

Aplicação de Redes Neurais Artificiais na Predição de Geração de Energia Fotovoltaica no Nordeste do Brasil

Application of artificial neural networks in the prediction of photovoltaic power generation in Northeast of Brazil

Henrique Queiroz Cunha¹

 orcid.org/0000-0001-9253-2095

Leonardo Farias Sobel¹

 orcid.org/0000-0003-0271-7681

¹Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, Brasil. E-mail: hqc@ecomp.poli.br

Artigo recebido em:
Artigo aceito em:

DOI: 10.25286/repa.v6i5.1767

Esta obra apresenta Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.

Como citar este artigo pela NBR 6023/2018: CUNHA, H. Q.; SOBEL, L. F. Aplicação de Redes Neurais Artificiais na Predição de Geração de Energia Fotovoltaica no Nordeste do Brasil. Revista de Engenharia e Pesquisa Aplicada, Recife, v.6, n. 5, p. 73-80, Novembro, 2021.

RESUMO

A geração de energia por meio de fontes sustentáveis ganha importância cada vez maior na atual configuração do mercado global. No Brasil a região Nordeste, por sua localização geográfica e características climáticas, apresenta maior estabilidade na produção de energia solar ao longo do ano. Por isso, se destaca entre as demais regiões e possui a maior capacidade instalada de usinas solares no território nacional. Desta forma, este trabalho tem como objetivo avaliar o uso de redes neurais artificiais como método para a predição de geração de energia fotovoltaica no Nordeste brasileiro. Para isso foram coletados e pré-processados os dados climáticos e de geração de energia disponíveis na cidade de Bom Jesus da Lapa/ Bahia. E, após processados, os resultados de predição obtidos por meio das redes Multilayer Perceptron (MLP) e Long Short-Term Memory (LSTM) foram comparados com os do método linear clássico ARIMA (Autoregressive Integrated Moving Average). Por fim, observa-se o bom resultado obtido pelas redes neurais como ferramentas para predição de energia fotovoltaica.

PALAVRAS-CHAVE: Redes Neurais; ARIMA; Energia Fotovoltaica;

ABSTRACT

The generation of energy through sustainable sources is becoming increasingly important in the current global market configuration. In Brazil, the Northeast region, due to its geographical location and climatic characteristics, has a best stability in the production of solar energy throughout the year. For this reason, it stands out among the other regions and has the largest installed capacity of solar plants in the country. Thus, this paper aims to evaluate the use of artificial neural networks as a method for predicting the generation of photovoltaic energy in the Brazilian Northeast. For this, the climatic and energy generation data available in the city of Bom Jesus da Lapa/ Bahia were collected and pre-processed. And, after processing, the prediction results obtained using the Multilayer Perceptron (MLP) and Long Short-Term Memory (LSTM) networks were compared with those of the classical linear ARIMA (Autoregressive Integrated Moving Average) method and showed good performance. Finally, the good result obtained by neural networks as tools for photovoltaic solar energy prediction was observed.

KEY-WORDS: Neural Networks, ARIMA, Photovoltaics energy;

1 INTRODUÇÃO

O aquecimento global vem exigindo, dos mais diversos segmentos econômicos, uma rápida adaptação ao conceito de sustentabilidade. Sendo tema de discussão não apenas da comunidade científica, mas dos governantes e da opinião pública [1].

O desenvolvimento da sociedade moderna anda de mãos dadas com a demanda de energia e a capacidade de produzi-la [2]. E o setor energético mundial foi responsável por 33,3 bilhões de toneladas de emissão de CO₂ em 2019 [3], o que torna irremediável a transição para uma matriz energética sustentável. Os dados da Agência Internacional de Energia (IEA) [3], demonstram ainda que, apesar de ter ocorrido um corte nas emissões de CO₂ pelos países desenvolvidos, as nações emergentes emitiram mais gases que em relação a 2018.

O Brasil apresenta situação privilegiada em termos de potencial de geração de energia elétrica a partir de fontes renováveis, isso deve-se ao fato do amplo uso das hidrelétricas para geração da nossa energia. Juntas as fontes sustentáveis de energia representam em 2021 mais de 85% da capacidade instalada no Brasil [4].

Embora o Brasil tenha uma grande matriz hidráulica para geração de energia, quase todo potencial está sendo aproveitado. Existe, também, uma dificuldade na construção de novas hidrelétricas por restrições ambientais e sociais [5]. E por isso, as novas hidrelétricas, em sua predominância, estão sendo construídas com caráter de fio d'água [6], minimizando a capacidade de regularização das vazões e gerando um perfil de intermitência, diretamente associado à pluviosidade na bacia hidrográfica [7].

Essa característica nos deixa "reféns" da chuva o que pode comprometer a regularidade da produção hidroelétrica, implicando na necessidade de utilização das termelétricas, geradoras de energia bem mais caras e poluentes [8].

A tecnologia fotovoltaica, de característica sustentável, apresenta grande crescimento no mundo. De acordo com o relatório da *Renewables Global Status Report* [9], as energias renováveis cresceram 200 GW em 2019, sendo a fonte solar fotovoltaica responsável por 57,5% (129W), seguida pela fonte eólica com 30% de participação (60 GW) e a fonte hidrelétrica 8% (18 GW).

Em relação à capacidade instalada solar fotovoltaica, os principais países do mundo são China, Japão e EUA, conforme ranking de 2019 da ABSOLAR. O Brasil aparece apenas na 16ª posição.

No Brasil a região Nordeste se caracteriza pela boa incidência de irradiação solar direta, principal fator para a viabilidade desta tecnologia. Se apresentando como uma excelente opção para a complementação da demanda das consolidadas hidroelétricas, favorecendo o controle hídrico nos reservatórios nos períodos de menor incidência de chuvas [10].

Até maio de 2021, o Nordeste conta com a maior potência outorgada de usinas fotovoltaicas, conforme informações disponíveis pela plataforma da ONS (Operador Nacional do Sistema) [11]. No Quadro 1, com informações retiradas do Sistema de Informações de Geração da ANEEL (SIGA), fica demonstrada a distribuição da Potência Outorgada no Brasil (kW) proveniente da Radiação Solar [12].

Quadro 1: Distribuição da Potência Outorgada no Brasil.

UPV	POTÊNCIA	%
Nordeste	2.409.659	71,41
Norte	14.492	0,43
Centro-oeste	5.971	0,18
Sudeste	931.732	27,61
Sul	12.688	0,38
TOTAIS	3.3743.544	100%

Fonte: ANEEL - SIGA (2021).

Contudo, por depender de condições climáticas, tais como radiação solar, temperatura, velocidade do vento [13, 14] entre outras variáveis, há de se considerar a necessidade de previsão para estimar o potencial instalado e planejamento [15, 16]. Daí o surgimento de inúmeras técnicas de predição que promovem uma maior previsibilidade ao operador do sistema elétrico.

Entre estas técnicas, se pode destacar a utilização de redes neurais artificiais. Justamente por sua capacidade de "aprender" padrões através do treinamento. Ainda mais quando os dados não possuem relação bem definida e/ou não lineares. Sendo mais difícil a adoção dos métodos convencionais [17, 18].

Ainda, para a caracterização do objeto do trabalho é importante descrever que séries temporais são um conjunto de observações ordenadas no tempo que, aparentemente, não seguem nenhuma lei ou tendência [18, 19]. No

entanto, em diversos exemplos de séries temporais estudados, como os relacionados a fenômenos naturais e dados climáticos, é possível identificar características que se repetem após determinado período de tempo (sazonalidade), mesmo que não sejam padrões lineares [18, 19].

Nesse contexto, esse estudo se propõe a utilizar um método linear clássico ARIMA e outros dois de redes neurais artificiais, o MLP e LSTM, para desenvolver uma metodologia na previsão de geração de energia, a partir dos dados meteorológicos disponíveis para a região Nordeste brasileira. Para isto, são usados os dados das Usinas do Conjunto Fotovoltaico B JL Solar localizado em Bom Jesus da Lapa/BA.

A escolha do Conjunto B JL Solar se deve por existir grande disponibilidade de dados temporais na plataforma da ONS e, ainda, possuem dados climáticos disponibilizados pelo INMET nesta localidade. Assim, se pode extrair o máximo potencial das redes neurais artificiais na previsão, sem a necessidade de técnicas de interpolação para estimar dados e condições climáticas. O Conjunto Fotovoltaico B JL Solar possui dados de geração de energia desde ABR/2018.

Este trabalho está organizado em quatro seções. A Seção 1 introduz o atual momento do Setor e a importância de utilização de modelos de previsão na área de energia solar; na Seção 2 são apresentados os materiais e métodos que foram utilizados para o estudo em questão. A Seção 3 descreve como foi realizado o estudo experimental e a Seção 4 apresenta os resultados. Na Seção % consta uma breve discussão onde é proposto novas ideias para futuras melhorias.

2 MATERIAIS E MÉTODOS

A seguir são apresentados os conjuntos de dados selecionados para o estudo, os procedimentos metodológicos empregados na previsão das séries temporais e as observações e análises obtidas do experimento realizado.

2.1 COLETA DE DADOS

Abaixo são descritos os procedimentos e os critérios adotados para coleta dos dados.

ONS: Por meio do portal do Operador Nacional do Sistema Elétrico (ONS) é possível obter os dados de geração de energia horária do Conjunto Fotovoltaico B JL Solar [20], localizado em Bom Jesus da Lapa, no Estado da Bahia.

Apesar de instalada em meados de ABR/2018, o atual potencial de geração de energia do Conjunto Fotovoltaico B JL Solar é atingido a partir de NOV/2018. Assim, foi utilizada a Geração de Energia (MWmed) no modelo de previsão.

INMET: Através do portal do Instituto Nacional de Meteorologia (INMET) é possível obter os dados históricos anuais de diversas estações meteorológicas espalhadas pelo Brasil [12]. O histórico disponível é entre os anos de 2000 e março/2021 onde é disponibilizado as medições horárias. Assim foi coletado os dados da Estação Meteorológica de Bom Jesus da Lapa a partir de ABR/2018 em acordo com os dados de geração de energia disponibilizados pela ONS do Conjunto Fotovoltaico B JL Solar.

Neste trabalho optou-se por utilizar os 17 atributos disponíveis para potencializar a previsão.

SOLCAST: Desenvolvido em 2015, é uma das plataformas de referência no mundo quando se trata de dados de irradiação solar. Desenvolvida por uma equipe de cientistas de dados e engenheiros localizados na cidade de Palo Alto na Califórnia, suas ferramentas de captura de dados contam com uma frota global de satélites meteorológicos geostacionários. Nela é possível obter dados em tempo real e/ou o histórico de dados horários da irradiação solar em praticamente qualquer local do mundo [21].

Os 18 atributos disponíveis foram utilizados no estudo de previsão.

2.2 METODOLOGIA

Nesta subseção está descrito o método, a forma e o tipo de análise realizada. Constará os principais passos de pré-processamento e os conceitos fundamentais adotados na estimativa de produção de geração de energia fotovoltaica adotados nos modelos utilizados que foram o linear ARIMA e os de redes neurais MLP e LSTM.

2.2.1 Pré-processamento de Dados

A partir da coleta de dados, conforme descrito na subseção 2.1, foi reunido o conjunto de atributos identificados como relevantes nesse trabalho em uma única tabela. Que após as fases de pré-processamento descritas a seguir objetivam a montagem do conjunto de treino e testes a ser utilizado no modelo clássico e nos de *machine learning*.

Inicialmente é observado que por se tratar de medições horárias, diversos dados não constavam. Após análise, verificou-se que tratam de momentos em que não ocorreram leituras, como pode ser facilmente exemplificado pelo atributo precipitação total (mm) que consta da tabela do INMET. Assim, esses dados foram preenchidos com o valor zero. Dessa forma, cada atributo foi analisado e preenchido os valores faltantes de acordo com as características necessárias para manter a integridade da base e a efetividade no resultado final do estudo.

Após a aglutinação dos dados do INMET, ONS e SOLCAST a base de trabalho resulta em colunas temporais (horárias) e com 35 atributos. Como critério, esse estudo adota o maior número de características dessas bases com o objetivo de maximizar o resultado dos modelos de predição.

Outro aspecto para a organização dos dados foi a normalização e para isso foi adotada a função *MinMaxScaler* da biblioteca *scikit-learn*. Assim os atributos são transformados em valores entre 0 e 1, preservando a distribuição original de cada coluna de forma independente. A função *MinMaxScaler* segue a equação (1):

$$\text{Valor Normalizado (entre 0 e 1)} = \frac{(X_n - X_{\min})}{(X_{\max} - X_{\min})} \quad (1)$$

Onde:

X_n : valor do atributo da série temporal original a ser normalizado;

X_{\min} : valor mínimo da série temporal associada à variável (ao atributo) em questão; e,

X_{\max} : valor máximo da série temporal associada à variável (ao atributo) em questão.

2.2.2 Modelos ARIMA

Importante classificar, inicialmente, que uma série temporal é um conjunto de observações ordenadas no tempo (não necessariamente igualmente espaçadas), e que apresentam dependência serial (isto é, dependência entre instantes de tempo) [22].

O modelo ARIMA (autoregressive integrated moving average, na sigla em inglês) é uma generalização do modelo ARMA (modelo autorregressivo de médias móveis) no qual é adicionado o conceito de integração. Ambos são modelos para a análise de séries temporais e predição. A metodologia do ARIMA consiste em ajustar modelos autorregressivos integrados de

médias móveis a um determinado conjunto de dados [18, 23].

O Seasonal ARIMA (SARIMA ou SARIMAX), é uma extensão do modelo ARIMA que permite identificar e considerar a sazonalidade [18, 23]. Além disso, o modelo SARIMA também trabalha bem com dados exógenos.

O ARIMA (p, d, q) vem seguido de três aspectos-chaves que são: a ordem de auto regressão (p); o grau de diferenciação (d); e, a componente de médias móveis (q). Sendo necessário fornecer estes valores na busca de um bom modelo. Para a verificação dos modelos gerados a partir da série temporal em estudo, visando o ajuste ideal dos parâmetros para fornecer a melhor previsão pelo ARIMA (p, d, q) é usado a função 'autoarima' [18].

No modelo SARIMA [(p, d, q)(P, D, Q)m] são adicionados mais 4 parâmetros: o P (maiúsculo, para a ordem auto regressiva sazonal); o D (maiúsculo, para a ordem de diferenciação sazonal); o Q (maiúsculo, para a ordem de médias móveis sazonal); e, o m (número de passos para um único período sazonal) [18, 23].

2.2.3 Modelos MLP

Modelo de rede neural que se destacam pelas seguintes características dos *perceptrons* multicamadas [17]:

- O modelo de cada neurônio na rede inclui uma função de ativação não linear que é variável;
- A rede contém uma ou mais camadas que estão ocultas dos nós de entrada e saída; e,
- A rede exibe alta conectividade, cuja extensão é determinada pelos pesos sinápticos da rede.

No que diz respeito ao seu funcionamento e arquitetura o algoritmo back-propagation destaca as redes *Multilayer (feedforward) Perceptron* e, de forma geral, possuem duas etapas [17]:

- Forward: Onde o vetor de entrada é aplicado à camada de sensoriamento e seus resultados propagados até a camada de saída com os pesos fixos durante o processo; e,
- Backwards: em que são feitos os ajustes dos pesos.

2.2.4 Modelo LSTM

A Long Short-Term Memory, ou LSTM, é um tipo de Rede Neural Recorrente.

Redes Neurais Recorrentes, ou RNNs, são um tipo especial de rede neural projetada para problemas de sequência. Dada uma rede MLP *feedforward* padrão, uma RNN pode ser pensada como a adição de loops à arquitetura que permitem

que as informações persistam. Ou seja, no caso mais simples, a rede vê uma observação por vez de uma sequência de dados e pode aprender quais observações que ela viu anteriormente são relevantes para fazer uma previsão [23].

Contudo, o principal desafio técnico enfrentado pelas RNNs é como treiná-las de forma eficaz (devido aos problemas da dissipação do gradiente – *vanishing* – ou da explosão dos gradientes – *exploding* – nas camadas iniciais). Assim, surgem as LSTMs com um novo design e que é popularizado por evitar os problemas que impedem o treinamento e dimensionamento que existem nas demais RNNs [23].

Assim a arquitetura LSTM, também chamada de “redes de memória de longo-curto prazo”, cumpre a promessa para a previsão de sequências com a característica de persistência. E, devido a essa capacidade de aprender correlações de longo prazo em uma sequência, conforme descrito nos parágrafos anteriores, as redes LSTM evitam a necessidade de uma janela de tempo pré-especificada e são capazes de modelagem de sequências multivariadas complexas [23].

A LSTM possui uma estrutura em cadeia que contém quatro camadas de interação e diferentes blocos de memória. Essas estruturas são chamadas de células. O termo neurônio como unidade computacional é tão arraigado ao descrever MLPs que, frequentemente, também é usado para se referir à célula de memória LSTM. Contudo, as células LSTM são compostas por pesos (weights) e portas (gates). De forma geral a informação fica retida nas células (que possuem parâmetros de peso em sua entrada e saída) e as manipulações de memória são realizadas nos portões (gates) [23].

Logo, a base para a memória das células está nos portões. Que também possuem funções ponderadas e que governam o fluxo das informações. São três as portas nas células: *Forget Gate*, *Input Gate* e *Output Gate*. Os portões são uma forma de proteger, controlar e, opcionalmente, deixar passar informações pelas células [23].

Assim as LSTMs possuem como principais características [23]:

- Consegue resolver os problemas técnicos de treinamento de uma RNN (*vanishing* e *exploding*);
- Agregar memória para superar problemas que possuem dependência temporal de longo prazo com dados de entrada sequenciais; e,
- Consegue processar dados sequenciais de entrada e de saída gradualmente, permitindo

variando os comprimentos de entrada e de saída dos dados.

2.2.5 Métricas de Avaliação

Para avaliar o desempenho de previsão dos 3 tipos de modelos usados, foram utilizadas medidas que expressam o erro médio do modelo preditivo em relação ao modelo original. Por se tratar de métricas que expressam “erros” quanto menor seu valor melhor o modelo avaliado.

Assim, está listado a seguir, as métricas utilizadas para a avaliação dos modelos estudados.

Na equação (1), a raiz do erro quadrático médio (RMSE, na sigla em inglês) é a medida que calcula “a raiz quadrática média” dos erros entre valores reais de geração de energia e as previsões [27].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (F_{oi} - F_{ei})^2}{n}} \quad (2)$$

Na equação (2), o erro médio absoluto (MAE, na sigla em inglês) é a diferença média absoluta entre valores reais de geração de energia e os valores previstos. Essa métrica varia de zero a infinito. Um valor menor indica um modelo de qualidade superior [27].

$$MAE = \frac{\sum_{i=1}^n |F_{oi} - F_{ei}|}{n} \quad (3)$$

Nas equações (2) e (3) temos:

- F_{oi} - representa a produção de energia na hora i ;
- F_{ei} - representa a produção de energia estimada pelos modelos (ARIMA ou de aprendizado de máquina) na hora i ; e,
- n - corresponde ao número de dados utilizados no estudo preditivo (dados para o treinamento).

3 ESTUDO EXPERIMENTAL

Nesta seção serão apresentadas as configurações dos modelos para o processo de busca dos hiperparâmetros de cada arquitetura utilizada e as métricas de avaliação.

Foram empregados os atributos, conforme coleta de dados descrita nas subseções anteriores, para a previsão de energia fotovoltaica. Ao todo são 8.737 observações e 35 atributos sendo o conjunto de treino e teste divididos da seguinte forma 6.552 instâncias (75%) para treinamento e 2.185 instâncias (25%) para testes.

Para o estudo foi usado um computador com processador 1.6 Intel® Dual Core™ i5, CPU 1.6Ghz com 8.00GB RAM. Foi utilizada a linguagem Python

3.7.10 com o auxílio das seguintes bibliotecas: *Pandas, NumPy, TensorFlow, Pmdarima, Scikit-learn, Keras, StatsModels, Matplotlib e Pydot.*

3.1 Aplicação dos Modelos

A seguir, encontra-se as configurações e hiper parâmetros adotados nos modelos estudados.

ARIMA/ SARIMA: Visando o ajuste ideal dos parâmetros para fornecer a melhor previsão foi usado a função 'autoarima' que retornou à configuração:

```
Best model: ARIMA(0,0,0)(0,0,0)[24] intercept
```

Adotando o resultado obtido na função 'autoarima' tem-se o modelo SARIMA (p,d,q = [0,0,0] e sazonal (P,D,Q [0,0,0]), com período sazonal m = 24. Assim, é implementado o modelo SARIMA conforme a seguir:

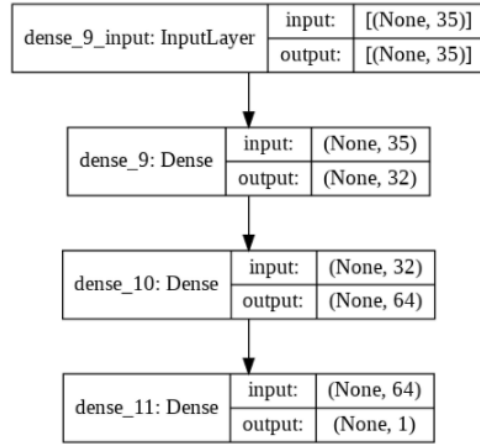
```
SARIMAX(endog=endog_y, exog=exog_x, order=(0,0,0), out_of_sample_size=0, seasonal_order=(0, 0, 0, 24), method='lbfgs', scoring='mse', start_params=None, suppress_warnings=True, trend=None)
```

As métricas de avaliação obtidas para o SARIMA foram:

```
Model Evaluation scores:
Test RMSE: 3.220
Test MAE: 1.912
```

MLP: Neste modelo é utilizado uma rede neural com duas camadas ocultas, função de ativação RELU, otimizador ADAM, função de perda MSE (Mean Squared Error) e um neurônio na camada de saída. Os hiper parâmetros utilizados foram: número de neurônios na camada oculta: 32 e 64; número de épocas 150; e, batch_size 16.

Figura 1: Arquitetura utilizada na MLP



Fonte: O autor.

As métricas de avaliação obtidas para a MLP foram:

```
Model Evaluation scores:
Test RMSE: 3.293
Test MAE: 1.650
```

LSTM: Para este modelo de rede neural foram aplicadas duas camadas ocultas, função de ativação RELU, otimizador ADAM, função de perda MSE (Mean Squared Error) e um neurônio na camada de saída. Os hiper parâmetros utilizados foram: número de neurônios na LSTM: 64; número de neurônios na camada oculta: 32; número de épocas 150; e, batch_size 16.

Figura 2: Arquitetura utilizada na LSTM

```

Model: "sequential_4"
-----
Layer (type)                Output Shape                Param #
-----
lstm (LSTM)                  (None, 32)                  8704
dense_12 (Dense)             (None, 64)                  2112
dense_13 (Dense)             (None, 1)                   65
activation (Activation)      (None, 1)                   0
-----
Total params: 10,881
Trainable params: 10,881
Non-trainable params: 0
  
```

Fonte: O autor.

As métricas de avaliação obtidas para o modelo LSTM foram:

```
Model Evaluation scores:
Test RMSE: 3.304
Test MAE: 1.566
```

MLP + GridSearch: Ainda, se utilizou o recurso *GridSearchCV*, com um dicionário de parâmetros, com o objetivo de encontrar a melhor configuração para o modelo MLP.

```
# Use scikit-learn to grid search
activation = ['relu', 'tanh', 'sigmoid',
'linear'] # softmax, softplus, softsign
dropout_rate = [0.0, 0.4, 0.7]
neurons = [1, 5, 10, 15, 20, 25, 30]
#####
#####
# grid search epochs, batch size
epochs = [50, 100, 150] # add 50, 100, 150
etc
batch_size = [16, 32] # add 5, 10, 20, 40,
60, 80, 100 etc
grid = GridSearchCV(estimator=model,
param_grid=param_grid, n_jobs=-1,
scoring='neg_root_mean_squared_error',
cv=3)
grid_result = grid.fit(x_tentativa,
y_tentativa)

# print best parameter after tuning
print(grid.best_params_)
```

O melhor modelo entre as combinações do dicionário de parâmetros foi:

```
Best: -0.470817 using {'activation':
'relu', 'batch_size': 16, 'dropout_rate':
0.4, 'epochs': 150, 'neurons': 30}
```

As métricas de avaliação obtidas para o modelo LSTM com *GridSearch* foram:

```
Model Evaluation scores:
Test RMSE: 3.524
Test MAE: 2.004
```

4 RESULTADOS

Nesta Seção é demonstrado os valores obtidos por meio das métricas estatísticas de ajuste priorizadas no estudo.

Por definição, o RMSE eleva ao quadrado a diferença dos erros entre o conjunto de dados reais e os de predição, antes de ter a média calculada. Assim, a presença de outliers no conjunto de dados

resulta em valores superiores quando comparados ao MAE. A Tabela (1) mostra os resultados obtidos.

Tabela 1: Métricas com os resultados obtidos.

	MAE	RMSE
SARIMA	1.912	3.22
MLP	1.660	3.293
LSTM	1.566	3.304

Fonte: Os autores.

Quando comparadas com os resultados do modelo de predição linear clássico (ARIMA), as redes neurais artificiais obtiveram resultados melhores de MAE e de grandeza similares no RMSE. Portanto, a partir das métricas utilizadas, observa-se o bom comportamento das redes neurais como ferramentas para predição

5 CONSIDERAÇÕES FINAIS

Assim, por meio deste trabalho foi proposto uma metodologia de previsão de produção de energia em usinas fotovoltaicas, utilizando dados de séries temporais, com o auxílio de algumas ferramentas que estão à disposição do meio acadêmico e do setor energético brasileiro, com destaque a utilização das técnicas de Machine Learning.

Para novos estudos, fica recomendado a utilização de outros modelos, como o de Rede Neural Convolutiva (CNN), realizando uma convolução 1D (Conv1D).

Ainda, para futuros estudos, poderá ser trabalhado o conjunto de dados do INMET de outras estações meteorológicas, utilizando a metodologia do presente estudo, na busca de novas localidades com alto potencial de geração fotovoltaico e com baixa potência instalada.

REFERÊNCIAS

- [1] GORE, Al. **Uma Verdade Inconveniente**. 1. ed. São Paulo: Manole, 2006. LAKATOS, E. M., MARCONI, M. A. Fundamentos de Metodologia Científica. 6. ed. São Paulo: Atlas, P.10, 2005.
- [2] GOLDEMBERG, J.; VILLANUEVA, L. P. **Energia, Meio Ambiente & Desenvolvimento**. São Paulo: Edusp, 2003, p. 44.
- [3] **Emissões globais de CO2 do setor energético se estabilizaram em 2019**. Época Negócios, 12 de fev. de 2020.

- [4] **EVOLUÇÃO DA CAPACIDADE INSTALADA NO SIN.** Disponível em: <<http://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>>. Acesso em 04 de maio de 2021.
- [5] PIMENTA, F. M.; ASSIREU, A. T. **Simulating reservoir storage for a wind-hydro hybrid system.** Universidade Federal de Santa Catarina, 2014.
- [6] **A Expansão das Usinas a Fio d'Água e o Declínio da Capacidade de Regularização do Sistema Elétrico Brasileiro.** Federação de Indústrias do Estado do Rio de Janeiro. Agosto de 2013.
- [7] PERON, A. M. **Análise da complementaridade das gerações intermitentes no planejamento da operação eletro-energética da região nordeste brasileira.** UNIVERSIDADE ESTADUAL DE CAMPINAS, 2017.
- [8] ALVAREZ, F. S. **Desenvolvimento de um sistema computacional para gerenciamento e análise de dados eólicos.** Universidade Federal de Pernambuco – UFPE, 2013.
- [9] **RENEWABLES 2020 GLOBAL STATUS REPORT.** Disponível em: <https://www.ren21.net/wp-content/uploads/2019/05/gsr_2020_full_report_en.pdf>. Acesso em 20 de maio de 2021.
- [10] Pereira, E. B. et al. **Atlas brasileiro de energia solar.** 2.ed. São José dos Campos: INPE, 2017. p.12.
- [11] **Dados da geração solar fotovoltaica no SIN.** Disponível em: <<http://www.ons.org.br/Paginas/resultados-da-operacao/boletim-geracao-solar.aspx>>. Acesso em 04 de maio de 2021.
- [12] **Matriz Elétrica Brasileira – Filtro por fonte: UFV (Usinas Fotovoltaicas) em operação.** Disponível em: <<https://bit.ly/3kLWHPg>>. Acesso em 04 de maio de 2021.
- [13] MUELLER, R. W. et al. **The CM-SAF operational scheme for the satellite based retrieval of solar surface irradiance - A LUT based eigenvector hybrid approach. Remote Sensing of Environment,** v. 113, n. 5, p. 1012-1024, 2009.
- [14] HABTE, A.; SENGUPTA, M.; LOPEZ, A. **Evaluation of the national solar radiation database (NSRDB): 1998-2015.** National Renewable Energy Lab. (NREL), Golden, CO (United States), 2017.
- [15] CHIN, V. J.; SALAM, Z.; ISHAQUE, K. **Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review.** Applied Energy, v. 154, p. 500-519, 2015.
- [16] DE AZEVEDO DIAS, C. L. et al. **Performance estimation of photovoltaic technologies in Brazil.** Renewable Energy, v. 114, p. 367-375, 2017.
- [17] HAYKIN, S. **Neural Networks and Learning Machines.** Pearson Education, 3 ed., 2008, Cap.4.
- [18] PALIWAL, M.; KUMAR, U. A. **Neural networks and statistical techniques: A review of applications.** Expert Systems with Applications, v.36. 2009.
- [19] BROWNLEE, J. **Deep learning for time series forecasting: predict the future with MLPs, CNNs and LSTMs in python.** 2019.
- [20] **ONS – GERAÇÃO DE ENERGIA.** Disponível em: <http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx>. Acesso em 11 de maio de 2021.
- [21] **SOLCAST, 2021. Solcast.** Disponível em: <<https://solcast.com/>>. Acesso em 11 de maio de 2021.
- [22] CARRASCO, J. L. G; ROMANEL, C. **Monitoramento da instrumentação da barragem Corumbá I por redes neurais e modelos de Box & Jenkins.** Rio de Janeiro, 2003. 146p. Dissertação de Mestrado – Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro, Capítulo 4.
- [23] BROWNLEE, J. **Long short-term memory networks with python: develop deep learning models for your sequence prediction problems.** 2019.