

Previsão da Irradiação Solar Fotovoltaica baseada em Deep Learning

Felipe de Sena Rodrigues* Ângelo Márcio Oliveira Sant'Anna* Daniel Barbosa** Nyegirton Barreiros dos Santos Costa***

*Departamento de Engenharia Mecânica, Universidade Federal da Bahia, Salvador-BA,
(e-mail: felipe.sena@ufba.br, angelo.santanna@ufba.br)

**Departamento de Engenharia Elétrica, Universidade Federal da Bahia, Salvador-BA,
(e-mail: dbarbosa@ufba.br)

*** Instituto Federal do Sertão Pernambucano, PE (e-mail: nyegirton.costa@if-sertao-pe.edu.br).

Abstract: The Northeast area has shown great potential for generating of solar energy in Brazil, for this reason several energy companies have evaluated the economics feasibility this kind of renewable energy. Thus, as it increases the portion of renewables sources in supply of energy is important to estimate your potential with an acceptable accuracy in distincts horizons, like hours, days, weeks, and months. This paper proposed to develop distinct *deep learning* models for forecasting the global solar irradiation. The measures were collected from a solarimetric station located in the State of Bahia. The models are evaluated through five performance metrics, and the best results were selected for the final models. Finally, Friedman statistical test and Bergmann-Hommel's *post hoc* test were applied to evaluate the hypothesis for significance difference between the developed models.

Resumo: A região nordeste tem apresentado um grande potencial de geração de energia solar no Brasil, por isso diversas empresas de energia têm avaliado a viabilidade econômica deste tipo de energia renovável. Dessa forma, conforme aumenta a parcela de fontes renováveis no fornecimento de energia é importante estimar seu potencial com uma precisão aceitável em horizontes distintos como horas, dias, semanas e meses. Este artigo propôs desenvolver modelos distintos de aprendizado profundo para previsão da irradiação solar global (W/m^2). As medições foram obtidas a partir de uma estação solarimétrica localizada no Estado da Bahia. Os modelos foram avaliados através de cinco métricas de desempenho, e os melhores resultados foram selecionadas para os modelos finais. Por fim, o teste estatístico de Friedman e o teste de Bergmann-Hommel's *post hoc* foram aplicados para avaliar a hipótese de diferença significativa entre os modelos desenvolvidos.

Keywords: artificial intelligence; deep learning; forecasting; solar radiation; photovoltaic energy.

Palavras-chaves: inteligência artificial; aprendizado profundo; previsão; irradiação solar; energia fotovoltaica.

1. INTRODUÇÃO

De acordo com o Balanço Energético Nacional de 2021, a Região Nordeste é a maior geradora de energia elétrica do país, sendo responsável por 46% do total nacional (EPE, 2020). Dentre as fontes de geração, se destacam as de origem renovável, especialmente a solar. Tal fato se deve a alta incidência de irradiação solar na região.

A energia solar no Nordeste, também possui a menor variabilidade interanual, com valores entre 5,39 e 5,59 kWh/m², estando 50% das médias anuais no intervalo de 5,43 a 5,50 kWh/m². Com essa análise da variabilidade das médias anuais dos totais diários de irradiação global horizontal ao longo dos anos de 2005 a 2015, foi observado que nessa região a estação com menor variação é o verão e a maior o inverno (INPE, 2017).

De acordo com Ruther (2004), através do efeito fotovoltaico, células solares convertem diretamente a energia do Sol em energia elétrica de forma estática, silenciosa, não-poluente e renovável. O autor acrescenta que, uma característica fundamental desses sistemas instalados no meio urbano é a

possibilidade de conexão com a rede elétrica, assim dispensando o banco de baterias. E que em sua configuração mais comum, estes sistemas permitem que quando o gerador solar fornece mais energia do que a necessária, o excesso seja injetado na rede elétrica, gerando um crédito energético, e também quando o sistema gera menos que a demanda, há o suprimento pela rede elétrica.

Atualmente, diversas empresas de energia estão avaliando a viabilidade econômica e planejando a operação de usinas solares nas Regiões Nordeste e Centro-Oeste do Brasil. Para contribuir com esse esforço, o Instituto Nacional de Pesquisas Espaciais (INPE) e várias Universidades estão trabalhando para fornecer dados científicos confiáveis sobre a avaliação da energia solar e sua variabilidade espacial e temporal (Lima *et al*, 2016).

Segundo Heinen e Fernandes (2018), conforme aumenta a parcela de fontes renováveis intermitentes no suprimento de energia elétrica, torna-se imperativo estimar com precisão a geração e o consumo de eletricidade. Desta forma, previsões em horizontes distintos reduzem as incertezas e auxiliam a operação dos sistemas elétricos, evitando

possíveis problemas de suprimento. Assim, estimativas dias à frente, por exemplo, permitem alocar sinais e reservas de energia capazes de suprir a demanda de uma cidade ou região, bem como estimativas em horizontes de 01 às 06 horas alertam para flutuações da produção e, conseqüentemente, permitem a tomada de decisões que evitem interrupções e problemas relacionados com a Qualidade da Energia Elétrica (QEE) entregue aos consumidores.

Em face a essa necessidade de previsões de geração cada vez mais precisas, diversos trabalhos foram propostos na literatura. Yadav e Chandel (2014), por exemplo, construíram uma revisão sobre as técnicas de previsão de irradiação solar usando redes neurais artificiais, sendo utilizados diferentes dados de entrada, como: a irradiação difusa, a irradiação direta e a irradiação diária.

Lorenz, Hammer e Heinemann (2004), por sua vez, realizaram a previsão da irradiação solar superficial, em um intervalo de curto prazo de 30 minutos a 6 horas, usando o método semiempírico Heliosat para derivar a radiação dos dados de satélite calculada a partir das imagens. Nos resultados verificou-se que a previsão obtida depende diretamente da hora do dia a ser estimada e que a acurácia varia de acordo com a irradiação e variabilidade dos dados.

Liu *et al.*, (2021) buscaram abordar a previsão de irradiação com uma hierarquia de quatro novos modelos físicos de persistência, utilizando mais de dez anos de medições. Os resultados mostraram que os novos modelos físicos de persistência superaram o de persistência simples e persistência inteligente, além de melhorar a previsão obtida em horizontes maiores de 1,25 horas.

O modelo denominado máquina de aprendizado extremo (ELM, do inglês, *Extreme Learning Machine*) foi utilizado para estimar a irradiação na Turquia, numa proposta multivariada na qual os dados históricos de entradas foram as características de temperatura da superfície do solo, latitude, longitude, altitude e cidades. Os resultados mostraram que em comparação a modelos tradicionais de RNAs com retropropagação, o ELM obteve um menor valor para o erro de viés médio (MBE, do inglês, *Mean Bias Error*) e raiz do erro médio quadrático (RMSE, do inglês *Root Mean Square Error*), contudo um coeficiente de determinação (R^2) maior às localizações em geral (ŞAHIN *et al.*, 2014).

Castro e Montini (2012) aplicaram o modelo SARX com 84 meses de observações, focado em equilibrar o balanço do crescimento econômico, necessidades energéticas e ampliação da oferta. O modelo possui componente sazonal e 5 variáveis exógenas ligadas à indústria, além de uma variável *dummy* sobre o reflexo em 2009 da crise econômica global para prever a demanda energética do setor no Brasil.

Verbois *et al.*, (2018), realizaram a predição da irradiação solar do dia seguinte nos trópicos com base no modelo de pesquisa e previsão do tempo (WRF, do inglês, *Weather Research and Forecasting*) com aprendizado estatístico

multivariado. O WRF-solar-PCA demonstrou um desempenho significativo comparado aos modelos de referência. Ele alcançou um RMSE e erro médio absoluto (MAE, do inglês *Mean Absolute Error*) que foram 23% e 22% menor que o modelo de persistência inteligente e 10% e 15% menor que o modelo climatológico.

Diante dos trabalhos supracitados, é possível verificar que a previsão de energia solar pode ser realizada por vários métodos, sendo agrupados primordialmente em duas grandes categorias: os modelos físicos e os modelos de aprendizado de máquina ou inteligência artificial. Desta forma, a escolha do método a ser usado depende principalmente do horizonte de previsão, uma vez que cada modelo possui sua própria precisão. Assim, existem várias abordagens para prever a irradiação solar, dependendo do tempo de previsão alvo.

Assim, este trabalho se propõe a construir e comparar através de métricas estatísticas três modelos de aprendizado profundo aplicado à previsão do histórico de irradiação solar fotovoltaica de uma estação solarimétrica situada no estado da Bahia. Além disso, os modelos são expostos aos testes não paramétricos de Friedman e de Bergmann-Hommel *post hoc* para avaliar significativamente a diferença nos resultados das medições previstas pelos modelos.

2. METODOLOGIA

Nesta seção é discutida uma visão geral sobre os tópicos teóricos que embasam a construção do projeto.

2.1. Deep Learning

Deep Learning é um ramo do aprendizado de máquinas focado na criação de largas redes neurais que são capazes de tomar decisões precisas baseadas em dados (Kelleher, 2019). Assim, essa técnica é ideal para lidar com problemas grandes e altamente complexos de aprendizado de máquina, como a classificação de bilhões de imagens, serviços de reconhecimento de fala, recomendando os melhores vídeos para assistir a milhões de usuários todos os dias, dentre outras aplicações (Géron, 2017).

Desta forma, ao invés de ensinar um computador por meio de uma lista enorme de regras para resolver o problema, é dado um modelo com o qual ele pode avaliar exemplos e um pequeno conjunto de instruções para modificar o modelo quando se comete um erro. Com isso, espera-se que ao longo do tempo, um modelo bem adequado seja capaz de resolver o problema com extrema precisão (Buduma e Lacascio, 2017). Diante dessa versatilidade, Alzahrani *et al.*, (2017) utilizaram *deep learning* na previsão da irradiação solar de curto prazo em dados de uma fazenda solar situada no Canadá. Os resultados obtidos foram comparados com outros métodos de machine learning e verificou-se que as redes do tipo *deep learning* apresentaram os menores erros de estimação.

Aslam *et al.* (2019) realizaram um estudo comparativo de modelos de *deep learning* para previsão de radiação solar no longo prazo, considerando os dados históricos de instalações de microrede localizadas na Coreia. Considerando a irradiação solar e a irradiância horizontal global de céu limpo, observou-se que as previsões foram satisfatórias. Suresh *et al.*, (2020) aplicaram a comparação entre métodos estatísticos tradicionais, como a regressão linear múltipla, e o modelo de média móvel autoregressiva (ARMA) com modelos de *deep learning* do tipo rede neural convolucional simples e híbrido. A rede simples foi do tipo multicamadas, enquanto que o método híbrido utilizou a memória de curto prazo longa. Os resultados mostraram que os modelos simples e híbridos tiveram resultados mais promissores que os tradicionais.

2.2. Métricas de Desempenho

As métricas estatísticas para avaliação do desempenho dos modelos utilizadas, foram: MAE, RMSE, R², erro médio absoluto percentual (MAPE, do inglês *Mean Absolute Percentage Error*) e contagem de variância (VAF, do inglês *Variance Accounted*). As Equações (1) à (5) ilustram as fórmulas para o cálculo das métricas de desempenho.

$$MAE = \frac{1}{n} \sum_1^n (\hat{y} - y)^2 \quad (1)$$

$$MAPE = \frac{1}{n} \sum_1^n \left| \frac{\hat{y} - y}{y} \right| * 100 \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_1^n (\hat{y} - y)^2}{n}} \quad (3)$$

$$R^2 = 1 - \frac{\sum_1^n (y - \hat{y})^2}{\sum_1^n (y - \bar{y})^2} \quad (4)$$

$$VAF = \left[1 - \frac{var(y - \hat{y})}{var(y)} \right] * 100 \quad (5)$$

Sendo n o número de previsões realizada, y o valor alvo, \hat{y} o valor estimado pela rede, \bar{y} a média das observações e var a variância.

2.3. Testes não-paramétricos

Adicionalmente às métricas supracitadas, pode-se utilizar os testes não paramétricos como uma alternativa aos paramétricos quando há falta de propriedades necessárias à sua aplicação. Sendo assim, para uma comparação que envolva mais de dois algoritmos, testes de comparações múltiplas devem ser usados. Em comparações 1 x N (um para vários), um método de controle é destacado por meio da aplicação do teste. Então, todas as hipóteses de igualdade entre o método de controle e o resto pode ser testado pela aplicação de um conjunto de procedimentos *post hoc*. Já em comparações N x N (vários para vários), considerando hipóteses de igualdade entre todos os pares de algoritmos existentes, sendo também possíveis, com a inclusão de procedimentos *post hoc* específicos à tarefa (Derrac *et al.*, 2011).

Assim, o teste de Friedman é aplicado para variáveis quantitativas ou qualitativas em escala ordinal e tem como

objetivo verificar se k amostras emparelhadas são extraídas da mesma população. Favero e Belfiore (2017) descrevem que o teste é uma alternativa à análise de variância quando os dados não seguem uma distribuição normal, como é o caso desse trabalho, ou quando a amostra for pequena.

Para corroborar com os resultados do teste de Friedman, Acosta *et al.* (2021) recomendam utilizar o teste de Bergmann-Hommel para identificar quais modelos são diferentes entre si. É importante observar que o teste *post hoc* de Bergmann-Hommel aplica um conjunto exaustivo de hipóteses, em busca de hipóteses positivas únicas ou múltiplas tornando o resultado do p -valor mais confiável, ou seja, a hipótese nula busca validar que os conjuntos comparados são iguais.

3. ESTUDO DE CASO

Nesta seção é discutido o estudo realizado, bem como as fases da previsão por meio das redes neurais sobre os dados históricos de irradiação solar global e a avaliação para medir a eficiência através das métricas de desempenho. É importante salientar que em todas as etapas do deste trabalho foi utilizada a linguagem de programação Python 3 (Python Software Foundation, 2022).

3.1. Conjunto de dados

No projeto foi utilizado um banco de dados de 398 dias de uma estação solarimétrica localizada em uma cidade do interior do Nordeste brasileiro. Cada dia de medição possui 144 amostras que representam as médias de 10 minutos de irradiação. Além disso, o banco de dados possui inúmeras características, como: a temperatura do painel, a temperatura ambiente, a umidade relativa, a pressão atmosférica, a radiação global, etc. É importante salientar que as medições são acompanhadas pelas suas variações, tais como: o valor médio, o desvio padrão, o máximo e o mínimo. Neste projeto foram utilizados apenas os dados históricos de irradiação solar global média (W/m²), que foram remodelados para um período horário.

3.2. Tratamento dos dados

Segundo Chollet (2018), o pré-processamento ou tratamento dos dados visa tornar os dados brutos mais favoráveis às redes neurais e vai além da construção de modelos preditivos. Esse processo inclui a vetorização, a normalização, a manipulação de valores faltantes e a extração de recursos. Por isso, desde a fase de tratamento de dados existem etapas que são essenciais para se chegar à previsão de modelos que conseguem descrever determinado evento.

A Tabela 1 apresenta a descrição aproximada do conjunto pelo número de dados (N), média (M), desvio padrão (Std), valor máximo (Máx), valor mínimo (Mín), 1º quartil (25%), mediana (50%) e 3º quartil (75%).

Tabela 1. Descrição dos dados.

N	M	Std	Máx	Mín	25%	50%	75%
4290	542	296	1192	13	280	538	1192

Essas medidas estatísticas são referentes ao período das 6 horas até 16 horas. Esse foi o período utilizado na previsão, pois os períodos noturnos, início da manhã e fim de tarde, possuem um potencial de irradiância baixo, conforme os *boxplots* por hora de todo o ano da Figura 3.




Fig 3. *Boxplots* das medições horárias anuais.

Outra característica estatística explorada no pré-processamento foi a extração dos *outliers*. Bruce e Bruce (2019) definem-o como qualquer valor que seja muito distante dos outros valores em um conjunto de dados. De acordo com eles, ser um *outlier* por si só não torna um valor de dado inválido ou errado, mas costumam ser o resultado de erros nos dados observados, como misturar dados de unidades diferentes ou leituras ruins de um sensor.

Rodrigues *et al.* (2021) realizaram a análise estatística do conjunto de dados utilizados neste trabalho e também visualizaram a existência dos *outliers*. Além disso, relataram que apenas o período das 16 horas seguia uma distribuição próxima à normal pelo teste de Anderson Darling e Shapiro Wilk. De acordo com Géron (2017), se algumas instâncias são claramente *outliers*, é possível simplesmente descartá-las ou tentar consertar os erros manualmente, tendo como algumas das sugestões para imputação desses dados o uso da média ou mediana. No projeto foi escolhida a média para substituição dos valores extremos.

Assim, o método analítico para a detecção de *outliers* utilizada nesse projeto é apresentado em (6) e (7). Todavia, como apenas foram visualizados *outliers* na parte inferior dos horários escolhidos para a previsão, é necessário substituir os valores com base no primeiro quartil. Salienta-se ainda que esse processo é aplicado a cada hora, para detecção horária, e qualquer valor inferior ao resultado de (6), considera-se como um provável *outlier*.

$$IQR = \text{quartil}(75\%) - \text{quartil}(25\%) \quad (6)$$

Substituindo 6 em 7, temos a equação para detectar *outliers*:

$$\text{quartil}(25\%) - 1.5 * (IQR) \quad (7)$$

Além da extração dos *outliers*, realizou-se a normalização dos dados, conforme (8). Esse método de aplicação modifica a escala dos dados para um intervalo de 0 até 1, e pode ser encontrado na biblioteca Scikit-Learn do Python 3 (Pedregosa *et al.*, 2011).

$$\frac{(X - X_{\text{mín}})}{(X_{\text{máx}} - X_{\text{mín}})} * (\text{máx} - \text{mín}) + \text{mín} \quad (8)$$

A última fase de pré-processamento representa a separação do conjunto de dados para o treino, o teste e a validação. De acordo com Chollet (2018) e Géron (2017), um balanço comum de separação são 80% para treinamento e 20% para teste. Dessa forma, foram dedicados 7008 dados à primeira e 1752 à segunda, enquanto que para a validação dos modelos foram utilizados 652.

3.3. Arquitetura das Redes

De acordo com Braga *et al.* (2000), a definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Nesta definição, fazem parte o número de camadas da rede, o número de nós por camada, o tipo de conexão entre nós e a topologia da rede, etc.

As Tabelas 2, 3 e 4 descrevem a composição de cada modelo de *deep learning* que alcançou o melhor resultado individualmente de acordo com as métricas de desempenho, sendo elas: Rede Neural de Avanço Profundo (DFF, do inglês *Deep Feed Forward*), a Memória de Curto Prazo Longa (LSTM, do inglês *Long short-term memory*) e Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*). As redes que alcançaram os melhores resultados possuíam algumas características em comum, como: a função de ativação Relu, a função de perda MSE, a função de otimização Adam e o número de épocas.

Tabela 2. Hiperparâmetros da rede DFF.

Nº de camadas ocultas	6
Nº de neurônios por camada oculta	32,16, 16, 16, 8, 4, 2
Nº de neurônios na camada de saída	1
Taxa de aprendizagem	0,005
Taxa de perda final	0,0131

Tabela 3. Hiperparâmetros da rede LSTM.

Nº de camadas ocultas	1
Nº de neurônios por camada oculta	32
Nº de neurônios na camada de saída	1
Taxa de aprendizagem	0,005
Taxa de perda final	0,0123

Tabela 4. Hiperparâmetros da rede CNN.

Nº de camadas ocultas	7
Nº de filtros na primeira camada	32
Nº de neurônios por camada oculta	32, 32, 32, 32 2, 1
Nº de neurônios na camada de saída	1
Taxa de aprendizagem	0,0005
Taxa de perda final	0,0136

4. RESULTADOS

As Tabelas 5, 6 e 7 representam as métricas de erros para os modelos de aprendizado profundo, DFF, LSTM e CNN, utilizados no trabalho, respectivamente. Espera-se que o melhor modelo tenha o menor MSE, RMSE e MAPE e VAF e R² mais próximos de 1. É possível verificar nos resultados que o modelo CNN superou ambos os concorrentes em todas as métricas, uma vez que obteve MSE, RMSE e MAPE inferior aos demais, como também VAF e R² mais próximos de 1.

Tabela 5. Métricas de desempenho dos modelos para os dados de treinamento.

Treinamento					
Modelo	MSE	RMSE	MAPE	VAF	R ²
DFF	152,2513	12,339	4,9628	0,9989	0,9981
LSTM	447,7274	21,1596	6,2312	0,9951	0,9941
CNN	98,9014	9,9449	4,1518	0,9992	0,9988

Tabela 6. Métricas de desempenho dos modelos para os dados de teste.

Teste					
Modelo	MSE	RMSE	MAPE	VAF	R ²
DFF	131,1241	11,4509	3,5502	0,9989	0,9981
LSTM	445,3267	21,1028	5,3168	0,9949	0,9943
CNN	86,474	9,2991	2,9221	0,9992	0,9990

Tabela 7. Métricas de desempenho dos modelos para os dados de validação.

Validação					
Modelo	MSE	RMSE	MAPE	VAF	R ²
DFF	155,2798	12,4611	5,0992	0,9989	0,9983
LSTM	426,9237	20,6621	6,1278	0,9958	0,9951
CNN	102,3165	10,1152	4,2819	0,9992	0,9989

As Figuras 4, 5 e 6 apresentam os gráficos de dispersão de resíduos das previsões para os modelos DFF, LSTM e CNN, respectivamente.

De acordo com Moretin e Bussab (2010), a diferença entre os dados e o modelo constitui os resíduos, conforme (9).

$$y = \hat{y} + \epsilon \quad (9)$$

sendo: y , o valor verdadeiro; \hat{y} , o valor previsto pelo modelo; ϵ e a parte aleatória (residual). Basicamente, são os resíduos que nos dizem se o modelo é adequado ou não para representar os dados. Logo, esses resíduos indicam características que as redes não aprenderam, como também variações naturais pertencentes aos dados que não puderam ser explicados pelo modelo.

Fig. 4. Resíduos do modelo DFF.


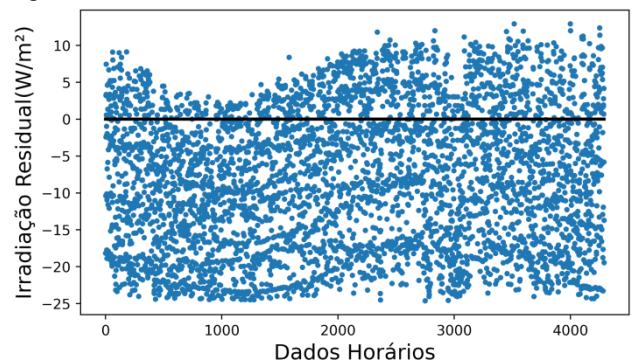


Fig. 5. Resíduos do modelo LSTM.

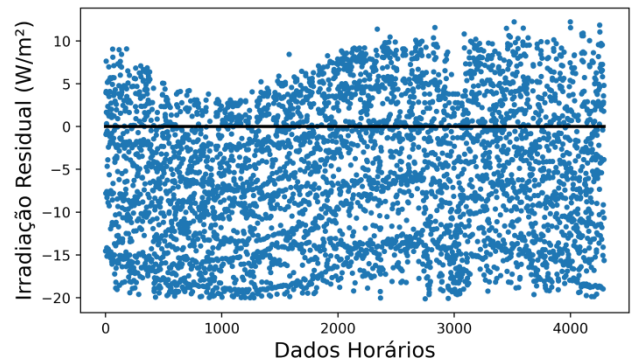


Fig. 6. Resíduos do modelo CNN.

Tendo em vista que, em um modelo ideal o resíduo de previsão seria zero em todos os pontos. Quanto mais próximo da linha, menor é o erro. Observando todos os gráficos é perceptível a assimetria dos resíduos em torno do zero, visto que existem mais valores aglomerados abaixo (DFF e LSTM) e acima (CNN).

De forma geral, as medidas de assimetria referem-se à forma da curva de uma distribuição de frequências. Para uma curva ou distribuição de frequências simétricas, a média, a moda e a mediana são iguais. Para uma curva assimétrica, a média distancia-se da moda, e a mediana situa-se em uma posição intermediária. Por outro lado, se a distribuição de frequências se concentra do lado esquerdo, de modo que a cauda à direita seja mais alongada que a cauda à esquerda, teremos uma distribuição assimétrica

positiva ou à direita média distancia-se da moda, e a mediana situa-se em uma posição intermediária (Favero e Belfiore, 2017) .

Outra medida fundamental à tomada de decisão do modelo, tendo em vista desempenhos semelhantes é observar o custo computacional dos algoritmos. Dessa forma a tabela 8 apresenta o tempo decorrido em segundos (s) para processar cada rede e suas quantidades de totais de parâmetros.

Logo, o modelo CNN também se destaca nesse quesito, tendo em vista que seu processamento foi 23,55% mais eficiente em relação ao tempo quando comparado ao DFF e 17,88% mais eficiente que o LSTM.

Tabela 8. Custo computacional

	DFF	LSTM	CNN
Parâmetros	1321	4385	4357
Tempo(s)	215,63	200,74	164,84

A Figuras 7 mostra a previsão de todas as redes em relação aos dados reais para um determinado trecho dos dados, na

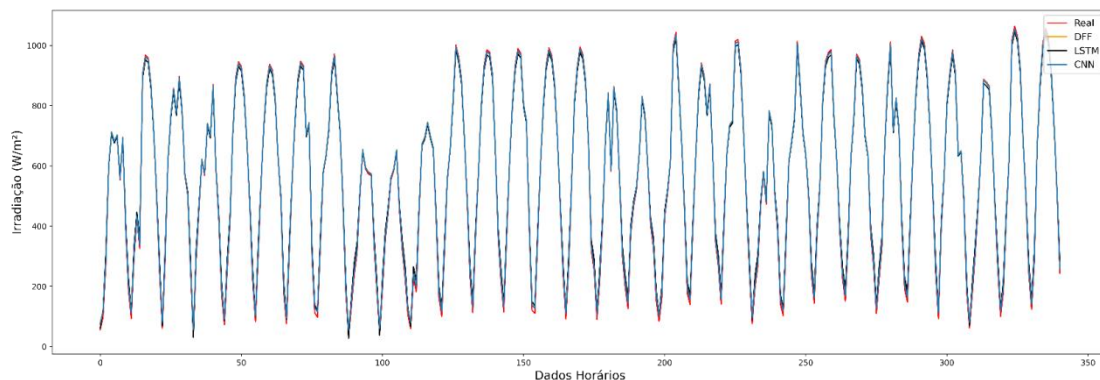


Fig 7. Previsões dos modelos de aprendizado profundo no intervalo de 1 mês.

5. CONCLUSÃO

Este trabalho visou comparar os resultados de três modelos de aprendizado profundo aplicados na previsão de dados históricos da irradiação solar global (w/m^2) de uma estação solarimétrica situada em uma cidade do interior do nordeste brasileiro.

A arquitetura do modelo CNN implementado, melhor em performance no estudo, se diferencia da abordagem típica, pois é usualmente aplicado para problemas 3D e 2D, entretanto continua sendo eficiente quando aplicado a tensores unidimensionais.

Assim, além da previsão da irradiação, foram utilizadas as técnicas de pré-processamento, para aumentar a acurácia dos resultados obtidos pelos modelos de inteligência artificial e, diversas métricas de desempenho para avaliar os modelos utilizados.

qual é possível verificar que as previsões possuem comportamentos parecidos e seguem a dinâmica das estimativas esperadas.

Adicionalmente às métricas de desempenho, foi aplicado o teste Friedman nas previsões obtidas pelos diferentes modelos utilizados, considerando que estas são distintas. Assim, o conjunto de validação foi verificado e retornou os valores de *statistics* igual a 140,956 e *p-valor* igual a 0. Estes resultados implicam que a hipótese nula é rejeitada, o que corrobora com a distinção dos três modelos.

Para verificar o resultado do teste de Friedman, também foi aplicado o teste *post hoc* de Bergmann-Hommel e observou-se quais modelos diferem entre si, ao nível de significância de 5%, conforme a Tabela 8.

Tabela 9. Resultados do teste Bergmann-Hommel.

	DFF	LSTM	CNN
DFF	---	6,09e-08	0,0001
LSTM	6,09e-08	---	1,55e-10
CNN	0,0001	1,55e-10	---

Os resultados demonstraram que os modelos propostos conseguem seguir o comportamento dos dados com uma boa acurácia, embora o modelo de convolucional tenha obtido os melhores indicadores. Esse modelo também se destacou pelo seu tempo de processamento, precisando de poucas épocas para evoluir até o resultado esperado.

Por fim, foram aplicados dois testes não paramétricos, pois a distribuição dos dados não é normal, para confirmar a hipótese de que os modelos pareados não são iguais. Após a aplicação dos testes, foi verificado que apesar dos dados de entrada serem os mesmos, existem diferenças estatisticamente significantes na comparação dos grupos, ou seja, a distribuição das previsões dos modelos DFF, LSTM e CNN não são as mesmas.

Em relação a trabalhos futuros, sugere-se a exploração de novos conjuntos de dados de irradiação solar, como também a adição de variáveis para testar o impacto nos resultados,

além da aplicação de outros modelos de aprendizado profundo para comparação com estes resultados.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) por meio do programa PIBIC / UFBA - FAPESB.

REFERÊNCIAS

- Acosta, S. M. Amoroso, A. L., Sant'Anna, A. M. O. Canciglieri, O. (2021). Predictive modeling in a steelmaking process using optimized relevance vector regression and support vector regression. *Annals of Operations Research*, 303:1-25.
- Alzahrani, A. Shamsi, P. Dagli, C. Ferdowsi, M. (2017). Solar Irradiance Forecasting Using Deep Neural Networks. *Procedia Computer Science*, 114, 304-313.
- Aslam, M., Lee, J. Kim, H. Lee, S. Hong, S. (2019). Deep Learning Models for Long-Term Solar Radiation Forecasting Considering Microgrid Installation: A Comparative Study. *Energies*, 147, 1-15.
- Braga, A. P.; Carvalho, A. P. L. F.; Ludermir, T. B. (2000). *Redes Neurais Artificiais: Teoria e Aplicações*. LTC, Rio De Janeiro.
- Bruce, P. Bruce, A. (2019). *Estatística Prática para Cientistas de Dados: 50 Conceitos Essenciais*. Starlin Alta Editora e Consultoria Eireli, Rio de Janeiro.
- Buduma, N. Lacascio, N. (2017). *Fundamentals of Deep Learning: Designing Next-Generation Machine Learning Algorithms*. O' Reilly Media, Sebastopol.
- Bussab, W. Morettin, P. (2006). *Estatística Básica*. Editora Saraiva, São Paulo.
- Castro, J. B. B. de. Montini, A. A. (2012). SARX Model Application for Industrial Power Demand Forecasting in Brazil. *Sociedade, Contabilidade e Gestão*, 7, 1-12.
- Chollet, F. (2018). *Deep Learning with Python*. Manning Publications Co, Shelter Island.
- Derrac, J. García, Salvador. Molina, D. Herrera, D. (2011). A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms. *Swarm and Evolutionary Computation*, 1, 3-18.
- EPE (2021). Balanço Energético Nacional. Empresa de Pesquisa Energética, Brasília.
- Fávero, L. P. Belfiore, P. (2017) *Manual de Análise de dados: Estatística e Modelagem multivariada com Excel, SPSS e Stata*. Elsevier Editora, Rio de Janeiro.
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn & TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, Sebastopol.
- Heinen, E. D. Fernandes, R. A. S. (2018). Redes Neurais Recorrentes Aplicadas à Previsão de Radiação Solar no Horizonte de Curto Prazo. In *Anais do Computer on the Beach*, 841-849.
- INPE. (2021). Atlas Brasileiro de Energia Solar. Instituto Nacional de Pesquisas Espaciais.
- Kelleher, J. D. (2019). *Deep Learning*. The MIT Press.
- Lima, F. Martins, F. Pereira, E. Lorenz, E. Heinemann, D. (2016). Forecast for surface solar irradiance at the Brazilian Northeastern Region Using NWP model and Artificial Neural Networks. *Renewable Energy*, 87, 807-818.
- Lorenz, E. Hammer, A. & Heinemann, D. (2004). Short term forecasting of solar radiation based on satellite data. In: *ISES Europe Solar Congress*, 1-8.
- Pedregosa, F. Varoquaux, G. Gramfort, A. Michel, V. Thirion, B. Grisel, O. Blondel, M. Prettenhofer, P. Weiss, R. Dubourg, V. Verplas, J. Passos, A. Cournapeau, D. Brucher, M. Perrot, M. Duchesnay, E. (2011). *Scikit-learn: Machine Learning in Python*. *Journal of Machine Learning Research*, 12, 2825-2830.
- Python Software Foundation. (2022). *Python.org: documentation*. Disponível em: <<https://docs.python.org/3/>>. Acesso em: 11 de fev. de 2022.
- Rodrigues, B. K. F. Gomez, M. P. Sant'anna, A. M. O. Barbosa, D. (2021). Análise Estatística da Irradiação Solar de uma Estação solarimétrica. *SBSE*, 1, 1-6.
- Rüther, R. (2014). *Edifícios solares fotovoltaicos: o potencial de geração solar fotovoltaica integrada a edificações urbanas e interligada à rede elétrica pública no Brasil*. Editora UFSC / LABSOLAR, Florianópolis.
- Şahin, M.; Kaya, Y.; Uyar, M.; Yıldırım, S. (2014). Application of extreme learning machine for estimating solar radiation from satellite data. *Int. Journal Energy Resource*, 38, 205-212.
- Suresh, V. Janik, P. Rezmer, J. Leonowicz, Z. (2020). Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. *Energies*, 723, 1-15.
- Verbois, H. Huva, R. Rusydi, A. Walsh, W. (2018). Solar Irradiance Forecasting in the Tropics Using Numerical Weather Prediction and Statistical Learning. *Solar Energy*, 162, 265-277.
- Voyant, C. Notton, G. Kalogirou, S. Nivet, M. Paoli, C. Motte, F. Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569-582.
- Liu, W. Liu, Y. Zhou, X. Xiw, Y. Han, Y. Yoo, S. Sengupta, M. Use of physics to improve solar forecast: Physics-informed persistence models for simultaneously forecasting GHI, DNI, and DHI. *Solar Energy*, 215, 252-265.
- Yadav, A. K. Chandel, S. S. (2014). Solar Radiation Prediction using Artificial Neural Network Techniques: A review. *Renewable and Sustainable Energy Reviews*, 33, 772-781.