
Sistema de estimação de irradiação solar utilizando grandezas meteorológicas e redes neurais profundas

Solar irradiation estimation using meteorological quantities and deep neural networks

Kaique Tavares

Universidade Tecnológica Federal do Paraná (UTFPR), Cornélio Procópio, PR, Brasil

E-mail: ktavares@alunos.utfpr.edu.br

Augusto Matheus dos Santos Alonso

ORCID: <https://orcid.org/0000-0002-7505-309X>

Universidade de São Paulo (USP), São Carlos, SP, Brasil

E-mail: augusto.alonso@usp.br

Wesley Angelino de Souza

ORCID: <https://orcid.org/0000-0002-3431-6359>

Universidade Tecnológica Federal do Paraná (UTFPR), Cornélio Procópio, PR, Brasil

E-mail: wesleyangelino@utfpr.edu.br

RESUMO

A produção de energia solar fundamenta-se principalmente na natureza física da radiação solar e a quantização da irradiação solar são importantes em cenários como mercados de geração e fornecimento de energia solar. No entanto, a irradiação solar não é facilmente mensurável e acessível a sensoriamento, principalmente devido a questões de custo, manutenção e requisitos técnicos de calibração. Portanto, este trabalho propõe um modelo de rede neural profunda como regressor para estimar a irradiação solar global dentro do cenário brasileiro. Para isso, foram utilizados dados do Instituto Nacional de Meteorologia do Brasil (INMET) de 304 estações meteorológicas entre 2019 e 2022, abrangendo mais de 19 milhões de dados meteorológicos horários. Os resultados apresentam a previsão dos valores medidos de seis grandezas: hora, temperatura, umidade relativa, velocidade do vento, precipitação e pressão atmosférica. Além disso, o modelo de estimação da irradiação foi validado com base no desenvolvimento e validação de uma estação meteorológica responsável por coletar dados meteorológicos locais da cidade de Cornélio Procópio, Paraná.

Palavras-chave: aprendizado profundo; irradiação solar; redes neurais artificiais; regressão;

ABSTRACT

Solar energy production primarily relies on the physical nature of solar radiation, and quantifying solar irradiation is crucial in scenarios like solar energy generation and energy markets. However, measuring solar irradiation is challenging and not easily accessible due to implementation costs, as well as maintenance and technical calibration requirements. Therefore, this study proposes the application of a deep neural network as a regressor, aiming at estimating global solar irradiation in the Brazilian context. To accomplish this, we utilized data from the Brazilian National Institute of Meteorology (INMET), collected from 304 weather stations between 2019 and 2022, encompassing over 19 million hourly meteorological records. The results demonstrate the prediction of six measured variables: time, temperature, relative humidity, wind speed, precipitation, and atmospheric pressure. Furthermore, we validated the irradiation estimation model by developing and validating a meteorological station that collects local weather data in the city of Cornélio Procópio, Paraná State, Brazil.

Keywords: deep learning; solar irradiance; artificial neural networks; regression;

INTRODUÇÃO

As fontes de energia renovável, como a solar e a eólica, ganharam destaque nas últimas décadas devido à sua capacidade de reduzir o uso de fontes de energia fósseis e minimizar o impacto ambiental (ADEDYOYIN; BEKUN; ALOLA, 2020). De acordo com dados da BP ENERGY (2021), a energia solar está aumentando sua participação na produção total de energia global, registrando um crescimento de 20% em 2020 em relação ao ano anterior. A China lidera a capacidade instalada de geração solar, representando 35,9% da capacidade global, enquanto o Brasil é responsável por 1,1%. Segundo a EPE (2014), o potencial estimado de geração fotovoltaica distribuída em edificações residenciais no Brasil é cerca de 2,3 vezes o consumo elétrico total residencial do país em 2013, evidenciando o enorme potencial da energia fotovoltaica para suprir a demanda energética do país.

A energia fotovoltaica é baseada na radiação solar (GASPARIN, 2009), e a monitoração dessa grandeza é importante em diversas aplicações, como sistemas agrícolas (ANTONOPOULOS et al., 2019) e cargas térmicas em edificações (NOTTON et al., 2019). No entanto, a radiação solar não é facilmente mensurável devido aos custos de sensores, manutenção e calibração (LIU, X. et al., 2009). Em locais onde não há coleta de dados de radiação solar, torna-se possível estimá-la por meio de equações matemáticas, bem como através de técnicas de inteligência artificial, modelos baseados em satélite, entre outras abordagens (LIU, X. et al., 2009). Em geral, estes modelos são úteis em sistemas de coleta de dados de outras grandezas, as quais podem ser combinadas em uma função matemática para a predição da radiação solar. Os parâmetros comumente utilizados incluem insolação, temperatura do ar, nebulosidade, umidade relativa do ar, altitude, latitude e o número do dia do ano, que podem ser considerados individualmente ou combinados entre si (LI et al., 2010), constituindo assim um problema de regressão (HOLMSTROM; LIU, D.; VO, 2016).

DIXON, HALPERIN E BILOKON (2020) afirmam que a regressão linear é amplamente utilizada em diversas aplicações, como preços no mercado de ações e previsão de preços de imóveis. ANTONOPOULOS et al. (2019) indicam que, para casos de regressão linear, as redes neurais profundas (DNN – *Deep Neural Network*) apresentam vantagens em relação às redes neurais tradicionais, pois são capazes de aprender a complexa relação entre as entradas e as saídas, graças à função de ativação em cada camada de neurônios.

Diante da necessidade de contribuir com a previsão da radiação solar em locais específicos dentro do espaço territorial brasileiro, este trabalho apresenta um modelo baseado em DNN para estimar a irradiação solar. Em tal modelo, utiliza-se dados provenientes de uma estação meteorológica, incluindo informações sobre temperatura, umidade, pressão atmosférica, precipitação horária e velocidade do vento. Para a construção do modelo, foram utilizados dados fornecidos pelo Instituto Nacional de Meteorologia (INMET), abrangendo o período de 2019 a 2022, e coletados por estações meteorológicas localizadas nas regiões Sul, Sudeste e Centro-Oeste do Brasil.

O objetivo principal deste estudo é utilizar essa estimativa para estabelecer um perfil de referência de radiação solar para estudos de geração fotovoltaica. Portanto, a fim de validar o modelo em situações reais, é apresentado o desenvolvimento de uma estação meteorológica e o envio dos dados coletados para um centro de processamento.

Dessa forma, a próxima seção aborda o desenvolvimento do modelo computacional para a estimativa de irradiação solar, bem como a descrição da estação meteorológica desenvolvida para este artigo.

MATERIAIS E MÉTODOS

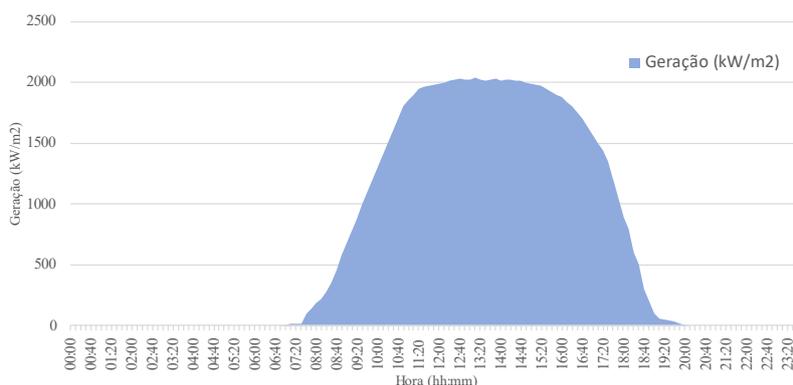
A irradiação solar

A irradiação solar é quantizada através da curva de geração fotovoltaica, a qual é definida pela relação entre a potência elétrica gerada por um sistema fotovoltaico e a densidade de potência da radiação solar incidente em uma determinada superfície, sendo expressa em kW/m^2 ou em kJ/m^2 (BUENO, 2016).

A geração fotovoltaica de energia é baseada na conversão direta da radiação solar em eletricidade por meio do efeito fotovoltaico. Os painéis solares fotovoltaicos captam a radiação solar e a transformam em corrente elétrica contínua. Ademais, a quantidade de energia elétrica gerada depende da intensidade da radiação solar que incide sobre os painéis solares. Assim, a curva de geração fotovoltaica apresenta a potência elétrica gerada pelo sistema, dada o comportamento de sua resposta perante variações na densidade de potência da radiação solar. Geralmente, a curva apresenta uma relação não linear, na qual a geração de energia aumenta à medida que a densidade de potência solar aumenta. No entanto, existe um ponto limite de eficiência no qual a geração de energia atinge seu valor máximo para as condições específicas do sistema fotovoltaico (BUENO, 2016).

A curva de geração, como apresentada na Figura 1, possibilita avaliar o desempenho de um sistema fotovoltaico, permitindo entender como a produção de energia varia ao longo do dia, da estação do ano ou de diferentes condições de radiação solar. Com base nessa curva torna-se possível dimensionar, projetar e otimizar sistemas fotovoltaicos, a fim de atender às demandas específicas de geração de energia.

Figura 1 – Curva de geração fotovoltaica.



Fonte: TAVARES; ALONSO; SOUZA (2023)

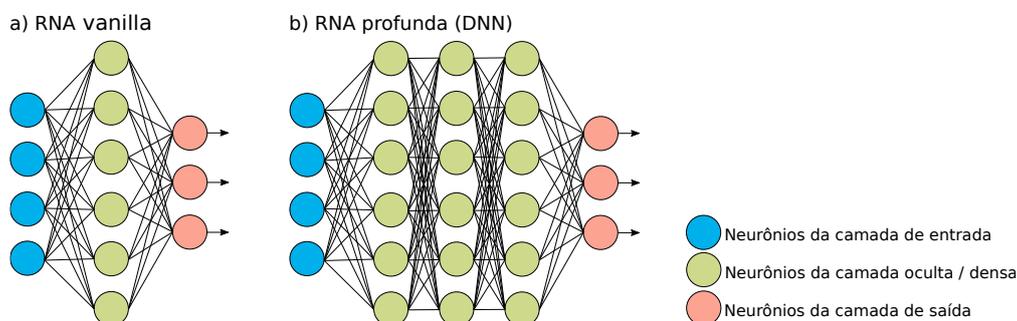
Redes neurais artificiais

As redes neurais artificiais (RNA) são modelos computacionais bioinspirados, com capacidade de representar processos complexos de aquisição, manutenção e generalização do conhecimento, utilizando a relação entre dados de entradas e saídas (BERNADINO et al., 2021). A unidade básica de uma RNA é o neurônio, sendo que as múltiplas unidades destes são interconectadas por modelos conhecidos como sinapses. Por sua vez, associa-se um valor de ajuste a tais sinapses constituintes da RNA, o qual é conhecido como fator de peso.

As primeiras RNAs foram idealizadas em 1943 (MCCULLOCH; PITTS, 1943), porém, somente a partir de 1986, com a construção de uma rede neural perceptron multicamadas (MLP - *Multilayer Perceptron*) com retropropagação (RUMELHART; HINTON; WILLIAMS, 1986), começaram a ser aplicadas em modelos práticos. Um MLP é uma arquitetura de RNA que consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, conforme apresenta a Figura 2-a). O MLP utiliza o conceito de aprendizado supervisionado chamado de retropropagação

(*backpropagation*) durante o processo de treinamento e pode distinguir dados que não são linearmente separáveis.

Figura 2 – Comparação de uma rede neural tradicional e uma rede neural profunda.



Fonte: TAVARES; ALONSO; SOUZA (2023)

Desde o marco histórico do MLP, foi introduzido o conceito chamado de aprendizado profundo (*deep learning*) devido ao avanço computacional das últimas décadas e à possibilidade de aumentar a quantidade de camadas ocultas e neurônios, conforme apresenta a estrutura da Figura 2-b). Assim, novas arquiteturas de RNAs foram construídas para diversos propósitos, como regressão, classificação supervisionada, visão computacional, reconhecimento de fala, processamento de linguagem natural e reconhecimento de áudio (KIM, 2016).

Redes neurais artificiais e estudos de previsão de irradiação solar

Pesquisas na literatura consultada apresentam técnicas voltadas à previsão de irradiação solar, como em WANG et al. (2019), o qual conduziu um estudo de previsão da radiação solar diária, comparando três arquiteturas de RNAs: MLP, rede neural de regressão generalizada (GRNN - *General regression neural network*) e rede neural de base radial (RBFNN - *Radial basis function network*). Os modelos foram desenvolvidos com base na temperatura do ar, umidade relativa, pressão do ar, pressão do vapor de água e duração da luz solar, medida em 12 estações em diferentes zonas climáticas como variáveis de entrada. Foi constatado, com base nos resultados, que os modelos MLP e RBFNN fornecem melhor precisão do que o GRNN.

BELAID e MELLIT (2016) desenvolveram um método que utiliza uma máquina de vetor de suportes (SVM) para a previsão da irradiação solar global diária e média mensal em um clima árido (Ghardaia, Argélia), tendo como entrada as grandezas de temperatura ambiente, duração máxima da luz solar e a radiação solar extraterrestre. Para

estas grandezas, o coeficiente de correlação variou de 0,894 a 0,896 e erro de previsão de cerca de 7,5%.

MEHDIZADEH et al. (2016) desenvolveram um estudo baseado em programação de expressão genética (GEP - *Gene Expression Programming*), RNA, sistema de inferência neuro-fuzzy adaptativo (ANFIS - *Adaptive neuro fuzzy inference system*) e 48 equações empíricas para estimar a radiação solar diária em Kerman, Irã. Os autores relataram que os cenários baseados em parâmetros meteorológicos e na luz solar em ANFIS e RNA apresentavam melhor precisão em comparação com os modelos empíricos.

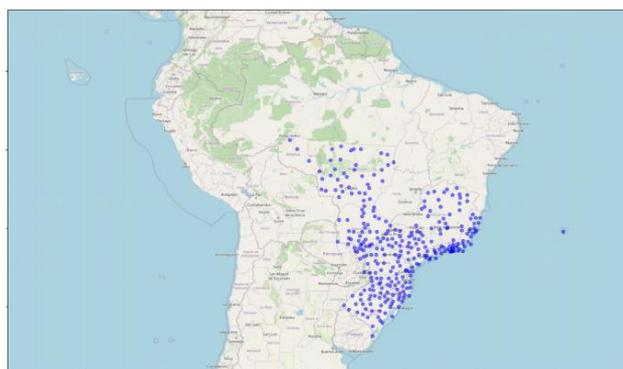
No cenário brasileiro, a aplicação de RNAs dentro deste contexto é limitada, embora alguns estudos tenham apresentado o uso de RNA para a previsão de irradiação solar focando nas regiões de Fortaleza - Ceará (SILVA et al., 2022) e Seropédica - Rio de Janeiro (OLIVEIRA; SANTOS; SILVA, 2019), com desempenho de acerto no valor de 89,7%.

Portanto, sabe-se que as RNAs apresentam capacidade significativa de prever a irradiação solar, podendo ser empregadas em estudos deste contexto. Desta forma, este estudo apresenta um modelo baseado em RNA para a estimação da irradiação solar no Brasil.

Base de dados meteorológicos

Neste projeto, foi utilizada uma DNN para estimar a irradiação solar com base em outras grandezas meteorológicas. Foram utilizados dados disponibilizados pelo Instituto Nacional de Meteorologia do Brasil (INMET), na base de dados BDMEP, constituindo um conjunto de dados horários provenientes de 304 estações meteorológicas no período de 2019 a 2022, conforme ilustrado na Figura 3 e com o formato dos dados conforme a Tabela 1.

Figura 3 – Localidade das estações meteorológicas observadas neste estudo.



Fonte: TAVARES; ALONSO; SOUZA (2023)

Tabela 1 – Composição de cada arquivo de estação meteorológica e seus atributos.

Nome	Unidade/formato
Cabeçalho	
Região do país	
UF (Unidade Federal)	
Código (WMO)	
Latitude	°
Longitude	°
Altitude	m
Data de fundação	dd/mm/aa
Dados	
Data	AAAA-MM-DD
Hora	HHMM UTC
Precipitação horária	mm
Pressão atmosférica ao nível da estação	mB
Pressão atmosférica máxima na hora anterior	mB
Pressão atmosférica mínima na hora anterior	mB
Radiação global	kJ/m ²
Temperatura do ar	°C
Temperatura do ponto de orvalho	°C
Temperatura máxima na hora anterior	°C
Temperatura mínima na hora anterior	°C
Temp. máxima do ponto de orvalho na hora anterior	°C
Temp. mínima do ponto de orvalho na hora anterior	°C
Umidade relativa do ar máxima na hora anterior	%
Umidade relativa do ar mínima na hora anterior	%
Umidade relativa do ar	%
Direção do vento	° (graus)
Rajada máxima do vento	m/s
Velocidade do vento	m/s

Fonte: TAVARES; ALONSO; SOUZA (2023)

Embora haja um total de 19.256.948 registros horários coletados, muitos deles apresentam valores ausentes ou erros de leitura. Por esse motivo, é realizada a exclusão desses dados problemáticos com o objetivo de fornecer dados de qualidade para o modelo da DNN. Em seguida, é realizado o processo de seleção de atributos por meio da análise de colinearidade (SOUZA et al., 2022), e, por fim, os dados são normalizados para aumentar a convergência do modelo baseado em DNN.

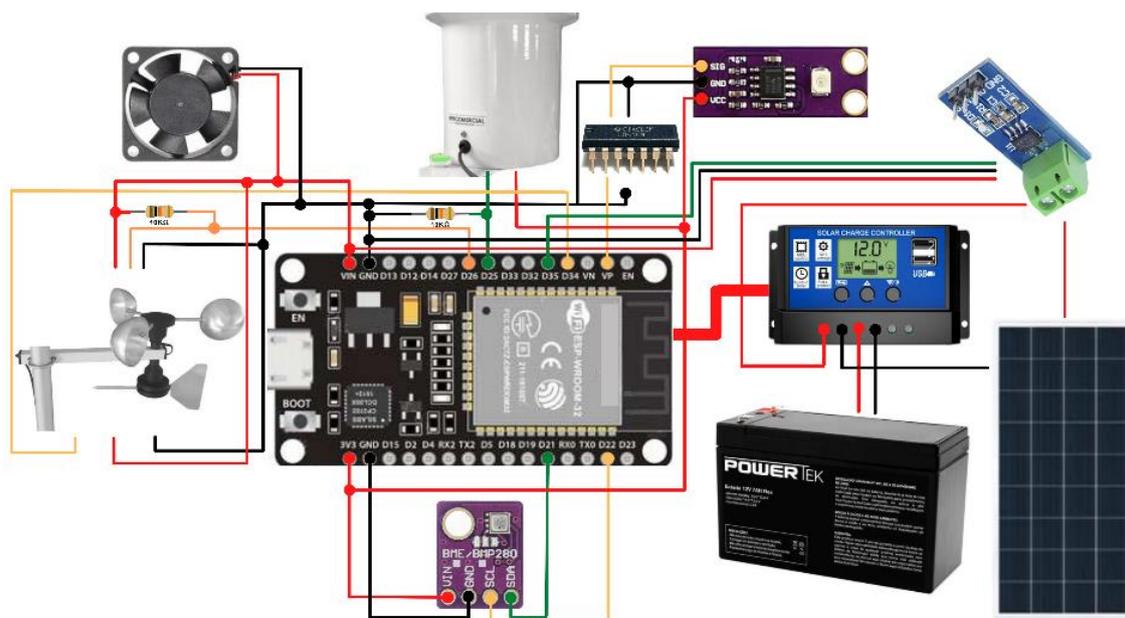
Posteriormente ao processo de treinamento e construção do modelo da DNN, foi desenvolvida uma estação meteorológica para a aquisição das grandezas, além de um software para realizar o monitoramento da estação e enviar dados a uma central na internet. Neste caso, a estação serve como dados para a validação através de um cenário não visto previamente pelo modelo da DNN. Outro aspecto é validar em uma cidade na qual não apresenta dados históricos no INMET.

Desenvolvimento de uma estação meteorológica

Para a construção da estação meteorológica, foi utilizado um aço de tubo galvanizado como base para o acoplamento dos sensores, além da plataforma computacional utilizada (denominada ESP32), a qual corresponde a um microcontrolador responsável pela aquisição e o envio dos dados medidos para a internet. Dos sensores utilizados, tem-se as grandezas de temperatura, pressão e umidade provenientes do sensor BME280, já o ANBR1 é responsável pelo sensoriamento da velocidade e direção do vento. Quanto à leitura da radiação ultravioleta, esta é feita pelo sensor GUYA-S12SD e, por fim, tem-se a precipitação monitorada pelo pluviômetro PL1. A tensão máxima de entrada dos conversores analógicos para digitais (ADC) do ESP32 é 3,3 V e a tensão máxima de saída do GUYA-S12SD é 4,3 V, isso faz com que seja necessário a implementação de um amplificador, no caso foi usado o TL084, reduzindo o sinal do sensor pela metade.

O sistema da estação meteorológica consiste na ligação entre cada sensor e o microcontrolador, além das conexões do sistema de alimentação composto pela placa solar, a bateria e o regulador de carga, com um sensor de corrente fazendo a leitura da corrente gerada pelo painel. O diagrama do hardware é representado pela Figura 4 e a Figura 5 apresenta uma foto da estação montada e em funcionamento.

Figura 4 – Integração de hardware para a estação meteorológica



Fonte: TAVARES; ALONSO; SOUZA (2023)

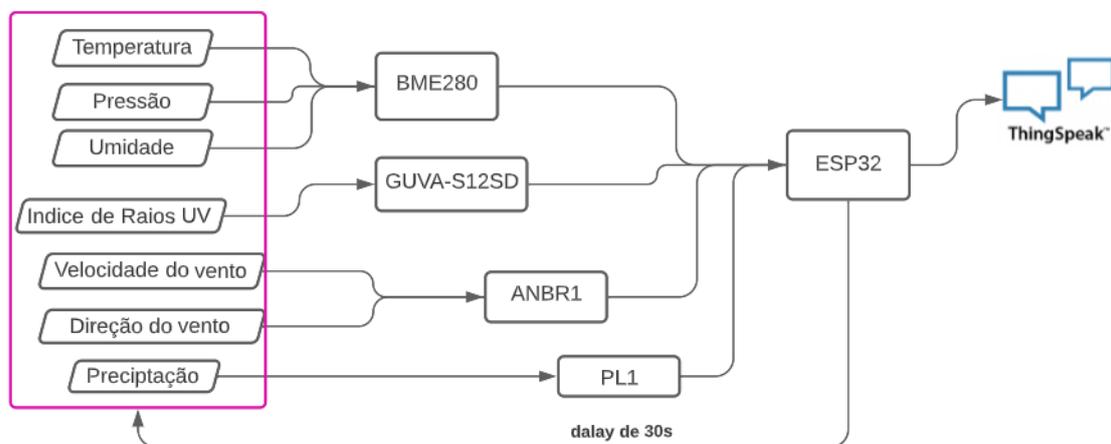
Figura 5 – Foto da instalação da estação meteorológica desenvolvida



Fonte: TAVARES; ALONSO; SOUZA (2023)

Para as conexões dos periféricos ao microcontrolador, foi utilizado uma placa de fenolite, na qual foram soldados pinos fêmeas à conexão do ESP32. Quanto à programação computacional, foi desenvolvido um código para o microcontrolador utilizando a linguagem C++ e o software Arduino IDE. O diagrama de software do sistema é apresentado na Figura 6. Os dados adquiridos são enviados via internet para a plataforma ThingSpeak, onde são armazenados gerando uma série histórica, além de permitir a visualização em tempo real dos dados. Dessa forma, a estação foi colocada em funcionamento, servindo de estudo de caso para o modelo de previsão da irradiação solar.

Figura 6 – Diagrama de software da estação meteorológica montada



Fonte: TAVARES; ALONSO; SOUZA (2023)

Dessa forma, a próxima seção apresenta os resultados da DNN, bem como a validação na estação meteorológica construída neste trabalho.

RESULTADOS E DISCUSSÕES

Os dados coletados da base do INMET foram utilizados no processo de treinamento e validação da DNN, com a arquitetura apresentada na Tabela 2. As camadas de ordem 1 e 2 possuem a função de ativação ReLU (ativação linear retificada) e a camada 3, de saída, possui a função de ativação linear, pois trata-se de um problema de regressão.

Tabela 2 – Arquitetura da DNN

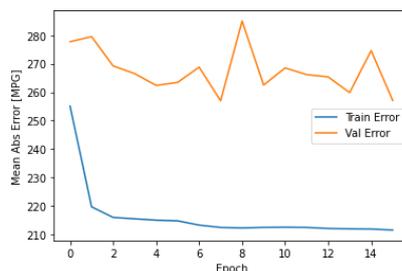
Ordem	Camada (tipo)	Neurônios	Função de ativação	Nº de parâmetros
0	Entrada	6	-	-
1	Densa	24	ReLU	168
2	Densa	24	ReLU	600
3	Saída	1	Linear	25

Fonte: TAVARES; ALONSO; SOUZA (2023)

Antes do treinamento do modelo, foi feito o processo de tratamento dos dados com o objetivo de melhorar a qualidade dos dados e desempenho do modelo de DNN. O conjunto inicial dos dados continha 22 grandezas e, após a análise por correlação, 6 grandezas (sendo elas: “precipitação horária”, “pressão atmosférica”, “temperatura”, “umidade relativa”, “velocidade do vento” e “hora”) foram consideradas relevantes para o resultado proposto. Posterior à limpeza e exclusão de dados faltantes, foi feita a normalização nos dados de entrada utilizando a técnica de normalização *min-max*.

Após 16 épocas de treinamento, o modelo apresentou convergência, conforme apresenta a curva de treinamento da Figura 7. Após o processo de treinamento do modelo da DNN, foram utilizados dois conjuntos de dados desconhecidos previamente pelo modelo. O primeiro é proveniente da estação de Cornélio Procópio - PR apresentada na Figura 2, na qual não há sensor de monitoramento da irradiação solar. O segundo conjunto de dados é de uma estação em Bauru - SP, desenvolvido pelos autores e que possui a medição da irradiação solar. Para realizar essa estimativa, apenas as 6 grandezas que fazem parte do treinamento do modelo foram utilizadas como atributos de entrada, e a irradiação solar como parâmetro de validação da estimativa.

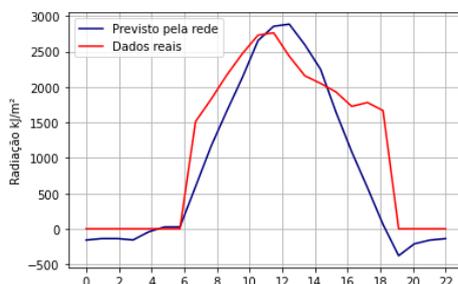
Figura 7 – Erro do treinamento do modelo



Fonte: TAVARES; ALONSO; SOUZA (2023)

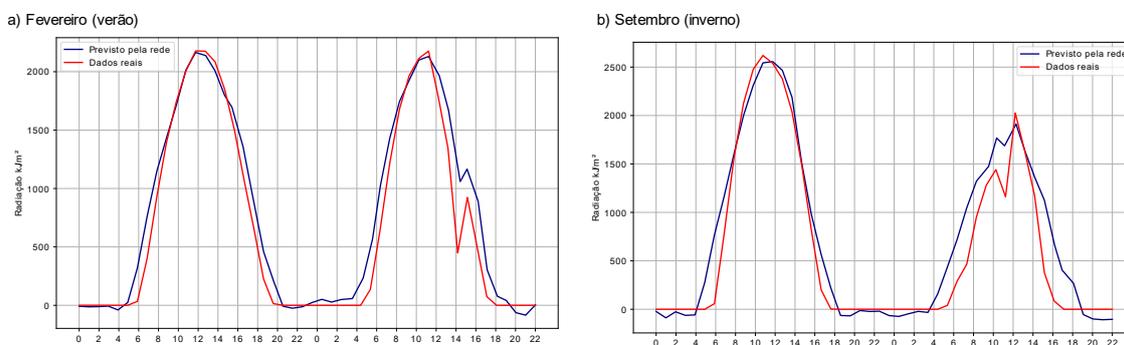
Para a estação de Cornélio Procópio, a corrente gerada pelo painel solar foi adotada como grandeza de comparação e, para a estação de Bauru, utilizou-se a própria irradiação solar monitorada pela estação. Os dados de entrada devem ser normalizados da mesma forma que os dados de treino, usando a técnica de normalização min-max. Sendo assim, a Figura 8 apresenta o resultado estimado pela rede e o cálculo da radiação a partir da leitura do sensor de corrente para a estação de Cornélio Procópio e a Figura 9 apresenta o valor estimado da radiação para os dados da estação de Bauru, comparados com a leitura do sensor de radiação da estação.

Figura 8 – Estimativa do modelo para os dados de Cornélio Procópio (dia 24/08/2022).



Fonte: TAVARES; ALONSO; SOUZA (2023)

Figura 9 – Estimativa do modelo para os dados de Bauru



Fonte: TAVARES; ALONSO; SOUZA (2023)

O modelo construído através da DNN tende a estimar adequadamente a irradiação solar utilizando grandezas meteorológicas indiretas. Observando a Figura 8, tem-se a

percepção de que a medição da corrente sendo gerada possui a mesma informação do que a irradiação estimada, mas não acompanha a curva de irradiação em sua totalidade. Pela Figura 9-a) é possível perceber que o modelo se ajustou melhor do que na Figura 9-b). Porém, verifica-se ainda que o modelo se aproxima dos valores reais medidos. Desta forma, mesmo tendo dados com tendência de irradiação semelhantes, conclui-se que é necessário considerar mais atributos, como a geolocalização e mês do ano.

CONCLUSÃO

Existem complicações técnicas e operacionais na mensuração de tal grandeza, dificultando o seu amplo uso em estudos e aplicações práticas de tempo real. Este trabalho fez a proposta do uso de uma base de dados de 304 estações brasileiras, cedidas pelo INMET, coletadas no período entre 2019 e 2022, para construir um modelo baseado em aprendizado profundo para estimar a irradiação solar. O modelo apresentou uma boa estimativa da irradiação solar, apesar de apresentar uma faixa horária maior da irradiação se comparado com os dados reais. Um possível motivo para esse problema é a sazonalidade, o modelo pode não ter identificado esse padrão. Além disso, a comparação entre os dados de Bauru foi mais precisa, pois a comparação feita entre a grandeza estimada pelo modelo é a mesma que é realizada pela estação. Já para os dados de Cornélio Procópio, a comparação é feita entre a previsão do modelo da DNN e um cálculo realizado com a leitura da corrente gerada pela placa solar, e com isso devem ser considerados ruídos na leitura, além de imprecisões nos cálculos.

Como trabalhos futuros, pretende-se agregar a geolocalização e o mês da medição ao modelo de DNN. Há também a intenção de comparar o modelo de previsão de irradiação com dados de painéis fotovoltaicos, para validar a irradiação. Por fim, pretende-se utilizar a base de dados do INMET para também realizar o modelo de previsão futura da irradiação.

AGRADECIMENTOS

Os autores agradecem a fundação Araucária, o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Centro Integrado de Pesquisa em Controle e Automação (CIPECA) pelo suporte financeiro e estrutural para o desenvolvimento deste projeto.

REFERÊNCIAS

ADEDOYIN, F. F.; BEKUN, F. V.; ALOLA, A. A. Growth impact of transition from non-renewable to renewable energy in the EU: the role of research and development expenditure. **Renewable Energy**, Elsevier, v. 159, 2020.

ANTONOPOULOS, V. Z. et al. Solar radiation estimation methods using ANN and empirical models. **Computers and Electronics in Agriculture**, v. 160, p. 160–167, 2019.

BELAID, A.; MELLIT, A. Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. **Energy Conversion and Management**, vol. 118, pp. 105–118, 2016.

BERNARDINO, L. G. R.; NASCIMENTO, C. F.; TAVARES NETO, R. F.; SOUZA, W. A.; MARAFÃO, F. P., Neural-network-based approach applied to harmonic component estimation in microgrids. **Brazilian Power Electronics Conference (COBEP)**, 2021.

BP. Statistical review of world energy globally consistent data on world energy markets and authoritative publications in the field of energy. **BP Energy Outlook**, v. 2021, n. 70, 2021.

BUENO, P. H., Modelagem analítica e numérica semiempírica de células fotovoltaicas, **Dissertação de Mestrado**, UFMG, 2016.

DIXON, M. F.; HALPERIN, I.; BILOKON, P. **Machine learning in Finance**. Springer, 2020. v. 1170.

EPE . Inserção da geração fotovoltaica distribuída no Brasil—condicionantes e impactos. Rio de Janeiro, **Relatório Técnico**, 2014.

GASPARIN, Fabiano Perin. Desenvolvimento de um traçador de curvas características de Módulos Fotovoltaicos, **Dissertação de Mestrado**, UFRGS, 2009.

HOLMSTROM, M.; LIU, D.; VO, C.. Machine learning applied to weather forecasting. **Meteorology. Applied**, v. 10, p. 1–5, 2016.

KIM, K. G. Book review: Deep learning. **HIR**, vol. 22, no. 4, pp. 351–354, 2016.

LI, H. et al. Estimating daily global solar radiation by day of year in China. **Applied Energy**, Elsevier, v. 87, n. 10, p. 3011–3017, 2010.

LIU, X. et al. Evaluation of temperature-based global solar radiation models in China. **Agricultural and forest meteorology**, Elsevier, v. 149, n. 9, p. 1433–1446, 2009.

MCCULLOCH, W.S., PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics** 5, 115–133, 1943.

MEHDIZADEH, S.; BEHMANESH, J.; KHALILI K., Comparison of artificial intelligence methods and empirical equations to estimate daily solar radiation. **Journal of Atmospheric and Solar-Terrestrial Physics**, vol. 146, pp. 215–227, 2016.

NOTTON, G. et al. Some Applications of ANN to Solar Radiation Estimation and Forecasting for Energy Applications. **Applied Sciences**, v. 9, n. 1, 2019.

OLIVEIRA, J. M.; SANTOS, D. D. S.; SILVA R. M., Predição da radiação solar global usando modelos de redes neurais artificiais. **Revista Mundi Engenharia, Tecnologia e Gestão**, vol. 4, no. 5, 2019.

RUMELHART, D., HINTON, G.; WILLIAMS, R. Learning representations by back-propagating errors. **Nature** 323, 533–536, 1986.

SILVA, A. W. B. et al., Methodology based on artificial neural networks for hourly forecasting of pv plants generation. **IEEE Latin America Transactions**, vol. 20, no. 4, pp. 659–668, 2022.

SOUZA, W. A et al. Selection of features from power theories to compose NILM datasets. **Advanced Engineering Informatics**, Elsevier, v. 52, p. 101556, 2022.

WANG, K.; QI, X.; LIU, H. Photovoltaic power forecasting based lstm-convolutional network. **Energy**, v. 189, p. 116225, 2019. ISSN 0360-5442.