

Análise Comparativa de Modelos para Previsão de Irradiação Solar

Alexandre Maciel¹

 orcid.org/0000-0003-4348-9291

Eduardo Castilho¹

 orcid.org/0000-0001-9115-5099

Thiago Andrade¹

 orcid.org/0000-0002-7438-6036

Caroline Medeiros¹

 orcid.org/0000-0002-3514-1681

Júlio Galvão¹

 orcid.org/0000-0002-0382-1125

¹Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, Brasil. E-mail: alexandre.maciel@upe.br

DOI: 10.25286/repa.v7i2.2208

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

Como citar este artigo pela NBR 6023/2018: Alexandre Maciel; Caroline Medeiros; Eduardo Castilho; Júlio Galvão, Thiago Andrade. Análise Comparativa de Modelos para Previsão de Irradiação Solar. Revista de Engenharia e Pesquisa Aplicada, v.7, n. 2, p. 23-31, 2022.

RESUMO

Esse artigo apresenta uma análise comparativa de modelos de previsão de irradiação solar com os objetivos de avaliar os principais parâmetros que influenciam na geração de energia solar e medir a eficiência na previsão de energia solar gerada dada uma localização específica. A partir de dados extraídos de bases de dados públicas, foram transformados em séries temporais e realizado a aplicação técnicas de mineração de dados para identificar os atributos relevantes e treinar os modelos de previsão. Os modelos uma vez treinados, foram comparados utilizando métricas como RMSE (raiz quadrática média dos erros) para avaliar a eficiência e aplicabilidade para a previsão.

PALAVRAS-CHAVE: NSRDB; Mineração de Dados; Energia Solar; Modelo;

ABSTRACT

This article presents a comparative analysis of solar irradiation prediction models with the objectives of evaluating the main parameters that influence solar energy generation and measuring the efficiency in predicting solar energy generated given a specific location. From data extracted from public databases, they were transformed into time series and applied data mining techniques to identify the relevant attributes and train the forecast models. The models, once trained, were compared using metrics such as RMSE (root mean square of errors) to assess the efficiency and applicability for the prediction.

KEY-WORDS: NSRDB; Data Mining; Solar Energy; Model;

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Em função da diversificação da matriz energética e do impulsionamento pela geração de energia por meio de fontes renováveis, houve um aumento no desenvolvimento de tecnologias voltadas à produção de eletricidade de forma sustentável. Nesse contexto, o crescimento é justificado principalmente para suprimir os efeitos negativos ambientais e econômicos associados às fontes de energia convencionais [1-2].

Especificamente, de acordo com o Departamento de Energia dos Estados Unidos (DOE), as usinas fotovoltaicas fazem uso do recurso energético mais abundante no mundo: a energia solar. Além disso, a adoção da tecnologia de células solares alavancou tanto a indústria espacial, com o desenvolvimento de satélites e naves espaciais alimentados por energia solar, como também o desenvolvimento e diversificação da matriz energética dos países, através da sua implantação em residências e usinas [3].

Uma célula solar converte a energia dos fótons da luz solar em energia elétrica por meio do fenômeno fotoelétrico encontrado em certos tipos de materiais semicondutores, como silício e selênio. Eficiência de células solares depende da temperatura, insolação, características do espectro da luz solar e assim por diante [4].

Algumas das principais características do uso da energia solar são: são substitutos confiáveis a serem considerados como uma fonte de energia inovadora na construção, processos industriais e sistemas de dessalinização de água [4]. Além disso, outras variáveis técnicas e econômicas, como um desgaste lento de seus componentes, baixos custos iniciais e de funcionamento e incentivos econômicos de modo a diminuir o preço módulos fotovoltaicos [4].

O problema em questão é a dificuldade de se obter uma previsão automática, inteligente e adaptável sobre a irradiação solar em determinada região, com o intuito de identificar as melhores localizações, utilizando medições históricas da área, para se construir usinas fotovoltaicas para geração e distribuição de energia elétrica.

1.2 DESCRIÇÃO DO PROBLEMA

A geração de energia renovável não é totalmente previsível devido à influência de fatores ambientais (e.g. fenômenos naturais, tempo, clima e temperatura). Isso faz com que a quantidade de eletricidade coletada sofra variações periodicamente. Então é necessário estimar a quantidade de potência que pode ser gerada no futuro para que haja um balanceamento da matriz energética, a fim de identificar a necessidade de possíveis expansões, manutenções ou construções de usinas e evitar faltas de abastecimento [2-7].

A energia de sistemas de backup faz bastante sentido por ser abundante e limpa. Geradores a diesel ou gasolina, além de serem extremamente poluentes, ainda trazem o incômodo dos altos ruídos produzidos, sendo assim, não apropriados para uso residencial. Regiões com maior índice de radiação são propícias para criação de usinas de energia [8].

Compreender o comportamento espacial e temporal dos recursos solares é fundamental para a tomada de decisões em relação ao projeto ideal de sistemas de conversão de energia solar e para a decisão das localizações mais propícias para construir estações fotovoltaicas, contribuindo para um melhor aproveitamento da energia solar [2]. Segundo a Associação Brasileira de Energia Solar Fotovoltaica (ABSOLAR), mesmo com o cenário de pandemia da COVID-19, no Brasil, a potência de geração solar fotovoltaica cresceu 1GW entre Janeiro e Maio de 2020, totalizando uma marca de 5,5 GW

1.3 OBJETIVOS

Avaliar os principais indicadores de irradiação e meteorológicos utilizados em estações fotovoltaicas e realizar um estudo comparativo entre os modelos de previsão MLP (Multi Layer Perceptron) e LSTM (Long Short Term Memory). Destacam-se os objetivos específicos:

- Estudar os algoritmos de predição em séries temporais escolhidos que são os mais usados na literatura;
- Realizar análise comparativa entre os modelos escolhidos sobre o conjunto de dados de irradiação solar;

2 ESTADO DA ARTE

Esta seção trata da área de negócio do estudo bem como os trabalhos relacionados.

2.1 ÁREA DE NEGÓCIO

Radiação é a energia liberada pelo Sol, principalmente sob forma de ondas eletromagnéticas. Já a irradiância é o valor instantâneo da radiação solar incidente (W/m^2) [9]. Parte da radiação é vista em forma de luz, outra parte foge do espectro que conseguimos perceber visualmente, mas sentimos seus efeitos, são os raios infravermelhos (IV) e os ultravioletas (UV). Parte da radiação emitida pelo Sol é refletida (pelas nuvens, pelo gelo, pelos oceanos), perdida por difusão ou absorvida por moléculas de oxigênio e ozônio da atmosfera. No entanto, mais de 50% chega à superfície, e é essa fração de radiação que chega à superfície que nos interessa [6].

Irradiação é a propagação de energia sem a necessidade de meio material. É a quantidade de radiação solar em determinado intervalo de tempo. Geralmente, é medida em watt por hora por metro quadrado (Wh/m^2). O Brasil é um dos países com maior incidência de raios solares ao ano, especialmente os estados da região Nordeste, que apresentam os maiores valores de irradiação solar global (relação entre maior média e menor variabilidade). A média no país fica entre $4.500 Wh/m^2$ e $6.300 Wh/m^2$, de acordo com dados do Atlas Brasileiro de Energia Solar [6].

O processo da energia solar para produção de energia (chamado de efeito fotovoltaico) utiliza placas solares produzidas em material semicondutor para, quando as partículas de luz solar (fótons) incidirem, os elétrons do material semicondutor entrarem em movimento, gerando eletricidade. A energia solar é gerada pelas placas solares e levada ao inversor solar, equipamento responsável por transformar a corrente elétrica contínua em alternada e, então, ser distribuída para o local de consumo e utilizada pelos equipamentos [10].

Para realizar previsões acerca do comportamento da irradiação solar em determinada região, são utilizados alguns coeficientes de irradiação presentes na literatura. O artigo [11] faz uso dos indicadores GHI (Global Horizontal Irradiation - Irradiação Global Horizontal), índice de claridade (Clearness Index) e índice de céu claro (Clear Sky Index - CSI) medidos periodicamente

para criar séries temporais e prever a irradiação em determinado ponto. Já no trabalho [12], é criado um modelo de Regressão de Processo Gaussiano (Gaussian Process Regression - GPR) para realizar previsões sobre o GHI.

Destaca-se também a pesquisa [13], em que é criado um sistema de Predição Numérica do Tempo (Numerical Weather Prediction - NWP) capaz de estimar os indicadores GHI e DNI (Direct Normal Irradiation - Irradiação Direta Normal). Além disso, o artigo também evidencia que o parâmetro GHI é o mais importante quando se deseja obter uma maior eficiência na produção de eletricidade em usinas fotovoltaicas.

2.2 TÉCNICAS DE PREVISÃO

Nessa seção são descritas as técnicas de previsão utilizadas para realizar a análise de desempenho dado um conjunto de dados como entrada das respectivas técnicas.

2.2.1 MLP

Redes neurais MLP consistem em unidades de neurônios organizadas em camadas. Cada camada é composta por neurônios e a rede é totalmente conectada, considerando que cada neurônio conecta-se a todos os neurônios nas camadas subsequentes. Cada MLP é composta por no mínimo três camadas, consistindo de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A camada de entrada distribui as entradas para camadas subsequentes. Os neurônios de entrada têm funções de ativação linear e sem limites. Os neurônios da camada oculta têm funções de ativação não lineares e as saídas têm funções de ativação linear. Portanto, cada sinal de alimentação no neurônio em uma camada subsequente é um resultado da entrada original multiplicado por um peso com um limite adicionado e, em seguida, passa por uma função de ativação que pode ser linear ou não linear [14].

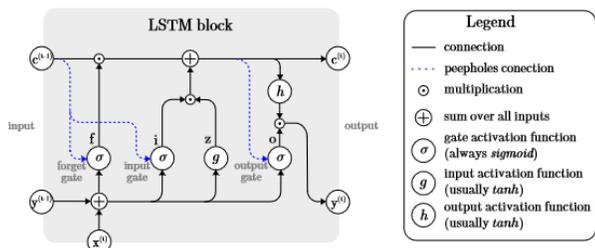
2.2.2 LSTM

O modelo LSTM é um poderoso sistema neural recorrente especialmente projetado para superar os problemas de gradiente de explosão ou desaparecimento que normalmente surgem ao aprender dependências de longo prazo, mesmo quando os atrasos mínimos são muito grandes.[15]

A arquitetura LSTM consiste em um conjunto de sub-redes conectadas recorrentemente, conhecidas

como blocos de memória. A ideia por trás do bloco de memória é para manter seu estado ao longo do tempo e regular o fluxo de informações, através de unidades de portas não lineares. A **Figura 2** mostra a arquitetura de um bloco LSTM original, que envolve as portas, o sinal de entrada $x(t)$, a saída $y(t)$, as funções de ativação e as conexões de olho mágico. A saída do bloco é conectada de forma recorrente de volta para a entrada do bloco e todas as portas [15].

Figura 2 - Arquitetura de um bloco LSTM original típico.



Fonte: [15].

2.3 TRABALHOS RELACIONADOS

Como trabalhos relacionados destacamos o artigo [16], que investiga como o desempenho de um módulo fotovoltaico (PV) varia em escala continental. Nele, é mostrada como a eficiência de células fotovoltaicas pode variar de acordo com alguns parâmetros, como por exemplo a refletividade da superfície do módulo, espectro da luz solar, temperatura do módulo PV e intensidade da luz. Assim, diferentemente do nosso problema proposto, o trabalho objetivou elucidar a influência de fatores externos em células PV para garantir um bom desempenho na geração de energia.

Em relação às bases de dados que tratam de energia solar, o artigo [17] percebeu que a maioria dos conjuntos de dados solares vêm de fontes heterogêneas e autônomas. Sendo assim, é proposto realizar uma unificação desses dados, através da criação de um novo pacote na linguagem de programação R, chamado SolarData, para facilitar o acesso a alguns conjuntos de dados solares disponíveis publicamente. Além disso, são apresentados exemplos de uso dos datasets e suas respectivas descrições. A primeira versão do pacote contém os seguintes conjuntos de dados: (1) NREL physical solar model version 3; (2) NREL Oahu solar measurement grid; (3) NOAA surface radiation network; (4) SoDa Linke turbidity factor; e (5) NASA shuttle radar topography mission.

No trabalho [18] foi realizada a análise dos dados de produção da micro rede do IPB (Instituto

Politécnico de Bragança) de sistemas solar fotovoltaicos que correlaciona dados de irradiação com meteorológicos para a construção de modelos de previsão da produção mais fiáveis, além de fazer previsão de produção de energia elétrica obtendo bom desempenho a curto e médio prazo permitindo balancear o fluxo de energia da micro rede.

Na pesquisa [19] uma rede LSTM é aplicada para previsão de dados de geração (tensão e corrente) em painéis fotovoltaicos a partir da utilização de dados meteorológicos chegando a obter um erro médio absoluto menor do que 1%, tanto para a corrente quanto para a tensão.

3 MATERIAIS E MÉTODOS

Esta seção trata da descrição dos dados utilizados no estudo, o pré-processamento realizado e a metodologia aplicada.

3.1 DESCRIÇÃO DA BASE DE DADOS

Lançado ao público como parte da Iniciativa de Dados de Energia Aberta do Departamento de Energia, o Banco de Dados Nacional de Radiação Solar (NSRDB) é uma coleção completa em série de valores a cada meia hora das três medições mais comuns de radiação solar - irradiância global horizontal (GHI), direta normal (DNI) e horizontal difusa (DHI) - e dados meteorológicos. Estes foram coletados sobre os Estados Unidos e regiões dos países vizinhos formando um apanhado dos últimos 23 anos [20].

Estes dados podem ser coletados por meio de medições em solo ou por sensoriamento remoto via satélite. Piranômetros e pireliômetros, que usam detectores termoeletrônicos ou fotoeletrônicos, são os radiômetros terrestres mais comuns para medir GHI e DNI, respectivamente. Outra forma é usar informações de satélites meteorológicos geoestacionários que fornecem estimativas de radiação solar contínua que cobrem um amplo espectro de escalas temporais e espaciais [20].

Além disso, a base de dados ainda conta com outras medições importantes como irradiância horizontal difusa (DHI), velocidade do vento, direção do vento, precipitação de chuva, umidade relativa, temperatura e pressão que podem ser úteis para a resolução do problema apresentado. O Quadro 1 descreve a medição GHI, alvo do estudo, já o Quadro 2 apresenta informações que auxiliam na localização das medições.

Quadro 1 - Descrição da medição GHI da base de dados NSRDB.

Atributo	Descrição	Tipo de dado
GHI	A quantidade total de radiação recebida de cima por uma superfície horizontal. Este valor inclui irradiação normal direta (DNI) e irradiação horizontal difusa (DHI). Aplicação: <ul style="list-style-type: none"> • Instalações FV fixas • Comparações com bases de dados solares para realizar avaliações MCP (Medir Correlação Predict) 	Double

Fonte: Os Autores.

Quadro 2 - Dados auxiliares de localização das medições.

Atributo	Descrição	Tipo de dado
Location ID	Identificador do ponto escolhido para coleta dos dados	Integer
City	Cidade de onde foi retirada a medição	Varchar
State	Estado de onde foi retirada a medição	Varchar
Country	País de onde foi retirada a medição	Varchar
Latitude	Latitude do ponto de medição	Double
Longitude	Longitude do ponto de medição	Double
Elevation	Elevação do ponto de medição	Double
Local Time Zone	Fuso horário local de onde foi retirada a medição	Integer

Fonte: Os Autores.

3.2 PRÉ-PROCESSAMENTO DOS DADOS

A base de dados NSRDB já é minimamente pré-processada, não sendo necessário o tratamento em relação a dados nulos ou mal formados. Para a execução do experimento, foram consideradas observações do ano de 2020, com intervalos de 1 hora, para a Usina Fotovoltaica Ponta da Pedra (latitude -7,993900 e longitude -38,623660), localizada em São José Do Belmonte - PE.

De posse dos dados, alguns passos para o pré-processamento foram tomados:

- Normalização de dados;
- Filtro dos atributos não utilizados;
- Agrupamento das observações por média diária;
- Organização do conjunto de dados em janelas para treinamento dos modelos.

3.3 ANÁLISE DESCRITIVA DO CONJUNTO DE DADOS

A análise descritiva foi feita sobre o conjunto de dados de GHI agrupado por média de observações diárias, pois o estudo comparativo será realizado a partir dele. Primeiramente são apresentadas as estatísticas descritivas do *dataset*, em seguida são mostrados gráficos para expor o comportamento dos valores de irradiação a serem utilizados pelos modelos durante o experimento.

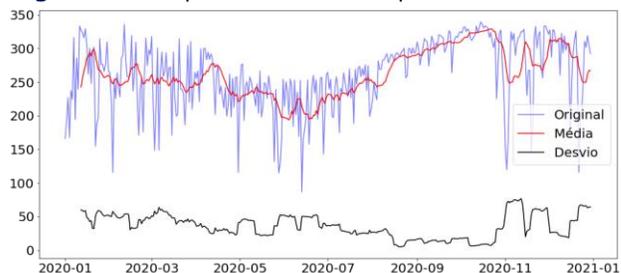
Quadro 3 - Estatísticas descritivas das medições de GHI.

Estatística	GHI
Contagem	365,0
Média	262,9
Desvio padrão	51,1
Mediana	267,0
Mínimo	86,5
Máximo	339,4

Fonte: Os Autores.

De acordo com o **Quadro 3**, o conjunto é composto por 365 elementos, que são as médias diárias de GHI. O valor médio das medições é de 262,9, com desvio padrão 51,1. Os valores têm amplitude de 252,9, variando entre 86,5 e 252.9. A mediana observada é de 267.

Figura 3 - Comportamento do GHI para o ano de 2020.

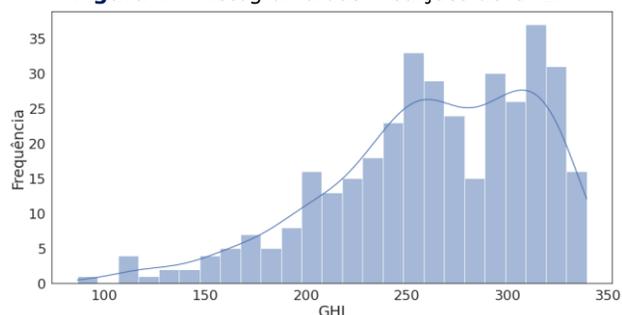


Fonte: Os Autores.

A **Figura 3** demonstra o comportamento do GHI diário para a localização e o ano escolhidos. Os

valores médios e de desvio padrão são calculados a partir de janelas móveis, considerando as estatísticas de 12 dias anteriores a cada data. Percebe-se uma periodicidade quando os valores de GHI atingem os mínimos. Durante os meses de julho e novembro ocorre um aumento na irradiação.

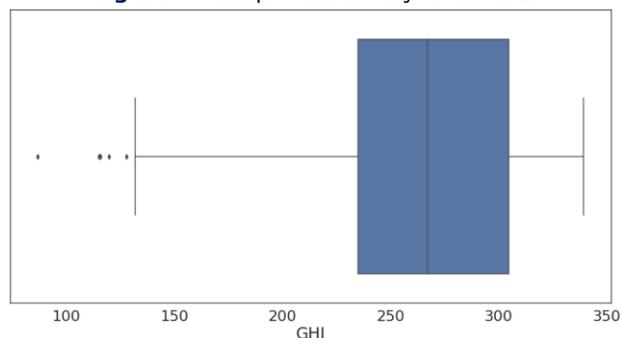
Figura 4 - Histograma das medições de GHI.



Fonte: Os Autores.

O histograma da **Figura 4** foi dividido em 25 faixas de valores, que parte do valor mínimo observado até o máximo. São calculadas as frequências de cada um dos intervalos para exibição. Além disso, a linha representa a estimativa de densidade dos dados. O gráfico evidencia que há uma presença mais frequente de valores médios diários do GHI acima de 200.

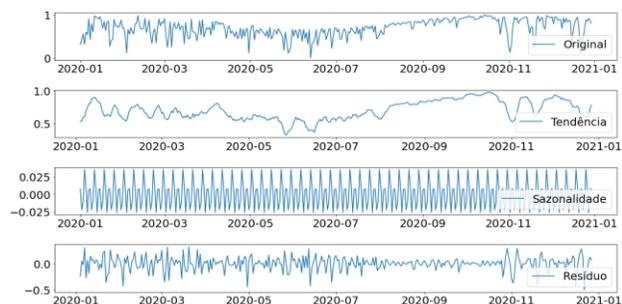
Figura 5 - Boxplot das medições de GHI.



Fonte: Os Autores.

Através da **Figura 5**, é possível visualizar a distribuição dos dados do experimento. No boxplot, são condensados os comportamentos das estatísticas descritivas de uma maneira visual. Podemos evidenciar que as medições não estão simetricamente distribuídas e que os valores acima da mediana estão mais condensados do que os abaixo. Também é mostrado que há indício de *outliers* próximos aos valores mínimos.

Figura 6 - Decomposição da série temporal.



Fonte: Os Autores.

Por fim, para avaliar o comportamento da série temporal do experimento, é necessário fazer uma decomposição para encontrar os componentes de tendência, sazonalidade e resíduo. A **Figura 6** mostra o resultado da decomposição da série, realçando que há uma sazonalidade semanal nos dados e tendência de aumento entre os meses julho e novembro de 2020.

3.4 MODELOS DE PREVISÃO

Através da linguagem de programação Python, construiu-se implementações dos modelos MLP e LSTM para realizar a análise comparativa. Nas seções seguintes é descrito os passos necessários para a implementação dos respectivos modelos.

3.4.1 MLP

Antes de definir o modelo de MLP se fez necessário a adaptação do processo de treinamento para uma série temporal, definindo um tamanho de janela para a quantidade de entradas a serem analisadas para o treinamento da rede neural.

Como forma de solucionar a perda de observações após o agrupamento da série em janelas, utilizou-se os últimos dados de treinamento para povoar o conjunto de validação.

Após esse passo, o processo de escolha de lags correlacionados e estatisticamente significativos através dos correlogramas.

Após a modelagem do conjunto de dados, é executada uma busca por hiperparâmetros a fim de encontrar uma combinação que minimize a métrica de desempenho escolhida na análise. Os seguintes parâmetros foram utilizados no algoritmo de *grid search*:

- quantidade de camadas escondidas: [5, 10, 20, 30, 40, 50, 100];
- função de ativação: ['tanh', 'logistic', 'relu']
- modelo solucionador: ['lbfgs', 'sgd', 'adam']

- quantidade máxima de execuções: [1000, 5000, 10000]

A partir da biblioteca sklearn, da função **MLPRegressor** é construído o treinamento para modelo MLP de previsão com os respectivos parâmetros assim como o método de cálculo das métricas de previsão da série temporal de entrada.

3.4.2 LSTM

A partir da biblioteca keras da linguagem de programação Python e de alguns métodos previamente construídos para o treinamento do modelo MLP como os métodos da janela temporal e da seleção de lags foi possível a criação do método de construção do modelo LSTM, para as métrica de desempenho escolhida na análise. Os seguintes parâmetros foram utilizados no algoritmo de *grid search*:

- modelo solucionador: ['adam']
- quantidade máxima de execuções: [10, 50, 100]

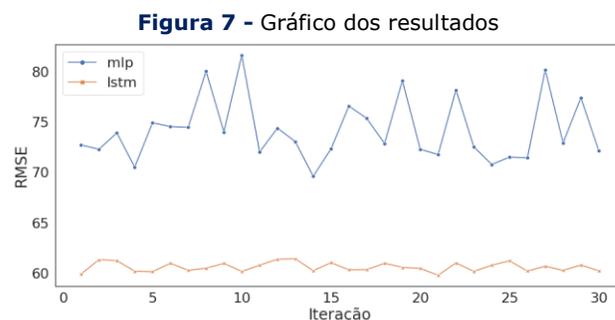
3.5 METODOLOGIA EXPERIMENTAL

A análise comparativa é dividida em duas etapas. A primeira compreende o pré-processamento inicial dos dados e a estimação dos melhores parâmetros dos modelos através de uma busca sobre várias combinações de hiperparâmetros. A segunda etapa realiza a repetição do processo de treinamento e teste dos algoritmos por 30 execuções a fim de avaliar o desempenho de cada um, através da métrica RMSE - *Root Mean Square Error* (raiz quadrada do erro-médio). Nessa etapa, é feita também a transformação e a normalização dos dados para a execução das técnicas, o cálculo do Teste U de Mann-Whitney para definir se há semelhanças entre os resultados obtidos e a exibição dos gráficos de desempenho sobre cada repetição. Para o teste estatístico, assume-se a hipótese nula H_0 de que os modelos são equivalentes e a hipótese alternativa H_1 afirma que há diferenças entre os modelos. É usado o nível de significância $\alpha = 0,05$.

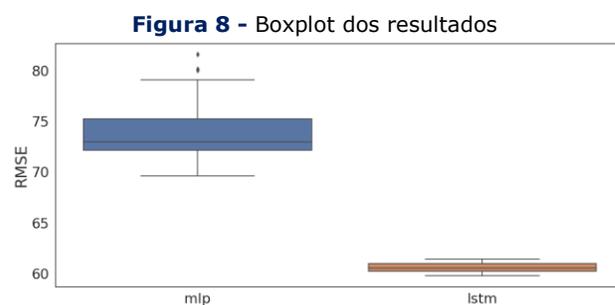
4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1 RESULTADOS

Utilizando as bibliotecas scipy e seaborn, os resultados obtidos com a utilização dos modelos MLP e LSTM em 30 execuções para o RSME para previsão de GHI são os seguintes:



Fonte: Os Autores.



Fonte: Os Autores.

Quadro 4 - RMSE médio da avaliação dos modelos.

Algoritmo	RMSE
MLP	$7,416.10^1 \pm 3,050.10^0$
LSTM	$6,059.10^1 \pm 4,528.10^{-1}$

Fonte: Os Autores.

Como forma de validar a comparação entre os valores médios obtidos, aplicou-se o Teste U de Mann-Whitney para determinar o grau de similaridade entre as observações de cada modelo. Com o resultado do $p - valor = 1.510 \cdot 10^{-14}$ e grau de significância $\alpha = 0,05$, devemos rejeitar a hipótese nula H_0 pois existem diferenças entre os modelos.

4.2 DISCUSSÃO

A **Figura 7** apresenta o valor de RMSE por cada iteração do processo de análise comparativa. O MLP é representado pela linha superior (azul) e o LSTM pela linha inferior (laranja). Percebe-se que o algoritmo MLP possui uma amplitude de valores superior ao LSTM e também ao comparar ponto a ponto, o MLP apresenta um erro maior em todas execuções.

A **Figura 8** reflete o mesmo comportamento visto no gráfico de linha dos resultados: o algoritmo MLP apresenta uma variação maior, devido à maior amplitude do seu boxplot e também um erro superior quando comparado ao LSTM. Também podemos citar que a variação do modelo MLP gerou outliers, o que não é visto no LSTM.

Como forma de sumarizar os resultados, o **Quadro 3** apresenta os valores médios de RMSE para as 30 repetições do processo de avaliação de cada técnica. Sendo assim, destacamos que tanto o RMSE médio do LSTM é inferior ao do MLP como também o desvio padrão, o que valida o comportamento mostrado pelos gráficos de resultados.

Além disso, o teste estatístico atua como suporte à conclusão do experimento, já foi evidenciada uma diferença estatística entre as observações dos algoritmos, justificando a existência de uma melhor técnica.

5 CONCLUSÕES

O objetivo deste artigo foi comparar o desempenho entre algoritmos de previsão em séries temporais MLP e LSTM, sobre um conjunto de dados de medições de irradiação GHI no ano de 2020 na usina fotovoltaica de São José do Belmonte. O estudo foi motivado pela ideia de comparar modelos de aprendizagem de máquina voltados à séries temporais presentes na literatura.

Os algoritmos foram avaliados sobre conjunto de dados normalizado e agrupado por dia. No total foram realizadas 30 execuções de treinamento e teste para analisar o comportamento médio das técnicas. Após a execução do experimento, a diferença entre os RMSE médios obtidos foi da ordem de grandeza 10^1 em favor do LSTM. Em seguida, o Teste U de Mann-Whitney indicou que houve diferença estatística significativa entre as observações da métrica de desempenho escolhida.

Através da análise realizada, conclui-se que o LSTM obteve um melhor desempenho, demonstrando um valor médio e variação de RMSE inferiores aos do MLP. Isso indica que o LSTM possui uma precisão maior para a tarefa de previsão de irradiação solar do tipo GHI.

5.1 TRABALHOS FUTUROS

Dentre as aplicações futuras para os modelos apresentados, pode-se destacar:

- Criação de uma API para a consulta de previsão de energia solar gerada para uma localidade específica por um período de tempo;
- Melhorias nos ajustes de parâmetros dos modelos objetivando melhores métricas de desempenho para a previsões.

REFERÊNCIAS

- [1] Thai-Ha Le, Canh Phuc Nguyen, Donghyun Park, **Financing renewable energy development: Insights from 55 countries**, Energy Research & Social Science, Volume 68, 2020, 101537, ISSN 2214-6296, <https://doi.org/10.1016/j.erss.2020.101537>.
- [2] Perera K.S., Aung Z., Woon W.L. (2014) **Machine Learning Techniques for Supporting Renewable Energy Generation and Integration: A Survey**. In: Woon W., Aung Z., Madnick S. (eds) Data Analytics for Renewable Energy Integration. DARE 2014. Lecture Notes in Computer Science, vol 8817. Springer, Cham. https://doi.org/10.1007/978-3-319-13290-7_7.
- [3] DOE - UNITED STATES DEPARTMENT OF ENERGY. **Top 6 Things You Didn't Know About Solar Energy**. 2021. Disponível em: <<https://www.energy.gov/articles/top-6-things-you-didnt-know-about-solar-energy>>. Acesso em: 24 de julho de 2021 às 22h21.
- [4] S. Mekhilef, R. Saidur, A. Safari. **A review on solar energy use in industries**. 2021. Disponível em: <<https://www.sciencedirect.com/journal/renewable-and-sustainable-energy-reviews/vol/15/issue/4>>
- [5] CASARIN, RICARDO; Mercado Solar Brasileiro Já Cresceu 1 Gw Em 2020, Diz Absolar. **Portal Solar**, 2021. Disponível em: <<https://www.portalsolar.com.br/blog-solar/energia-renovavel/mercado-solar-brasileiro-ja-cresceu-1-gw-em-2020-diz-absolar.html>>. Acesso em: 22 de julho de 2021.
- [6] Você Sabe O Que É Irradiação Solar? Entenda Como É Possível Gerar Energia Fotovoltaica Mesmo Em Dias Nublados. **Quantum**, 2021. Disponível em: <<https://www.quantumengenharia.net.br/irradiacao-solar-dias-nublados/>>. Acesso em: 22 de julho de 2021.
- [7] Babatunde, OM, Munda, JL, Hamam, Y. **A comprehensive state-of-the-art survey on**

- power generation expansion planning with intermittent renewable energy source and energy storage.** Int J Energy Res. 2019; 43: 6078– 6107. <https://doi.org/10.1002/er.4388>.
- [8] Brum, Thiago Santos. **Projeto De Uso De Energia Fotovoltaica Como Fonte Emergencial. Projeto de Graduação do Curso de Engenharia Elétrica.** UFRJ. 2013. Disponível em: <<http://repositorio.poli.ufrj.br/monografias/monopoli10006178.pdf>>. Acesso em: 22 de julho de 2021.
- [9] Diferença Entre Irradiância E Irradiação. **Energês**, 2020. Disponível em: <<https://energes.com.br/fale-energes/diferenca-de-irradiancia-e-irradiacao/>>. Acesso em: 25 de julho de 2021.
- [10] Energia Fotovoltaica. **Portal Solar**, 2021. Disponível em: <<https://www.portalsolar.com.br/energia-fotovoltaica.html>>. Acesso em: 22 de julho de 2021.
- [11] Gordon Reikard, Clifford Hansen, **Forecasting solar irradiance at short horizons: Frequency and time domain models**, Renewable Energy, Volume 135, 2019, Pages 1270-1290, ISSN 0960-1481, <https://doi.org/10.1016/j.renene.2018.08.081>.
- [12] Hanany Tolba et al. **GHI forecasting using Gaussian process regression: kernel study.** IFAC-PapersOnLine. Volume 52. Issue 4. 2019. Pages 455-460. ISSN 2405-8963. <https://doi.org/10.1016/j.ifacol.2019.08.252>.
- [13] Francis M. Lopes et al. **Short-term forecasts of GHI and DNI for solar energy systems operation: assessment of the ECMWF integrated forecasting system in southern Portugal.** Solar Energy. Volume 170. 2018. Pages 14-30. ISSN 0038-092X. <https://doi.org/10.1016/j.solener.2018.05.039>.
- [14] Nazzal, Jamal & El-Emary, Ibrahim & Najim, Salam. (2008). **Multilayer Perceptron Neural Network (MLPs) For Analyzing the Properties of Jordan Oil Shale.** World Applied Sciences Journal. 5. https://www.researchgate.net/publication/239580128_Multilayer_Perceptron_Neural_Network_MLPs_For_Analyzing_the_Properties_of_Jordan_Oil_Shale
- [15] Van Houdt, Greg & Mosquera, Carlos & Nápoles, Gonzalo. (2020). **A Review on the Long Short-Term Memory Model. Artificial Intelligence Review.** 53. 10.1007/s10462-020-09838-1. https://www.researchgate.net/publication/340493274_A_Review_on_the_Long_Short-Term_Memory_Model
- [16] Huld, T.; Amillo, A.M.G. **Estimating Pv Module Performance Over Large Geographical Regions: The Role Of Irradiance, Air Temperature, Wind Speed And Solar Spectrum.** Energies 2015, 8, 5159-5181. <https://doi.org/10.3390/en8065159>.
- [17] Dazhi Yang. **SolarData: An R Package For Easy Access Of Publicly Available Solar Datasets.** Solar Energy. Volume 171. 2018. Pages A3-A12. ISSN 0038-092X. <https://doi.org/10.1016/j.solener.2018.06.107>.
- [18] Dias, Artur Jorge Ferreira da Costa, **Análise de Dados para Previsão de Micro Produção de Energia Solar e Eólica.** Dissertação apresentada à Escola Superior de Tecnologia e de Gestão Instituto Politécnico de Bragança, 2015, <http://hdl.handle.net/10198/12709>.
- [19] Gabriel, Icaro & Gomes, Gustavo & Araujo, Icaro & Barboza, Erick & Vieira, Tiago & Brito, Davi. (2020). **Previsão De Geração Fotovoltaica A Partir De Dados Meteorológicos Utilizando Rede Lstm,** https://www.researchgate.net/publication/348650259_PREVISAO_DE_GERACAO_FOTOVOLT_AICA_A_PARTIR_DE_DADOS_METEOROLOGICOS_UTILIZANDO_REDE_LSTM.
- [20] Manajit Sengupta, Yu Xie, Anthony Lopez, Aron Habte, Galen Maclaurin, James Shelby, **The National Solar Radiation Data Base (NSRDB),** Renewable and Sustainable Energy Reviews, Volume 89, 2018, Pages 51-60, ISSN 1364-0321, <https://doi.org/10.1016/j.rser.2018.03.003>.