

PREVISÃO DE CURTO PRAZO DA RADIAÇÃO SOLAR POR MEIO DE REDES NEURAIS ARTIFICIAIS: UM ESTUDO DE CASO PARA ARARANGUÁ, BRASIL

SHORT-TERM SOLAR RADIATION FORECASTING USING ARTIFICIAL NEURAL NETWORK: A STUDY CASE FOR ARARANGUÁ, BRAZIL

Políbio Ícaro Moro Capo¹ 

Giuliano Arns Rampinelli² 

Resumo: A energia solar vem ganhando importância nos últimos anos, os avanços tecnológicos e a competitividade econômica da energia solar fotovoltaica podem ser destacados como fatores decisivos para sua inserção na matriz elétrica. Dada a sazonalidade da radiação solar, no curto prazo, as previsões permitem uma alocação adequada dos recursos energéticos. Assim, a capacidade de prever a radiação solar é uma das características da produção de energia em uma usina solar fotovoltaica. O estudo teve como objetivo analisar a utilização de redes neurais artificiais como ferramenta de previsão de curto prazo da radiação solar, no período de três horas à frente, por meio da utilização de dados de estações meteorológicas localizadas em Araranguá - Santa Catarina - Brasil. A partir dos resultados obtidos, a ferramenta desenvolvida tem a capacidade de realizar a previsão de curto prazo da radiação solar. A capacidade de previsão usando dados de duas estações meteorológicas diferentes é destacada. Por meio das métricas foi possível quantificar a capacidade de previsão do modelo. Os meses de maio a setembro se destacam com valores de RMSE abaixo de 100 W / m². Os valores do MAE mostraram que em onze dos doze meses utilizados, os resultados ficaram abaixo de 100 W / m². Os valores negativos do MBE mostraram que a capacidade foi considerada subestimada. Os resultados médios da previsão mostram que a ferramenta tem boa precisão. Isso nos permite concluir que, dependendo da aplicação, os resultados são seguros com um erro percentual médio anual de 2,38%.

Palavras-chave: Redes neurais artificiais. Previsão de curto prazo. Radiação solar. Matlab.

Abstract: The solar energy has been gaining importance in recent years, the technological advances and economic competitiveness of photovoltaic solar energy can be highlighted as decisive factors for its insertion in the electrical matrix. Given the seasonality of solar radiation, in the short term, forecasts allow an adequate allocation of energy resources. Thus, the ability to forecast solar radiation is one of the characteristics of energy production in a solar photovoltaic plant. The study aimed to analyze the use of artificial neural networks as a tool for short-term forecasting of solar radiation, in the period of three hours ahead, through the use of data from meteorological stations located in Araranguá - Santa Catarina - Brazil. From the results obtained, the developed tool has the capacity to perform the short-term forecast of solar radiation. The forecasting capacity using data from two different weather stations is highlighted. Through the metrics it was possible to quantify the forecasting capacity of the model. The months of May to

¹ Mestre em Energia e Sustentabilidade, Universidade Federal de Santa Catarina, polibiomoro@gmail.com

² Doutor em Engenharia Mecânica, Universidade Federal de Santa Catarina, giuliano.rampinelli@ufsc.br

September stand out with values of RMSE below 100 W / m^2 . The MAE values showed that in eleven of the twelve months used, the results were below 100 W / m^2 . The negative MBE values showed the capacity was considered to be underestimated. The average results of forecasting show that the tool has good accuracy. These allow us to conclude that, depending on the application, the results are safe with an average annual percentage error of 2.38%.

Keywords: Artificial neural networks. Matlab. Short-term forecast. Solar radiation.

1 INTRODUÇÃO

A energia solar vem ganhando importância nos últimos anos, acompanhando a crescente demanda energética mundial, as perspectivas de escassez dos combustíveis fósseis e as motivações ambientais ligadas ao aquecimento global (LIMA et al., 2016). Atualmente, também pode ser destacado o avanço tecnológico e a competitividade econômica da energia solar fotovoltaica como fatores decisivos para sua inserção na matriz elétrica. De 2014 a 2019 houve a redução da geração por combustíveis fósseis e forte penetração de energia eólica e solar na matriz (BRASIL, MME, 2020a).

As fontes renováveis de energia, que incluem hidráulica, eólica, solar e bioenergia, chegaram a 46,1% de participação na Matriz da Demanda Total de Energia de 2019 (ou Matriz Energética), aumentando 0,6 ponto percentual em relação ao indicador de 2018. O indicador brasileiro representa três vezes o mundial. A energia solar cresceu 92% e a eólica, 15,5%, fontes que, somadas, contribuíram com 50% do aumento da participação das renováveis na matriz (BRASIL, MME, 2020b).

No caso da radiação solar que atinge a superfície terrestre, esta varia principalmente devido à variação climática na atmosfera, tendo uma grande influência na produção de energia elétrica a partir das tecnologias solares (MELLIT; PAVAN; LUGHI, 2014). Portanto, para auxiliar na confiabilidade de operação, principalmente, no caso de usinas fotovoltaicas, entre outros fatores, necessitam-se de estudos que possibilitem conhecer sua disponibilidade regional, variabilidade temporal e previsibilidade (LIMA et al., 2016).

Segundo Antonanzas et al. (2016), as duas abordagens principais podem ser encontradas na previsão da produção de plantas fotovoltaicas são: indireta e direta. As previsões indiretas preveem, em primeiro lugar, a radiação solar e, em seguida, utilizando um modelo da planta fotovoltaica, obtém-se a potência produzida. Por outro lado, as previsões diretas calculam diretamente a potência da planta. Além disso, segundo os autores, muitos outros estudos se concentram na previsão da irradiação solar, pois é o elemento mais difícil de se modelar e tem outras aplicações.

O horizonte de previsão onde a maioria das pesquisas foi realizada é para um dia futuro (ANTONANZAS et al., 2016). A razão para esse comportamento é que a maior parte da energia é negociada nos mercados do dia a frente, quando o planejamento e o compromisso de geração ocorrem. A literatura é dominada por horizontes de previsão horários ou dia a frente, as redes neurais artificiais (RNAs) são uma abordagem apropriada para horizontes de curto prazo e NWP (*Numerical Weather Prediction*) são mais adequados para horizontes mais longos (BARBIERI; RAJAKARUNA; CURTIN, 2017).

De acordo com David et al. (2016), dada a sazonalidade da radiação solar, a curto prazo, as previsões permitem uma adequada alocação dos recursos energéticos, um melhor funcionamento e confiabilidade de usinas e de sistemas menores isolados ou conectados à rede. Assim, a capacidade de prever a radiação solar é uma das características da produção de energia em uma usina solar fotovoltaica.

Dentro desse contexto, o objetivo desse trabalho é analisar a utilização de redes neurais artificiais como uma ferramenta para previsão de curto prazo da radiação solar, no período de três horas de antecedência, por meio da utilização de dados de estações meteorológicas distintas localizadas no município de Araranguá – Santa Catarina – Brasil.

Para a escolha da melhor configuração de rede neural, nesse trabalho foram realizados testes que variam a quantidade de neurônios na camada oculta da rede. Ao final do trabalho, espera-se ter informações sobre qual a melhor configuração para previsão da radiação solar no estudo de caso. A análise dos resultados demonstra as limitações e precisão do modelo adotado sendo essa a principal contribuição do estudo.

2 DESENVOLVIMENTO

Esta etapa é subdividida em duas partes, uma, referente ao tratamento de dados coletados em estações meteorológicas e a, segunda, da utilização da rede neural artificial como ferramenta para realizar a previsão da radiação solar.

2.1. Estações Meteorológicas e Base de dados

A análise efetuada nesse trabalho foi realizada no município de Araranguá, localizado no extremo sul do estado de Santa Catarina, Brasil. A cidade fica localizada na latitude -28.9484101 e longitude -49.4982562. Para tanto, utilizaram-se dados de duas estações meteorológicas. A estação do Núcleo Tecnológico em Energia Elétrica (NTEEL) da Universidade Federal de Santa Catarina e a estação do Instituto Nacional de Meteorologia (INMET). As estações estão distantes por um raio de aproximadamente 2 km.

A base de dados corresponde ao período de doze meses, compreendendo o mês de novembro de 2016 até outubro de 2017. As variáveis utilizadas são: o horário (minutos), temperatura (°C), umidade externa (%), velocidade do vento (m/s), e a radiação solar global no plano horizontal (W/m²). O intervalo de coleta foi de cinco minutos, provenientes da estação meteorológica operada pelo NTEEL. A estação do INMET fornece dados em base horária.

Para o tratamento das variáveis adaptou-se o modelo utilizado por (INPE, 2020). Portanto, removeram-se as inconsistências encontradas nas variáveis atmosféricas. Resumidamente, os filtros empregados foram:

- se a velocidade do vento apresenta valores menores que zero ou maiores que 25 m/s;
- se a radiação apresenta valor menor do que zero;
- se a umidade externa é menor que zero ou maior que 100%.

Em caso afirmativo, a linha de dados correspondente foi removida e o algoritmo continua sua execução. As verificações são realizadas até o final da base de dados para, assim, serem utilizados na rede neural.

2.2 Redes Neurais Artificiais (RNA)

As RNAs são as técnicas de aprendizagem de máquinas mais utilizadas na previsão de energia solar e correspondem a 24% dos trabalhos identificados

pelos autores em (ANTONANZAS et al., 2016). O aprendizado de máquina é a abordagem mais popular na previsão solar (YANG et al., 2018).

A resposta à questão de quais são os melhores algoritmos para prever a radiação não é fácil de responder. Isso em grande parte devido às previsões resultantes que diferem em localização geográfica. Assim, para cada região em particular, deve-se escolher o modelo mais adequado que deve seguir uma tendência de aplicação em regiões semelhantes (OBANDO; CARJAVAL; PINEDA, 2019). Entretanto, para um determinado conjunto de dados de entrada, a implementação adequada de qualquer um desses métodos gera habilidades de previsão semelhantes (YANG, et al, 2018).

Das diferentes topologias de RNAs, a *Multi-Layer Perceptron* (MLP) é utilizada com muito mais regularidade do que outros algoritmos devido à sua propriedade de "aproximação universal", capaz de desenvolver previsões não lineares (OBANDO; CARJAVAL; PINEDA, 2019). Com isso, utilizou-se como metodologia a RNA de múltiplas camadas, MLP.

Vários algoritmos foram desenvolvidos para treinar as redes neurais artificiais, como gradiente conjugado, Quasi-Newton, Levenberg-Marquardt (LM), propagação reversa de taxa de aprendizado variável, dentro outros (MELLIT; PAVAN; LUGHI, 2014). Esses algoritmos de aprendizado têm como base o *backpropagation* e são usados para acelerar a convergência (MANTZARI; MANTIZARIS, 2013).

O algoritmo de treinamento utilizado nesse trabalho foi o *backpropagation*. No qual, utilizam-se pares de entrada e saída para ajustar os pesos da rede por meio de um mecanismo de correção de erros. Conforme Haykin (2001), o treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Essas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

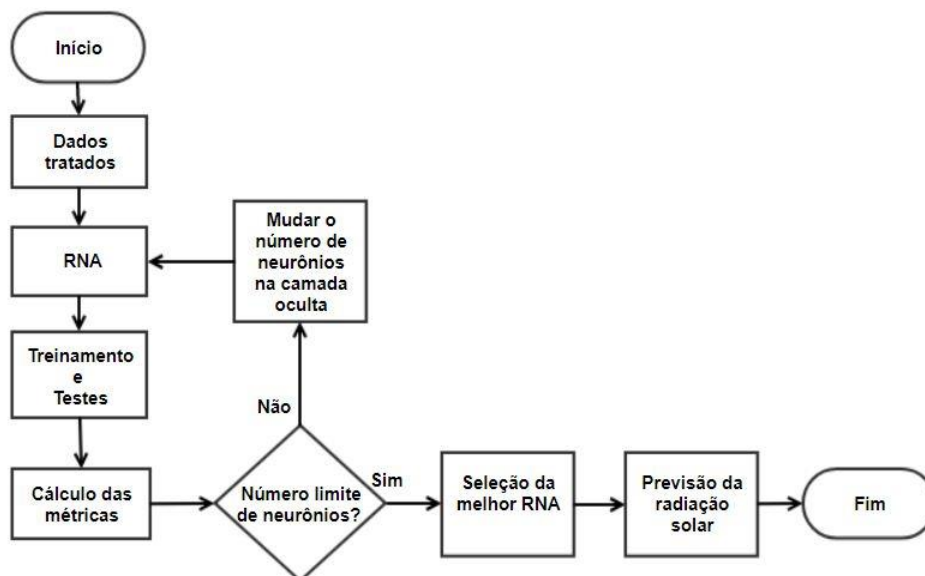
No trabalho de (NEELAMEGAM; AMIRTHAM, 2016), os autores investigaram o melhor algoritmo e modelo de RNA para previsão da radiação solar. Eles verificaram com base no erro médio mínimo, erro quadrático médio

mínimo e coeficiente de regressão linear máximo. Assim, o *backpropagation* de Levenberg-Marquardt provou ser o melhor algoritmo de treinamento e teste. O algoritmo de LM tem sido utilizado para fins de treinamento (KUMAR; KAUR, 2016).

A definição do número de neurônios em cada uma das camadas da rede é de extrema importância para o seu desempenho, principalmente no que se refere a sua capacidade de generalização. Entretanto, conforme Braga, Carvalho e Ludermir (2007), não se pode dizer que haja na literatura uma regra geral que determine, de forma precisa, qual deve ser o número de neurônios de uma rede neural para a resolução de determinado problema. O que se sabe é que quanto maior o número de neurônios, maior a complexidade da rede e maior a sua abrangência em termos de soluções possíveis. Há na literatura inúmeras abordagens que visam estimar o tamanho da rede ou avaliar a sua resposta, mas não existe uma abordagem que tenha encontrado, formalmente, uma resposta geral para essa questão fundamental no projeto de redes neurais. Em geral, é determinado por tentativa e erro, por isso difere significativamente de um estudo para o outro (OBANDO; CARJAVAL; PINEDA, 2019).

A partir do pressuposto, optou-se pela realização de testes para determinar o número de neurônios da camada oculta da rede. Para tanto, variou-se o número de neurônios entre 5 e 150 a fim de encontrar a rede que obtivesse as melhores métricas anuais, por consequência, a rede que melhor representa o conjunto de dados. A Figura 1, demonstra o fluxograma para determinação desse parâmetro.

Figura 1 - Fluxograma de escolha da RNA

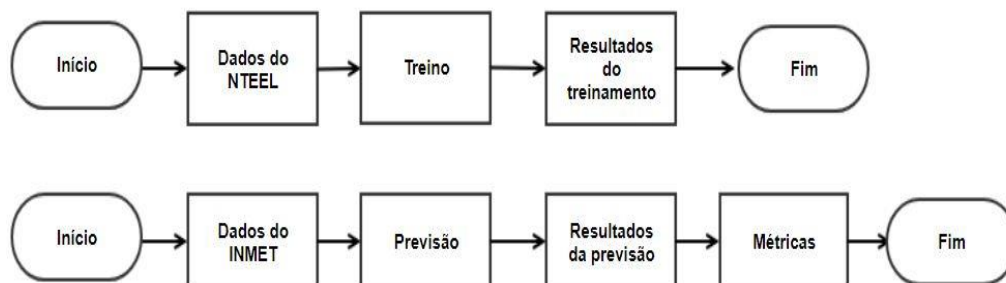


Fonte: Do autor, 2020.

O desenvolvimento da ferramenta foi efetuado utilizando a toolbox “nntool” do MATLAB 2014b. O algoritmo de LM é utilizado para o treinamento, teste e validação da rede. Os dados foram divididos de maneira aleatória e distribuídos em 70% para treinamento, 15% para testes e 15% para a validação. Essa é uma configuração padrão do MATLAB e encontrada na literatura como no trabalho de (KASHYAP; BANSAL; SAO, 2015).

O uso da rede neural deu-se em duas fases, Figura 2, na primeira ocorreram o treinamento e os testes para identificação da melhor rede. Para tanto, utilizaram-se os dados da estação do NTEEL.

Figura 2 - Etapas de utilização da rede neural



Fonte: Do autor, 2020.

2.3 Métricas

O desempenho e a precisão de um determinado modelo podem ser avaliados através de várias métricas, elas permitem a comparação entre diferentes modelos e locais (ANTONANZAS et al., 2016). Na bibliografia, podem ser encontradas diversas métricas, embora existam um grupo delas mais comumente usadas.

Com isso, a Agência Internacional de Energia (IEA) (IEA – PVPS, 2013), afirma que as principais métricas são: *root mean square error* (RMSE), Equação 1, o *mean absolute error* (MAE), Equação 2, o *mean bias error* (MBE), Equação 3. Além dessas, conforme Figueiredo Filho e Silva Júnior (2009), o Coeficiente Linear de Pearson (R) descrito na Equação 5.

$$RMSE = \left(\frac{1}{N} \sum_{i=1}^N e_i^2 \right)^{1/2} \quad (1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (2)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N e_i \quad (3)$$

Sendo Euler subscrito i definido pela Equação 4, como:

$$e_i = y_{i,previsto} - y_{i,observado} \quad (4)$$

Onde $y_{i,previsto}$ e $y_{i,observado}$ são os i-ésimos valores previstos e observados, respectivamente e e_i é o i-ésimo erro. Com $i = 1, \dots, N$ através de todo o conjunto de dados N.

$$R = \frac{1}{N-1} \sum \left(\frac{x_i - \bar{X}}{S_x} \right) \left(\frac{y_i - \bar{Y}}{S_y} \right) \quad (5)$$

Sendo x_i e y_i os valores das observações, \bar{X} e \bar{Y} as médias e S_x e S_y o desvio padrão de cada variável.

Segundo Dancey e Reidy (2006), citados por Figueiredo Filho e Silva Júnior (2009), o coeficiente de correlação Pearson (R) varia de -1 a 1. O sinal indica direção positiva ou negativa do relacionamento e o valor sugere a força da relação entre as variáveis. E, apontam para uma classificação de: R = 0,10 até 0,30 (fraco); R = 0,40 até 0,6 (moderado); R = 0,70 até 1 (forte).

O MAE demonstra a magnitude média do erro de previsão, enquanto RMSE fornece mais peso aos maiores erros de previsão (IEA – PVPS, 2013) grandes erros são proporcionalmente caros, de modo que o RMSE reflete melhor os custos dos erros de previsão para os operadores do sistema do que o MAE (MADSEN et al., 2005).

O MBE é uma indicação do desvio médio dos valores previstos e pode fornecer informações sobre o desempenho a longo prazo dos modelos (AHMAD; ANDERSON, 2014). Um valor de MBE positivo indica uma superestimação na radiação solar global predita e um valor negativo demonstra uma subestimação da previsão. Com isso, ao compreender a métrica MBE permitiria que os operadores do sistema de energia alocassem melhor os recursos para compensar erros de previsão no processo de despacho (ZHANG et al., 2013).

Ao indicar a precisão da previsão é importante especificar não apenas qual métrica é usada (RMSE, MAE ou outra), mas também, esclarecer se esse valor foi calculado durante períodos completos de 24 horas ou apenas levando em consideração as horas de incidência solar (IEA – PVPS, 2013). Portanto, para a construção dos resultados foram utilizadas apenas as horas em que havia incidência solar, as métricas MAE, RMSE, MBE e o coeficiente de correlação Linear de Pearson (R).

3 RESULTADOS E DISCUSSÃO

3.1 Tratamento de dados

Ao verificar os resultados do tratamento de dados na Tabela 1, nota-se a diminuição da quantidade de dados brutos. Esse fato demonstra que os *softwares* desenvolvidos removeram as inconsistências e que nem todos os meses estavam completos. Assim, foram excluídos os dados inconsistentes do treinamento da rede neural. Também são apresentados o número de dias completos utilizados em cada mês.

Tabela 1 – Dados utilizados por estação meteorológica

Mês	NTEEL			INMET		
	Brutos	Tratados	Dias	Brutos	Tratados	Dias
Jan.	7971	4980	28	744	550	31
Fev.	3793	2349	13	696	522	29
Mar.	8914	5562	31	744	558	31
Abr.	6861	4275	24	720	540	30
Mai.	3907	2455	14	743	554	31
Jun.	8640	5429	30	710	507	29
Jul.	8928	5604	31	456	342	19
Ago.	8929	5607	31	744	558	31
Set.	5148	3152	18	720	503	30
Out.	6356	3870	22	744	558	31
Nov.	7817	4834	27	720	540	30
Dez.	7789	4860	27	744	558	31
Total	85053	52977	295	8485	6290	353

Fonte: Do autor, 2020.

É importante notar que, para a obtenção dos resultados de previsão, os dados do INMET estavam praticamente completos. Apenas no mês de julho foram 19 dias. Como consequência, a previsão foi considerada completa pois foram utilizados 353 dos 365 dias possíveis. A estação do NTEEL coletou 295 dias de dados completos utilizados para treinamento e escolha da RNA.

3.2 Análise das redes neurais desenvolvidas

As redes neurais foram modeladas e desenvolvidas utilizando o *software* MATLAB 2014b. Os valores de R, dispostos na Tabela 2, representam a correlação linear de Pearson entre a radiação solar real e a prevista. Esses, foram obtidos durante a fase de treinamento com dados da estação do NTEEL. Especificamente, levam em consideração a divisão aleatória dos 52977 dados tratados em 70 % para o treinamento, 15 % de teste e 15 % de validação.

Tabela 2 – Coeficientes de correlação R para a estação do NTEEL

Neurônios	R
5	0,849
6	0,848
7	0,849
8	0,854
9	0,855
10	0,853
15	0,857
20	0,863
25	0,866
30	0,867
40	0,869
150	0,882

Fonte: Do autor, 2020.

Segundo Kumar e Kaur (2016) um modelo utilizando mais variáveis meteorológicas promove uma previsão mais precisa. Em contrapartida, o município de Araranguá apresenta grande sazonalidade climática. Salienta-se a necessidade de verificar quais as variáveis possuem maior impacto para a previsão da radiação solar com três horas de antecedência. Propõe-se que a relação entre os conjuntos de dados de entrada seja estudada em trabalhos futuros.

Na maioria dos trabalhos revisados, os autores escolhem a melhor rede com base no maior valor da correlação R obtida durante o treinamento da RNA.

Os resultados de treinamento mostram que os valores da correlação R são bem próximos e variam pouco. Esse fato é identificado na literatura, por exemplo, em (PINHEIRO; LOVATO; RÜTHER, 2017), (AHMAD; ANDERSON, 2014), e por fim em (CORNARO et al., 2013). Entretanto, os autores citados, na maioria dos casos, realizam uma previsão de potência gerada e/ou utilizam radiação horária ou médias mensais para diferentes conjuntos de variáveis de entrada.

Até o presente momento, poucos trabalhos, brasileiros, são identificados na literatura referentes ao tema de previsão da radiação solar ou de geração de potência (MACIEL; LEDESMA; ANDO JUNIOR, 2020). Como consequência, optou-se por calcular as métricas anuais para todas as configurações de rede neural estudadas utilizando os dados da estação do INMET, ou seja, dados inéditos para os modelos.

Ao calcular as métricas, descritas anteriormente, a literatura pressupõe que as redes com maior coeficiente R apresentariam os melhores resultados de previsão. Esse fato contrasta com os principais valores encontrados para a proposta de previsão em três horas antes. Os mesmos podem ser visualizados na Tabela 3.

Tabela 3 – Métricas anuais para a estação do INMET

Neurônios	R	RMSE (W/m ²)	MAE (W/m ²)	MBE (W/m ²)
5	0,849	122,40	76,08	-11,73
6	0,848	122,73	76,24	-9,39
7	0,849	123,55	77,13	-10,34
8	0,854	125,09	78,10	-9,64
9	0,855	126,56	78,54	-10,16
10	0,853	125,69	77,94	-13,33
15	0,857	126,40	78,10	-6,87
20	0,863	131,75	81,22	-11,09
25	0,866	132,76	81,57	-12,30
30	0,867	136,68	82,70	-9,25
40	0,869	135,40	82,79	-13,86
150	0,882	162,39	92,11	-9,44

Fonte: Do autor, 2020.

Conforme o resultado anterior, Tabela 3, optou-se por calcular um 'score' com base nas métricas anuais obtidas com dados do INMET. Esse foi definido a partir da Equação 6, onde realizou-se uma média das métricas encontradas.

$$score = \frac{(RMSE+MAE+|MBE|)}{3} \quad (6)$$

Portanto a rede escolhida, com o melhor score, foi a rede com seis neurônios na camada oculta, conforme visto na Tabela 4.

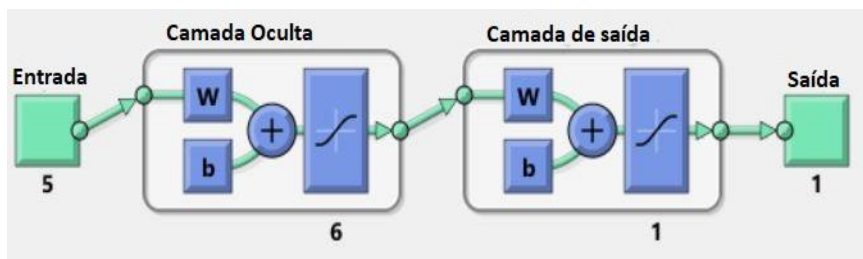
Tabela 4 – Coeficientes de correlação R para a estação do NTEEL

Neurônios	Score
5	70,07
6	69,45
7	70,34
8	70,94
9	71,75
10	72,32
15	70,46
20	74,69
25	75,54
30	76,21
40	77,35
150	87,98

Fonte: Do autor, 2020.

O esboço da topologia da rede neural pode ser visto na Figura 3.

Figura 3 - Esquema da melhor RNA encontrada



Fonte: Do autor, adaptado de (MATLAB, 2020).

O score foi calculado após o treinamento utilizando os valores de R da estação de NTEEL, dados intervalados em cinco minutos, o RMSE, MAE, MBE, foram obtidos com a base de dados anual da estação meteorológica do INMET. Portanto, foram realizadas previsões e os cálculos das métricas para determinar a RNA com o melhor desempenho. Contudo, as previsões mensais utilizam dados da estação do INMET e foram utilizadas para validar e avaliar com mais detalhes a capacidade de previsão da ferramenta. Os resultados mensais estão dispostos na Tabela 5.

Tabela 5 – Métricas mensais da estação do INMET

Ano/Mês	RMSE (W/m ²)	MAE (W/m ²)	MBE (W/m ²)	Dias
2016 Nov.	142,10	94,62	-38,66	30
2016 Dez.	158,14	105,41	-26,89	31
2017 Jan.	159,87	107,48	-36,90	31
2017 Fev.	138,30	89,66	-23,51	29
2017 Mar.	130,27	83,62	-30,85	31
2017 Abr.	109,20	68,68	22,98	30
2017 Mai.	91,98	56,72	11,92	31
2017 Jun.	91,92	52,48	6,82	29
2017 Jul	81,46	53,42	14,06	19
2017 Ago.	79,65	51,43	-8,75	31
2017 Set.	93,24	55,47	5,66	30
2017 Out.	138,95	84,35	1,62	31
Anual	122,73	76,24	-9,39	353

Fonte: Do autor, 2020.

Ao analisar a Tabela 5, destaca-se os valores de MBE encontrados para os meses de junho, agosto, setembro e outubro. Pois, os valores indicam que, quanto mais próximo de zero, melhores são os resultados a longo prazo do modelo conforme (IEA – PVPS, 2013). Nos meses em que o MBE apresentou valores negativos a rede previu de maneira subestimada e em caso positivo sobrestimada. Destaca-se o valor de MBE encontrado quando se utilizam todos os dados. Portanto, anualmente a capacidade foi considerada subestimada ficando abaixo de 10 W/m².

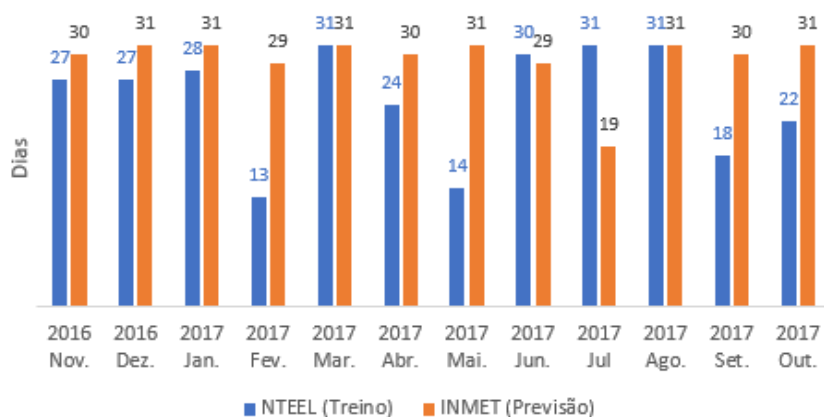
Os valores de MAE representam a magnitude média do erro de previsão. Com isso, destaca-se que dos doze meses, dez obtiveram valores abaixo de 100 W/m². E, anualmente, calculou-se 76,24 W/m². O que implica que a RNA apresenta uma boa capacidade de previsão.

Os resultados de RMSE fornecem mais peso aos maiores erros de previsão, de modo que o RMSE reflete melhor os custos de despacho pois grandes erros são proporcionalmente caros (MADSEN et al., 2005). Destaca-se os meses de maio a setembro com valores de RMSE menores que 100 W/m². O que demonstra que foram obtidas previsões com pequena discrepância entre o valor real. Contudo, os meses de novembro a março requerem maior atenção quando se trata de despacho de energia. Esse fato evidencia a limitação da rede neural em realizar as previsões com valores altos de radiação solar. Pressupõe-se que isso ocorra devido as relações entre as variáveis meteorológicas utilizadas como entrada no treinamento. Todavia, a maior incidência de radiação solar em alguns desses meses, provavelmente, afete o RMSE de maneira significativa.

Ao comparar a Figura 4. com a Tabela 5, nota-se que não há relação direta com a quantidade de dias utilizados no treinamento e na previsão. Logicamente, espera-se que com mais dados para o treinamento os resultados sejam melhores. Entretanto, esse fato não limita a capacidade de previsão do modelo. Dado que as métricas demonstram que, por exemplo, no mês de maio foram utilizados 14 dias para treinamento e a rede teve capacidade de prever os 31 dias da estação do INMET com resultados menores que 100 W/m². Entretanto, em fevereiro o RMSE encontrado corrobora com o pressuposto de

que a limitação, nesse caso, encontra-se nas variáveis meteorológicas ou da maior incidência de radiação solar nesse mês ao comparar com os demais.

Figura 4 - Dias utilizados para treinamento e para previsão



Fonte: Do autor, 2020.

Além do cálculo das métricas, optou-se por analisar as médias reais e as previstas para averiguar o impacto das previsões. Portanto, efetuou-se o cálculo dos erros percentuais por meio da Equação 6.

$$Erro\% = \left| \frac{média_{real} - média_{prevista}}{média_{real}} \right| \times 100 \quad (6)$$

Os resultados dos erros percentuais podem ser vistos na Tabela 6 e na Figura 5 a comparação das médias.

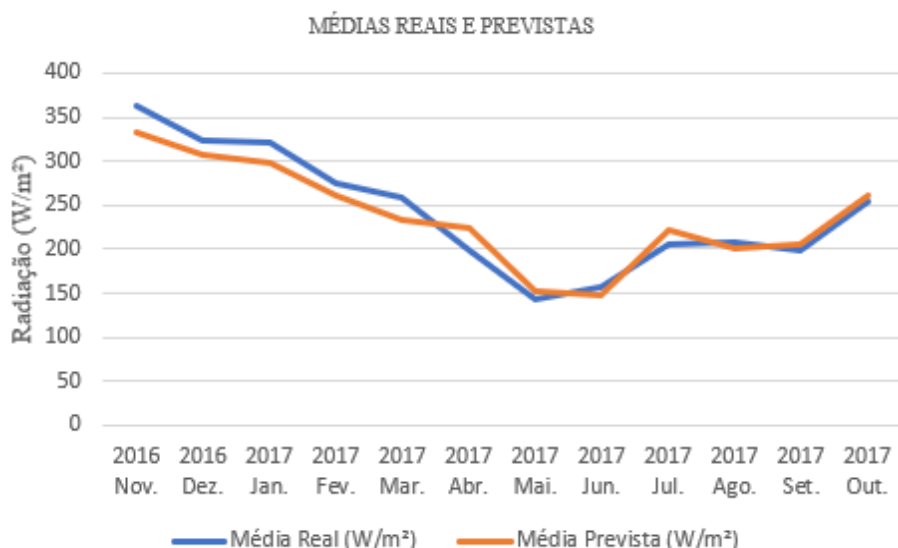
Tabela 6 – Médias mensais e erros percentuais INMET

Ano/Mês	Média Real (W/m ²)	Média Prevista (W/m ²)	Erro (%)
2016 Nov.	363,12	333,16	8,25%
2016 Dez.	322,72	307,43	4,74%
2017 Jan.	321,91	296,96	7,75%
2017 Fev.	275,30	261,50	5,01%

2017 Mar.	258,17	232,91	9,78%
2017 Abr.	199,07	223,58	12,31%
2017 Mai.	143,21	153,40	7,12%
2017 Jun.	156,10	147,34	5,61%
2017 Jul.	205,82	221,05	7,40%
2017 Ago.	208,24	201,34	3,31%
2017 Set.	198,75	206,53	3,91%
2017 Out.	254,85	260,97	2,40%
Anual	244,15	238,33	2,38%

Fonte: Do autor, 2020.

Figura 5 - Médias mensais reais e previstas estação do INMET



Fonte: Do autor, 2020.

Os resultados destacam que na média, e dependendo de sua aplicação, a previsão é considerada segura, uma vez que sensores de medição apresentam erros da ordem de 5 a 10% dependendo da classe e das manutenções realizadas no equipamento (MOHANTY; MUNEEER; KOLHE, 2016). Destaca-se os meses de outubro e agosto com 2,40% e 3,31%, respectivamente. O mês de abril foi o único com erro percentual acima de 10%. Na média anual, o erro de 2,38% demonstra a boa capacidade de previsão da ferramenta desenvolvida.

4 CONSIDERAÇÕES FINAIS

Com a análise dos resultados foi possível identificar que os valores da correlação R estão diretamente relacionados com o tamanho da rede neural e com as variáveis de entrada do modelo, ou seja, com as condições climáticas locais. Salienta-se a necessidade de verificar quais as variáveis possuem maior impacto para a previsão da radiação solar. Propõe-se que os conjuntos de dados de entrada sejam estudados em detalhes em trabalhos futuros.

Através das métricas foi possível quantificar a capacidade de previsão do modelo. Destacam-se os meses de maio a setembro com valores de RMSE abaixo de 100 W/m². O que demonstra que foram obtidas previsões próximas ao valor real. Contudo, os meses de novembro a março requerem maior atenção quando se trata de despacho de energia.

Os valores de MAE demonstraram que em dez dos doze meses utilizados, os resultados ficaram abaixo de 100 W/m². O que implica que a RNA apresenta uma boa capacidade de previsão. O MBE apresentou valores negativos sendo a previsão subestimada e positivos sobrestimada para alguns meses. Destaca-se o valor de MBE encontrado quando se utilizam todos os dados. Portanto, anualmente a capacidade foi considerada subestimada ficando abaixo de 10 W/m².

Os resultados médios, demonstram que a ferramenta apresentou um bom desempenho nos acertos. Esses permitem concluir que, conforme a aplicação, os resultados são seguros com erro médio percentual anual da ordem de 2,38%. Contudo, de maneira geral, a rede possui limitação de previsão nos picos de incidência de radiação solar. Portanto, requer maior atenção quando se trata de despacho de energia e deve ser investigado em trabalhos futuros. Destaca-se a capacidade do modelo em prever a radiação solar utilizando dados de duas estações meteorológicas diferentes e distantes entre si.

AGRADECIMENTOS

Agradecemos ao Instituto Nacional de Meteorologia e ao Núcleo Tecnológico em Energia Elétrica da Universidade Federal de Santa Catarina, Campus Araranguá, pela disponibilização da base de dados. A CAPES pela bolsa de estudos do primeiro autor.

REFERÊNCIAS

AHMAD, A.; ANDERSON, T. "Global Solar Radiation Prediction using Artificial Neural Network Models for New Zealand," **Solar 2014: The 52nd Annual Conference of the Australian Solar Council, 2014.**

Disponível em: http://solarexhibition.com.au/wp-content/uploads/Solar_2014_Scientific-Research-Session_FINAL.pdf

ANTONANZAS, J. et al., "Review of photovoltaic power forecasting," **Solar Energy** 136, pp. 78–111, 2016.

BARBIERI, F.; RAJAKARUNA, S.; CURTIN, A. G., "Very short-term photovoltaic power forecasting with cloud modeling: A review," **Renewable and Sustainable Energy Reviews** 75, pp. 242–263, 2017.

BRAGA, A. de P.; CARVALHO, A. P. de L. F.; LUDERMIR, T. B. "**Redes neurais artificiais: Teoria e Aplicações**". 2nd ed. Rio de Janeiro, Brasil: LTC, 2007.

BRASIL, MME a – Ministério de Minas e Energia. **Indicadores dos 60 anos do MME.**

Disponível em:

<http://www.mme.gov.br/documents/78404/0/Indicadores+dos+60+anos+do+MME.pdf/55495d2b-40e7-1e1c-397b-54ccc3ed74b>

BRASIL, MME b – Ministério de Minas e Energia. **Resenha Energética Brasileira.**

Disponível em: <http://www.mme.gov.br/web/guest/secretarias/planejamento-e-desenvolvimento-energetico/publicacoes/resenha-energetica-brasileira>

CORNARO, C. et al. "Solar radiation forecast using neural networks for the prediction of grid connected PV plants energy production (DSP project)," **28th European Photovoltaic Solar Energy Conference and Exhibition, 2013.**

DANCEY, C. & REIDY, J. (2006), "**Estatística Sem Matemática para Psicologia: Usando SPSS para Windows**". Porto Alegre, Artmed.

DAVID, M. et al., "Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models," **Solar Energy**, vol 133, Publisher: Elsevier Ltd, pp 55-72, 2016.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. da. "Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r)" **Revista Política Hoje**, Vol. 18, n. 1, 2009.

Disponível em:

<https://periodicos.ufpe.br/revistas/politica hoje/article/viewFile/3852/3156>

HAYKIN, S. S. "**Redes neurais: princípios e prática**". 2nd ed., Porto Alegre, Brasil: Bookman, 2001.

IEA - PVPS - International Energy Agency, Photovoltaic Power Systems Programme: "**Photovoltaic and Solar Forecasting: State of the Art. 2013**"

Disponível em: http://www.iaepvps.org/index.php?id=3&elD=dam_frontend_push&docID=1690

INPE – Instituto Nacional de Pesquisas Espaciais - **Sistema de Organização Nacional de Dados Ambientais (SONDA)**, "**Validação dos dados**".

Disponível em: <http://sonda.ccst.inpe.br>

KASHYAP, Y.; BANSAL, A.; SAO, A. K. "Solar radiation forecasting with multiple parameters neural networks," **Renewable and Sustainable Energy Reviews** 49, pp. 825–835, 2015.

KUMAR, S.; KAUR, T., "Development of ANN Based Model for Solar Potential Assessment Using Various Meteorological Parameters," 5th International Conference on Advances in Energy Research, ICAER 2015, 15-17 Dec. 2015, Mumbai, India. **Energy Procedia** 90 pp 587 – 592, 2016.

LIMA, F. J. L. et al., "Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks," **Renew. Energy**, vol. 87, pp. 807–818, Mar. 2016.

MACIEL, J. N.; LEDESMA, J. J. G.; ANDO JUNIOR, O.H. "Forecasting Solar Power Output Generation: A Systematic Review with the Proknow-C," **IEEE Latin America Transactions**, vol. 19, no. 4, Abril 2021.

MADSEN, H. et al. "Standardizing the performance evaluation of short-term wind power prediction models," **Wind Eng.** pp 475-89, 2005.

MANTZARI, V. H.; MANTZARIS, D. H., "Solar radiation: Cloudiness forecasting using a soft computing approach," **Artificial Intelligence Research**, Vol. 2, No. 1, 2013.

MATLAB. **Toolbox nntool**. MATLAB 2014b. 2017.

MELLIT, A.; PAVAN, A. M.; LUGHI, V. "Short-term forecasting of power production in a large-scale photovoltaic plant," **Solar Energy**, vol 105, pp. 401–413, 2014.

MOHANTY, P.; MUNEER, T.; KOLHE, M. L. "**Green Energy and Techonology. Solar Photovoltaic System Applications: A Guidebook for Off-Grid Electrification**," 184p. Springer International Publishing, 2016.

NEELAMEGAM, P.; AMIRTHAM, V. A., "Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms," **Journal of Applied Research and Technology** 14, pp. 206–214, 2016.

OBANDO, E.; CARVAJAL, S.; PINEDA, J., "Solar Radiation Prediction Using Machine Learning Techniques: A Review," **IEEE Latin America Transactions**. vol 17, no 4, pp. 684 - 697, Apr, 2019.

PINHEIRO, E.; LOVATO, A.; RÜTHER, R. "Aplicabilidade de redes neurais artificiais para análise de geração de energia de um sistema fotovoltaico conectado à rede elétrica," **Revista Brasileira de Energias Renováveis**, 2017.

YANG, D. et al., "History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining," **Solar Energy**, pp. 60-101, Jul. 2018.

ZHANG, J. et al. "Metrics for Evaluating the Accuracy of Solar Power," **3rd International Workshop on Integration of Solar Power into Power Systems** London, England, 2013.

Disponível em: <https://www.nrel.gov/docs/fy14osti/60142.pdf>

Enviado em: 09 mar. 2021.

Aceito em: 14 out. 2021.

Editor responsável: Mateus das Neves Gomes.