azul a geração real, em cor laranja a geração prevista e em cor verde a diferença entre a geração de energia real e prevista. Observa-se um distanciamento entre os dois primeiros dias com 55,53 MW e -54,74 MW respectivamente. No terceiro dia, ocorreu uma diferença de -7,81 MW, uma diferença bem menor em relação aos dias anteriores.

5. Conclusão

Em busca de solucionar os problemas que o Brasil enfrenta com a crise energética, as autoridades e especialistas da área buscam adotar medidas para economizar o consumo de energia elétrica. Dentro deste escopo, uma das medidas que podem ser adotadas para o enfrentamento da crise e consequentemente a economia de energia é a previsão da geração de energia elétrica. A previsão trás flexibilidade para a tomada de decisão quando necessário, ou seja, gerar energia elétrica quando ela é demandada. O estudo de caso apresentado neste trabalho mostrou que o método proposto foi capaz de prever a geração de energia renovável no estado do CE, com erro de 5,55 % levando em consideração a métrica MAPE.

Técnicas como esta podem trazer informações sobre o perfil da curva de geração de energia, pois elas são capazes de prever com antecedência e assim serem tomadas tais decisões pontuais. Como este trabalho é um estudo de caso e constituído com dados de geração de energia elétrica de fontes eólica e solar do estado do CE e essas fontes serem não controláveis, não é possível ter um controle da geração, pois não se trata de fontes despacháveis como as usinas hidrelétricas, o que não se aplica em nível de Brasil, pois 58,1 % da matriz elétrica brasileira são compostas por fontes hidrelétricas, logo, aplicando essas técnicas de previsão com os dados de geração renovável de energia elétrica em nível de Brasil, pode-se ter um controle da despachabilidade da fonte hidráulica enquanto as demais (eólica e solar) estão gerando a todo vapor, e assim gerando uma economia com o armazenamento da fonte despachável.

Para trabalhos futuros, recomenda-se uma variação da ordem de Fourier do modelo em termos de comparação com a ordem fixa em busca de melhores resultados. Outra recomendação é a utilização de outras técnicas inteligentes de modelos de previsão para comparar com os resultados deste modelo.

Agradecimentos

Os autores agradecem a Fundação Cearense de Apoio a Pesquisa (FUNCAP) pelo apoio financeiro e ao Programa de Pós Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Ceará (UFC) pelo suporte e a viabilização desta pesquisa.

Referências

- Aslam, S., Herodotou, H., Ayub, N., & Mohsin, S. M. (2019). Deep Learning based Techniques to Enhance the Performance of Microgrids: A Review. *International Conference on Frontiers of Information Technology (FIT)*.
- Associação Brasileira de Energia Solar (ABSOLAR). <https://www.absolar.org.br/noticias/>.
- Associação Brasileira de Energia Eólica (ABEOLICA). <https://abeeolica.org.br/category/noticias/agencia-abeeolica/>.
- Câmara Comercializadora de Energia Elétrica (CCEE). <https://www.ccee.org.br/pt/web/guest/-/ccee-somava-12.240-agentes-ao-final-de-2021-14-a-mais-do-que-em-dezembro-de-2020#:~:text=A%20C%3%A2mara%20de%20Comercializa%C3%A7%C3%A3o%20de,mercados%20de%20energia%20no%20pa%C3%ADs>.
- Divya, R., Gopika, N. P., & Manjula, G. N. (2019). ANN Based Solar Power Forecasting in a Smart Microgrid System for Power Flow Management” *Innovations in Power and Advanced Computing Technologies*.
- Energia Eólica: Os bons ventos do Brasil. http://abeeolica.org.br/wp-content/uploads/2021/11/2021_11_InfoVento23.pdf.
- Escassez Hídrica. Operador Nacional do Sistema Elétrico. <http://www.ons.org.br/Paginas/Noticias/20210707-escassez-hidrica-2021.aspx>.
- Energia fotovoltaica: por que essa tecnologia vai brilhar cada vez mais. (2022). ABSOLAR. <https://www.absolar.org.br/noticia/energia-fotovoltaica-por-que-essa-tecnologia-vai-brilhar-cada-vez-mais/>.
- Gartner Top Strategic Technology Trends for 2021. Gartner. <https://www.gartner.com/smarterwithgartner/gartner-top-strategic-technology-trends-for-2021>.
- Haida, T., Muto, S. (1994). Regression based peak load forecasting using a transformation technique. *Power Systems. IEEE Transactions*.
- Jurasz, J., Canales, F. A., Kies, A., Guezgouz, M., & Beluco, A. (2020). A review on the complementarity of renewable energy sources: Concept, metrics, application and future research directions. *Elsevier. Solar Energy* 195, 703–72.
- Lyla, Y. 2019. Um Início Rápido da Previsão de Séries Temporais com um Exemplo Prático usando o FB Prophet.
- Ludermir, T. B. (2021). Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. 10.1590/s0103-4014.2021.35101.007.
- Khan, S., Paul, D., Momtahan, P., & Aloqaily, M. (2018). Artificial Intelligence Framework for Smart City Microgrids: State of the art, Challenges, and Opportunities. *Third International Conference on Fog and Mobile Edge Computing (FMEC)*.
- Métricas de avaliação para séries temporais. (2021). Alura. Junho de 2021, a partir de <https://www.alura.com.br/artigos/metricas-de-avaliacao-para-series-temporais>.
- Mehrzadi, M., Terriche, Y., Su, C., Xie, P., Bazmohammadi, N., Costa, M. N., Liao, C., Vasquez, J. C., & Guerrero, J. M. 2020. A Deep Learning Method for Short-Term Dynamic Positioning Load Forecasting in Maritime Microgrids. *Appl. Sci.* 4889.
- Ni, C., Ma, X., & Bai, Y. (2018). Convolutional Neural Network based power generation prediction of wave energy converter. *Proceedings of the 24th International Conference on Automation & Computing*, Newcastle University, Newcastle upon Tyne, UK, 6-7 September.
- Nordeste Registra em Julho Dez Recordes de Energia Renovável. Operador Nacional do Sistema Elétrico. <http://www.ons.org.br/Paginas/Noticias/20210804-nordeste-registra-em-julho-dez-recordes-de-geracao-renovavel.aspx>.
- Operador Nacional do Sistema. Novembro de 2021(a) a partir de <http://www.ons.org.br/>
- Operador Nacional do Sistema. Nordeste registra em julho dez recordes de energia renovável. *J* <http://www.ons.org.br/Paginas/Noticias/20210804-nordeste-registra-em-julho-dez-recordes-de-geracao-renovavel.aspx#:~:text=O%20segundo%20semestre%20chegou%20trazendo,energia%20oriundos%20de%20fontes%20renov%C3%A1veis>.
- Pinto, L. I. C., Martins, F. R., & Pereira, E. B. (2017). O mercado brasileiro da energia eólica, impactos sociais e ambientais. *Ambiente & Água - An Interdisciplinary Journal of Applied Science*. 10.4136/1980-993X.
- Proposta conceitual para a Abertura do Mercado. (2021). CCEE- Câmara de Comercialização de Energia Elétrica. Setembro de 2021, a partir de <https://static.poder360.com.br/2021/11/proposta-conceitual-abertura-mercado-livre.pdf>.
- Panorama da solar fotovoltaica no Brasil e no mundo. Novembro de 2021, a partir de <https://www.absolar.org.br/mercado/infografico/>.
- Soares, M. A., & Costa, H. K. M. (2022). The Brazil’s power distribution utililites: anassessment about hydro crisisin 2001 and 2021. *Conjecturas*, 22(2).
- Taylor, S. J., & Letham, B. (2017). Forecasting at scale. *PeerJ Preprints* 5:e3190v2. doi.org/10.7287/peerj.preprints.3190v2.
- Veiga, R. Q., Lucena, A. J., & Wanderley, H. S. (2022). Influences of El Niño on the distribution of rainfall in the city of Rio de Janeiro. *RA’EGA, O espaço geográfico em análise*, 53(2), 22–47.