

Utilização de Redes Neurais Artificiais para a estimação da potência gerada de Sistemas Fotovoltaicos Conectados à Rede

Amanda S. F. Rocha*. Luann G. O. Queiroz**. Oureste E. Batista**.
Fabiana K O. M. V. Guerra*. Marcelo R. B. G. Vale*.

*Programa de Pós-Graduação em Engenharia Elétrica, PPGEE
Universidade Federal Rural do Semi-Árido, UFERSA, Mossoró, Brasil,
(amanda_suianny@hotmail.com / fkv@ufersa.edu.br/ marceloguerra@ufersa.edu.br)

**Programa de Pós-Graduação em Engenharia Elétrica, PPGEE
Universidade Federal do Espírito Santo, UFES, Vitória, Brasil,
(luann.queiroz@edu.ufes.br / oureste.batista@ufes.br)

Abstract:

The use of photovoltaic solar energy has been increasing worldwide, and in Brazil, due to the energy crises that the country faces, this energy source has been an alternative to circumvent this problem. However, as it is an intermittent source, and depends exclusively on local climatic conditions, it can present a loss in energy generation efficiency, therefore, a previous study of the location to be installed is necessary. Therefore, the present work seeks to use an Artificial Neural Network (ANN) to analyze the performance of a photovoltaic system connected to the network, through the forecast of the generated power. For this, a 3kWp system was used as a model, this system is located in the city of Mossoró-RN. The implementation of the ANN was carried out with the support of Matlab®, inserting as real input variables solar radiation and city temperature, and the electrical power generated by the photovoltaic system itself was used as an output variable. Applying the proposed performance analysis methods, the ANN shows itself to be favorable for the prediction of the generated power, with Correlation Coefficient between 0.88 and 0.96, Percentage Mean Error in the range of 10 ~ 22 and average expected powers that approach the real values.

Resumo:

A utilização da energia solar fotovoltaica vem aumentando em todo o mundo, e no Brasil, devido às crises energéticas que o país enfrenta, essa fonte de energia tem sido uma alternativa para contornar esse problema. No entanto, por se tratar de uma fonte intermitente, e depender exclusivamente das condições climáticas locais, a mesma pode apresentar perda na eficiência de geração de energia, logo, se faz necessário um estudo prévio do local a ser instalado. Sendo assim, o presente trabalho utiliza uma Rede Neural Artificial (RNA) para analisar o desempenho de um sistema fotovoltaico conectado à rede, através da previsão da potência gerada. Para isso, foi utilizado um sistema de 3kWp como modelo localizado na cidade de Mossoró-RN. Realizou-se a implementação da RNA com o auxílio do Matlab®, inserindo como variáveis de entrada dados reais de irradiação solar, temperatura da cidade, e a potência elétrica gerada pelo próprio sistema fotovoltaico utilizada como variável de saída. Aplicando os métodos de análise de desempenho propostos, tem-se que a RNA se mostra favorável para a previsão da potência gerada, com Coeficiente de Correlação entre 0,88 e 0,96, Erro Médio percentual na faixa de 10-22 e potências médias previstas que se aproximam dos valores reais.

Keywords: Photovoltaic Solar Energy; Artificial Neural Network; Power Forecast; Solar irradiation; Temperature.

Palavras-chaves: Energia Solar Fotovoltaica; Rede Neural Artificial; Previsão da Potência; Irradiação solar; Temperatura.

1. INTRODUÇÃO

A geração de energia elétrica é um fator essencial para o contínuo desenvolvimento da sociedade, que apresenta uma

forte dependência por esse tipo de insumo, contribuindo para a sua crescente demanda dos últimos anos. Para assegurar o fornecimento de energia, se faz necessário implementar alternativas de geração de forma sustentável e segura, que

possam complementar a energia provinda das termoeletricas e hidreletricas. Diante disto, as fontes alternativas de energia são as opções que vêm ganhando destaque em todo o mundo. Uma das fontes alternativas que tem contribuído de forma significativa para a diversificação da matriz energética brasileira, é a energia solar fotovoltaica. Tal fonte promove benefícios tanto para o setor, quanto para o consumidor final.

Apesar dos benefícios proporcionados, a energia solar fotovoltaica pode apresentar perdas devido à forte influência das variações climáticas a que está submetida. As perdas, causadas principalmente pela temperatura e irradiação solar, podem causar prejuízos. Índices elevados podem causar danos ao sistema, ao passo que, índices que não atingem os limites mínimos comprometem a geração de potência. Para isso, existe a necessidade de se realizar um estudo prévio a respeito do local de instalação do sistema, podendo prever eventuais problemas.

Dentro desses aspectos, a Rede Neural Artificial (RNA) pode ser aplicada no problema de intermitência do sistema solar fotovoltaico, visto que a mesma possui características favoráveis para operar com estes tipos de variáveis. Estas são capazes de realizar a previsão da potência elétrica gerada a partir das condições climáticas da região para indicar, preliminarmente, a viabilidade da instalação dos sistemas.

A utilização da RNA para realizar previsões vem sendo utilizada em diversos estudos ao longo dos anos. O trabalho de Kayri e Gencoglu (2017) usam a RNA para prever a produção de energia de um sistema solar fotovoltaico que possui um único eixo com rotação na direção leste-oeste, onde foram utilizadas duas redes, treinadas com dados coletados em dias ensolarados e em dias nublados, sendo utilizadas como variáveis de entrada a velocidade do vento, direção do vento, ângulo de elevação solar, temperatura do ar, umidade relativa, radiação global.

O trabalho de Dias et. al. (2019), mostra a aplicação de Redes Neurais Artificiais para previsão de incidência solar, fazendo um estudo comparativo entre dois tipos de redes neurais, a *Multilayer Perceptron* (MLP) e a *Radial Basis Function* (RBF). O estudo foi realizado com dados de Belo Horizonte-MG, onde para o processo de treinamento foram coletados os dados meteorológicos diários entre o período de janeiro de 2012 a dezembro de 2017. As variáveis de entrada escolhidas para treinamento das RNA's foram: a Precipitação (mm), Temperatura Compensada Média (°C), Evaporação do Piche (mm), Velocidade Média do Vento (mps), Umidade Relativa do ar (%) e Insolação (h). Além disso, utilizou-se a insolação como variável de saída. Dentre os modelos aplicados e avaliados, verificou-se que, tanto a MLP, quanto a RBF conseguiram convergir com valores de erros consideravelmente baixos. No entanto as RNA's tipo MLP que empregam o algoritmo Levenberg-Marquardt mostraram ser os modelos mais viáveis nas análises realizadas de previsão de insolação para a cidade de Belo Horizonte/MG, tanto no treinamento, quanto na validação, apresentando o menor valor de MSE.

De forma semelhante Zarcov et. al. (2019) utiliza a RNA no Matlab para prever irradiação solar em Oryahovo, Bulgária.

Os autores utilizam uma rede *Multilayer Perceptron*, e fazem dois testes em períodos diferentes (de maio a agosto e janeiro a abril) variando de 5 a 35 as quantidades de neurônios na camada oculta. A camada de entrada recebe como parâmetro a irradiação solar diária medida nos seis dias anteriores, enquanto na camada de saída tem-se a irradiação solar do dia seguinte. Os dados utilizados foram coletados em um período de cinco anos e reagrupados em intervalos de 10 minutos, além disso, os dados dos primeiros três anos foram usados para o treinamento da RNA, enquanto os dados dos últimos dois anos são usados para testar o desempenho do modelo. Após as implementações verificou-se que a rede neural com 20 neurônios na camada oculta apresenta o melhor desempenho em relação às demais estruturas, apresentando com o menor Erro Quadrático Relativo de Raiz (RRMSE), entre 4% e 5%.

Já Djalab et. Al. (2019) mostram outra maneira de se aplicar a RNA em sistemas fotovoltaicos, neste caso, prevendo possíveis falhas desses sistemas. Para isso, utilizou-se uma rede neural com três camadas, contendo 3 variáveis de entrada (potência, corrente e tensão) adquiridas através de um circuito modelo que simula o funcionamento de um módulo fotovoltaico. Foram inseridos ainda, 25 neurônios na camada oculta e 5 variáveis de saída (F0 Estado normal; F1 Sombra parcial de três módulos com diodos de bypass funcionando corretamente; F2 sombra parcial de três módulos com diodos de bypass desconectados; F3 curto-circuito em um módulo e F4 curto-circuito em dois módulos). Com uma base de dados de 5209 amostras, o módulo fotovoltaico foi simulado em condições normais de operação e também adicionando as 4 falhas. Aplicou-se um aprendizado automático utilizando o Matlab até se obter um erro quadrático muito baixo, obtendo um erro de 0,00099 após 19 iterações. A taxa de precisão adquirida indicada pelos autores de 96,8% para o modelo de diagnóstico da RNA indica que a rede é bem escolhida e bem treinada.

Diante disto, o presente trabalho tem como objetivo desenvolver uma RNA capaz de prever a geração de energia elétrica de um sistema fotovoltaico de 3kWp, a partir de informações reais do local de estudo, inserindo como dados de entrada a irradiação solar global e a temperatura. Utilizou-se como método de análise de desempenho erros médios, erros absolutos médios e coeficientes de correlação.

2. SISTEMA FOTOVOLTAICO CONECTADO À REDE

O Sistema Fotovoltaico Conectado à Rede (SFCCR) ou *on-grid*, se caracteriza por se tratar de uma conexão direta com a rede convencional de energia elétrica, onde toda a potência gerada pelo arranjo fotovoltaico é injetada na rede elétrica, sendo consumida instantaneamente, e com isso, dispensa o uso de equipamentos armazenadores de energia. Para tanto, é indispensável que seja utilizado um inversor, de modo a satisfazer as exigências de qualidade e segurança para que não comprometa a qualidade do sistema elétrico onde se interliga o arranjo fotovoltaico (CRESESB, 2004).

Para esses sistemas existem duas configurações, os sistemas fotovoltaicos distribuídos e os centralizados. Sendo a Geração Distribuída (GD) um método de geração que utiliza

fontes de energia elétrica de pequeno porte, de forma integrada ou isolada, pelas concessionárias, consumidores e terceiros, gerando eletricidade e consequentes benefícios para o sistema elétrico e para as unidades consumidoras específicas. Essa energia elétrica é produzida no local de consumo ou próximo a ele (Torres, 2015).

Em virtude do avanço desta tecnologia, foram criadas resoluções normativas que estabelecem regras para a utilização das GDs, entre elas estão as diretrizes para do consumidor gerar sua própria energia. Trata-se da micro e da minigeração distribuídas de energia elétrica, e essas inovações podem aliar economia financeira, consciência socioambiental e autossustentabilidade. Esse estímulo se justifica pelos potenciais benefícios que tal modalidade pode proporcionar ao sistema elétrico, sobretudo, o adiamento de investimentos em expansão dos sistemas de transmissão e distribuição, o baixo impacto ambiental, a redução no carregamento das redes, a minimização das perdas e a diversificação da matriz energética (ANEEL, 2015).

A utilização desta fonte de energia depende das condições climáticas locais, sendo influenciados, principalmente, pelos efeitos da temperatura e intensidade da radiação solar. Os níveis de incidência dessas variáveis climáticas devem atender as condições de operação dos módulos fotovoltaicos, pois os elevados níveis de insolação e a variação da temperatura ambiente podem provocar uma variação de temperatura nas células fotovoltaicas, que tende a reduzir a eficiência do sistema, além de causar efeitos na tensão e na corrente elétrica (CRESESB, 2004).

3. REDE NEURAL ARTIFICIAL

A Rede Neural Artificial é considerada uma ferramenta da Inteligência Artificial (IA) que funciona de forma semelhante ao cérebro humano por tentar reconhecer regularidades e padrões dos dados. De acordo com Haykin (2001), uma rede neural é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. Elas aprendem por experiência, e acumulam conhecimentos que serão posteriormente generalizados para tomadas de decisões.

Trabalhar com a não linearidade de determinadas variáveis é uma das principais vantagens da RNA. Elas são usualmente aplicadas nas previsões de séries temporais, pois permite a aproximação da maioria das funções não-lineares. As séries temporais apresentam comportamentos em que as propriedades de convergência, generalização e aprendizado das redes neurais podem gerar resultados satisfatórios quando comparados com outros modelos (Martins et al. 2008).

A arquitetura de uma RNA define como seus neurônios estão arrançados, ou dispostos, uns em relação aos outros. Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas dos neurônios. Desta forma, a RNA é constituída por três camadas, a Camada de entrada: responsável pelo recebimento de dados externos; Camada intermediária: também conhecida como camada escondida ou oculta. Nelas ficam localizados os neurônios responsáveis por extrair as características associadas ao

processo. Vale salientar que algumas redes podem não possuir esta camada; Camada de saída: constituída pelos neurônios que produzem e apresentam os resultados finais da rede, esses resultados são decorrentes dos processamentos efetuados pelos neurônios das camadas anteriores (Silva et al. 2010).

A rede de múltiplas camadas utilizada neste trabalho, também conhecida como *Multilayer Perceptron* (MLP), são constituídas por uma ou mais camadas escondidas de neurônios. Geralmente são aplicadas em aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processo, etc. (Silva et al. 2010).

4. METODOLOGIA

A pesquisa foi realizada na Universidade Federal Rural do Semi-Árido (UFERSA), localizada na cidade de Mossoró-RN, em um sistema solar fotovoltaico de 3kWp conectado à rede com conexão monofásica. O sistema é constituído por 14 módulos fotovoltaicos da marca *Yingli Solar* (Fig. 1), modelo YL245P -29b, de 245W cada, com conexão em série, e um inversor *Sunny Boy 3000HFUS*, da SMA, que converte a corrente contínua em corrente alternada. Além disso, o sistema conta com um quadro de comando e proteção e um medidor bidirecional, no entanto, o foco principal será nos módulos e no inversor fotovoltaico, devido às análises e dados retirados dos mesmos.



Fig 1: Sistema fotovoltaico utilizado na pesquisa.

Visando organizar e otimizar a pesquisa da melhor forma possível, se fez necessário dividi-la em 6 etapas, conforme mostra a Fig. 2. A divisão do processo é iniciada com a coleta dos dados, em seguida houve a necessidade de se aplicar métodos de filtragem e normalização, para posteriormente iniciar a implementação da RNA no Matlab®, onde foram realizadas as etapas de treinamento e validação da rede. De posse da rede já implementada foram realizadas algumas validações no período de uma semana, logo depois os resultados foram analisados, comparando a potência real e a potência prevista.

- Coleta dos dados

Para treinar a RNA foram utilizados dados de irradiação solar global e temperatura como variáveis de entrada, coletados na estação meteorológica da UFERSA Espaço ASA/UFERSA

(UFERSA, 2017). A escolha dessas variáveis se justifica pela forte influência que ambas possuem sobre a geração de energia de sistemas fotovoltaicos. Como variável de saída utilizou-se a potência gerada pelo sistema fotovoltaico, sendo obtida por meio do inversor, uma vez que o mesmo possui a função de armazenar as informações por um determinado período. Os dados foram coletados no período de 01 de outubro de 2017 a 31 de março de 2018, totalizando 6 (seis) meses, o que equivale a 12041 amostras.

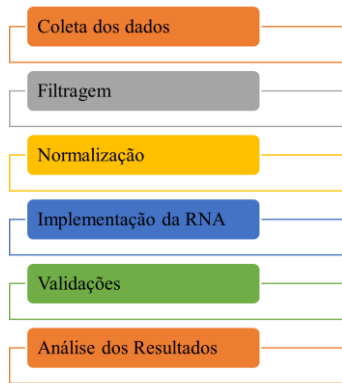


Fig. 2: Etapas da pesquisa

- Filtragem

Devido à intermitência característica presente nos dados coletados, foi necessário realizar o processo de filtragem com o intuito de evitar possíveis imprecisões nos resultados. Com isso, realizou-se dois processos de filtragem, o primeiro, com o auxílio do Excel®, e foram retirados os valores zero da planilha. Para o segundo processo de filtragem utilizou-se o Matlab®, por meio do comando *filter* baseado no método estatístico da média móvel. Após a aplicação das duas técnicas de filtragem, observou-se uma menor incidência de ruídos nas amostras.

- Normalização

A técnica de normalização foi utilizada para reduzir problemas quando se trabalha com variáveis que possuem unidades e dispersões distintas. É comum que as amostras não possuam uma variação com a mesma ordem de grandeza, afetando o treinamento de forma que haja uma atribuição de maior importância para certas variáveis e outras não. O processo de normalização consiste em ajustar os valores de todas as variáveis, que contêm escalas diferentes, convertendo-os em um tamanho comum a todos. Para isso, utilizou-se o método que baseia-se em (1).

$$y = \frac{(y_{máx} - y_{mín}) * (x - x_{mín})}{x_{máx} - x_{mín}} + y_{mín} \quad (1)$$

Onde x é o elemento do vetor a ser normalizado; $x_{máx}$ e $x_{mín}$ são os valores máximo e mínimo do vetor a ser normalizado; y é o valor normalizado de x ; $y_{máx}$ e $y_{mín}$ são os valores máximo e mínimo do intervalo em que se deseja normalizar os elementos. Os valores de $y_{máx}$ e $y_{mín}$ foram os mesmos para todas as variáveis, sendo 1 e 0 respectivamente.

- Implementação da RNA

Para o processo de implementação da RNA utilizou-se o *software* Matlab®, onde foram realizados o treinamento e as validações. Conforme já mencionado, o treinamento da rede teve como variáveis de entrada dados de irradiação solar global e temperatura do local de estudo, bem como a potência elétrica gerada pelo SFCR, sendo inserida como variável de saída, ambas em intervalos de 10 minutos. Além disso, se fez necessário a configuração de alguns parâmetros importantes para que o treinamento fosse efetivado, mostrados na Tabela 1. Esses parâmetros foram definidos, após realizar diversas combinações diferentes, buscando obter o melhor desempenho.

Tabela 1. Configuração dos parâmetros da rede

Tipo de rede	<i>Feedforward</i>
Número de variáveis de entrada	2
Número de variáveis de saída	1
Número de camadas ocultas	3
Número de neurônios nas camadas ocultas	(20,10,1)
Algoritmo de treinamento	trainlm
Função de ativação	(tansig,logsig,purelin)
Treinamento	70%
Validação	15%
Teste	15%
Tipo de divisão das amostras	dividerand

- Validações

As validações propostas servem como teste para verificar os resultados obtidos e analisar se a RNA é capaz de prever, de forma eficaz, a potência gerada pelo sistema a partir dos dados de entrada inseridos. O período selecionado para realizar as validações foi de 01/10/2017 a 07/10/2017, logo, os dados referentes a esses dias foram excluídos do conjunto de amostras de treinamento.

- Análise dos Resultados

A análise dos resultados obtidos com as validações requer métodos que demonstrem seu desempenho, que além de realizar comparações entre o real e o previsto, possa também averiguar essas comparações por meio de métodos confiáveis. Desta forma, foram aplicados cálculos de erros, tais como, Erro Absoluto, Erro médio (ME), Erro Absoluto Médio (MAE) e Regressão linear.

Utilizou-se também análises percentuais com base no cálculo das frações percentuais ME, conforme calcula Guarnieri (2006), onde o ME% representa a razão entre os valores de erro e a média dos valores reais multiplicadas por 100. Esses cálculos, segundo Guarnieri (2006), são comumente expressos como frações percentuais em relação à média das previsões, isto é, como erros relativos.

5. ANÁLISE DOS RESULTADOS

5.1 Treinamento

No treinamento da rede *feedforward* utilizando 12041 amostras em intervalos de 10 minutos, atribuiu-se o número de épocas com 100 iterações como critério de parada. No entanto, a rede convergiu com 41 iterações após atingir 10 checagens. Essa checagem de validação indica que, para o caso de não existir um aumento na taxa de erro até um número pré-estabelecido de iterações consecutivas, o treinamento será interrompido, para este caso, foi atribuído o número de 10 iterações consecutivas, e após atingir esse valor, o treinamento terminou. Outras informações obtidas durante o treinamento podem ser vistas na Fig. 3.

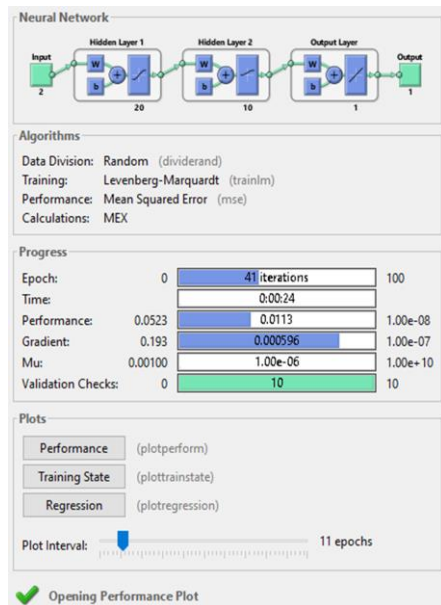


Fig. 3: Janela de treinamento

Após o treinamento da RNA ser finalizado foi possível analisar a eficiência desse treinamento por meio do diagrama de regressão, mostrado na Fig. 4.

Além de apresentar um coeficiente de correlação próximo a 1 em todas as etapas, nota-se que grande parte das amostras tendem a se aproximar da reta alvo. Com base nessas informações, pode-se afirmar que a rede desempenhou um treinamento adequado, com dados previstos que se aproximam satisfatoriamente do desejado. Vale destacar, que o treinamento seria considerado ideal caso as saídas da RNA e o alvos fossem exatamente iguais, e assim, o valor obtido na regressão seria igual a 1.

5.2 Validações propostas

As validações foram realizadas com o intuito de verificar a capacidade de previsão da RNA, bem como o desempenho de previsão da mesma para as variações de geração existentes

em sistema solar fotovoltaico ao longo do dia. As curvas de comparação entre a curva real e a curva prevista pela RNA são mostradas na Fig. 5, onde as Figuras 5a, 5b, 5c, 5d, 5e, 5f e 5g representam respectivamente a semana de 01/10/2017 a 07/10/2017.

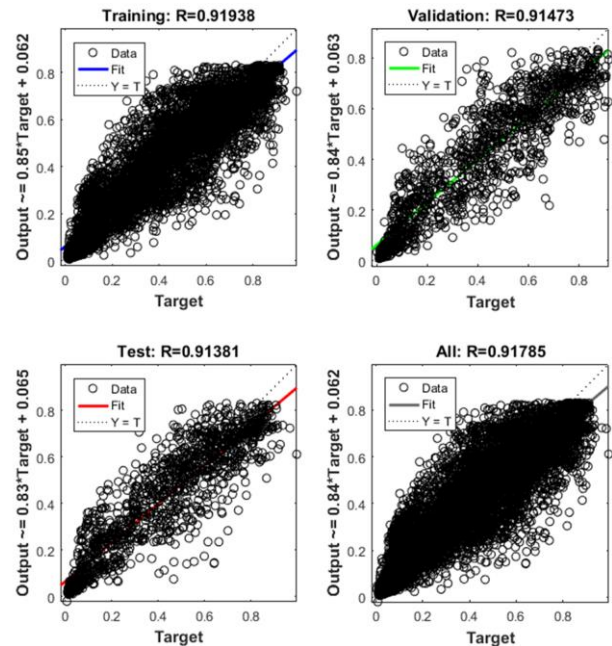

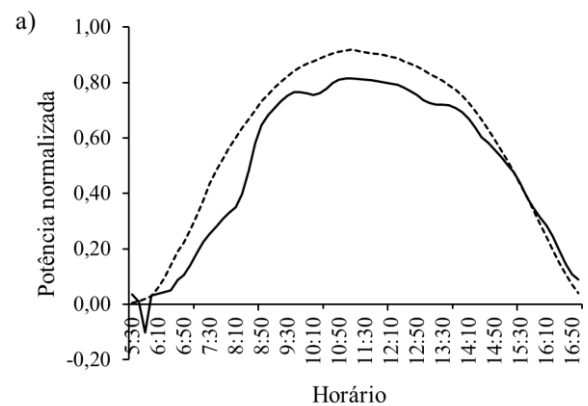


Fig. 4: Diagrama de Regressão Linear das etapas do treinamento




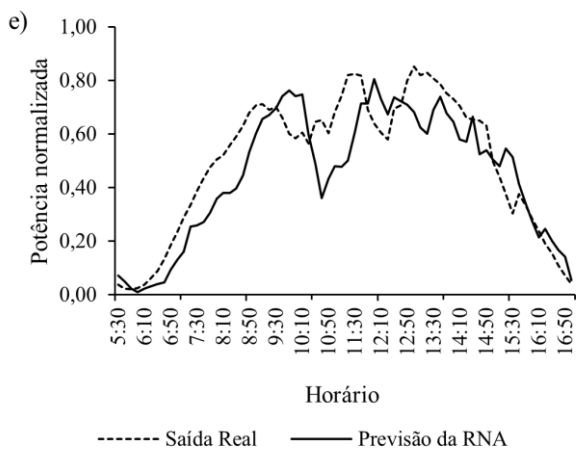





Fig. 5: Curvas de comparação entre o real x previsto

Ao analisar as curvas da Fig. 5, nota-se que a Previsão da RNA tenta acompanhar os detalhes das curvas reais mesmo em dias com a geração de potência apresentando maiores variações. Apesar disso, no dia 04/11/2017 as variações da curva real não são bem acompanhadas pela curva de previsão. Já para o dia 01/10/2017 (Figura 5a) é possível verificar poucas variações na geração de potência, e visualmente essa condição favorece o acompanhamento da RNA.

Vale destacar que apenas a análise visual não informa com precisão a eficiência dos resultados obtidos, para isso, foram elaborados digramas de regressão dessas validações, onde os mesmos indicam Coeficientes de Correlação (R) com índices satisfatórios, e uma distribuição de dados que possui forte tendência em acompanhar a reta alvo, indicando assim poucos desvios entre os valores reais e previstos. Na Fig. 6 são abordadas essas informações.

Observa-se que todas as validações propostas apresentaram coeficiente de correlação na faixa de 0,88-0,97, onde o maior índice encontrado foi para o dia com pouca variação de geração, podendo confirmar, a partir dos resultados de regressão, o melhor desempenho da rede neural para essa situação. Além disso, nota-se que os demais dias em que atingiram maiores variações de potência resultam em diagramas de regressão com dados mais dispersos, no entanto não reduz significativamente os coeficientes de correlação.

Com o objetivo de obter uma maior confiabilidade dos resultados obtidos com as validações, foram calculados erros, onde cada erro busca indicar o grau de proximidade entre os dados reais e os previstos pela rede neural. Na Tabela 2 é possível verificar os erros calculados.

Tabela 2. Erros das validações propostas

Período		ME	MAE	ME%
Dia 1	01/10/2017	0,07917	0,0885	13,59
Dia 2	02/10/2017	0,05142	0,1003	10,32
Dia 3	03/10/2017	0,04400	0,0910	10,15
Dia 4	04/10/2017	0,12405	0,1366	22,96
Dia 5	05/10/2017	0,05144	0,1037	10,32
Dia 6	06/10/2017	0,06511	0,0900	11,95
Dia 7	07/10/2017	0,06683	0,0816	11,70

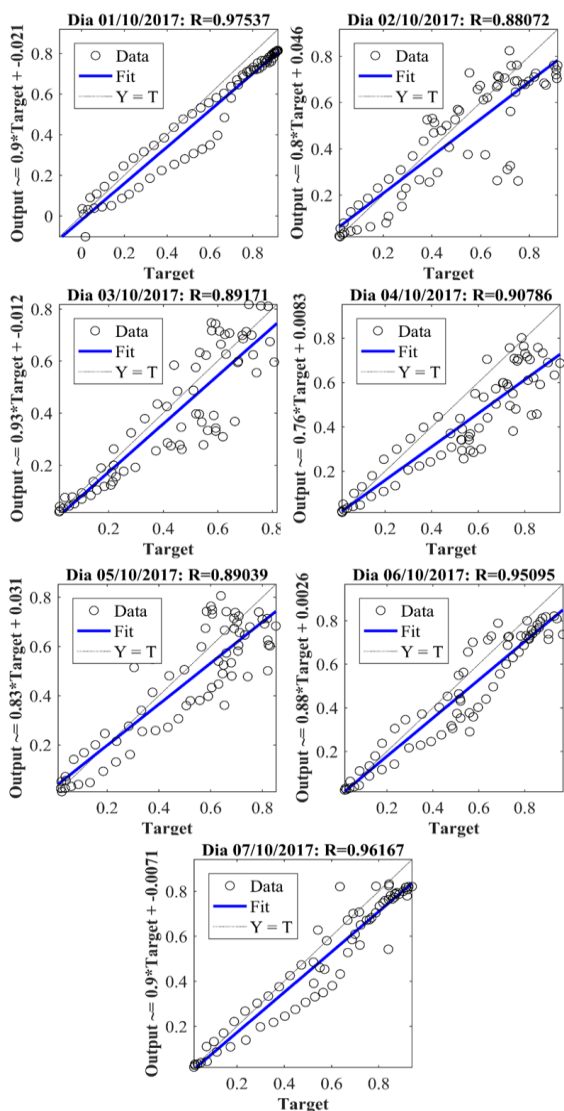


Fig. 6: Diagramas de regressão das validações propostas

Os valores de ME encontrados indicam que a rede apresentou um melhor desempenho, com menor erro, para a previsão do dia 03/11/2017. De modo geral, é possível observar que os erros possuem valores próximos, na faixa de 0,04 a 0,07, com exceção para o dia 04/11/2017, onde o EM se distancia um pouco dos demais e atinge 0,12405. Já para o MAE, houve um aumento em relação ao ME, pois o método aplicado nessa métrica mostra o quanto a previsão está longe dos valores reais, independente se acima ou abaixo. Outro fato importante a ser destacado refere-se ao MAE que não apresentam diferenças significativas de um dia para o outro, ficando na mesma faixa de valores entre 0,08 e 0,13.

Para uma análise percentual das validações utilizou-se o ME%, onde o maior erro obtido foi para o dia 04/10/2017 com aproximadamente 23%. Os demais dias apresentaram EM% na faixa de 10% a 13%, com pouca diferença entre eles.

A proximidade entre as curvas é o principal ponto de estudo deste trabalho, pois a partir dela é possível verificar o grau de precisão das previsões, e consequentemente se o desempenho

da rede neural foi adequado. Diante disto e visando resultados mais próximos da realidade, os dados foram desnormalizados e realizou-se comparações com a unidade real dos dados, o Watt (W). Os resultados desta análise são abordados nas Figs. 7 e 8, com o somatório das potências reais e previstas, bem como a média aritmética delas.

O gráfico da Fig. 7 mostra o somatório das potências reais e previstas ao longo de cada dia. Nela, é possível observar que o dia 03 se destacou com a previsão mais próxima da potência real, apresentando um Erro Absoluto (EA) de 8,82kW. Já o dia 04, que atingiu um valor de EA de 24,88kW, indicou um maior distanciamento entre as potências previstas e reais. Apesar do dia 03 apresentar o menor EA, nota-se que ele não demonstra diferenças significativas em relação aos demais dias, com exceção apenas para o dia 04.

Fig. 7: Comparação entre o somatório das potências previstas e reais das validações propostas

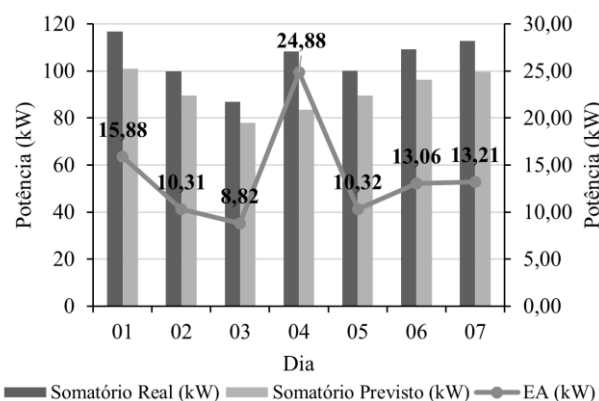
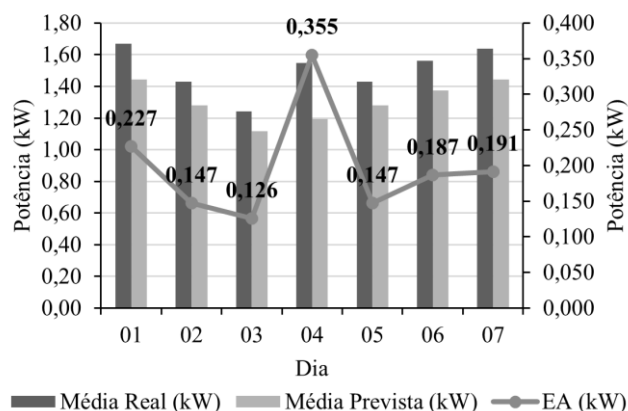


Fig. 8: Comparação entre as potências médias previstas e reais das validações propostas



O mesmo ocorre ao calcular as potências médias previstas. Conforme pode ser visto na Fig. 8, os dias 03 e 04 permaneceram nos extremos das análises, apresentando respectivamente, o menor e maior EA. Os demais dias não apresentaram EA com diferenças consideráveis em relação ao dia 03, permanecendo com erros na faixa de 0,147 a 0,227.

De modo geral, os valores de potência médias não apresentam diferenças significativas entre os reais e os

previstos, onde o EA não ultrapassa 0,3kW. Isso significa dizer que a geração diária média prevista do sistema fotovoltaico estudado difere em no máximo 0,3kW da potência gerada real média para os períodos analisados.

6. CONCLUSÕES

A previsão da geração de fontes intermitentes é algo desafiador, pois exige métodos que operem com as variações climáticas inerentes. Por não apresentar padrões predefinidos, essas variações limitam os métodos de previsão a serem utilizados. Com isso, a RNA apresenta características suficientes para atuar, de forma eficiente, frente a essas variações climáticas.

Por meio das análises realizadas foi possível verificar que a RNA apresentou um comportamento satisfatório, onde as curvas demonstram a aproximação entre os dados reais e previstos. Os resultados dos métodos de análises de desempenho também confirmaram a performance positiva da rede, com coeficientes de correlação que variavam na faixa de 0,88 a 0,96, em que os índices menores são resultados dos dias com maiores variações de potência.

Além disso, os erros encontrados não apresentaram valores elevados para o período estudado, exceto para o dia 04/11/2017, no qual, os erros ME, MAE E ME% se destacaram com os maiores valores em relação aos demais dias. Para o dia em questão foi detectado também uma maior divergência entre as curvas reais e previstas.

Nota-se ainda na análise com as unidades reais que as diferenças de previsão podem ser vistas em Watt, viabilizando a interpretação dos resultados, onde o somatório das potências reais e previstas mostram o menor e maior EA para os dias 03/11/2017 e 04/11/2017 com 8,82kW e 24,88kW, respectivamente. A potência média prevista não apresentou diferenças significativas em relação à potência média real do sistema, com EA que varia na faixa 0,147kW a 0,355kW.

De maneira geral e tendo em vista os aspectos analisados, percebe-se que a previsão da RNA se aproxima, sem grandes prejuízos, dos dados reais, confirmando a eficiência da RNA quanto ao seu desempenho em prever a potência gerada de um SFCR.

Recomenda-se como trabalhos futuros a adição de outras variáveis de entrada (velocidade do vento, temperatura do módulo, umidade) para verificar os possíveis impactos dessas variáveis no desempenho da RNA.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Código de Financiamento 001.

A estação meteorológica Espaço ASA/UFERSA, pelo fornecimento dos dados para a realização da pesquisa.

REFERÊNCIAS

- ANEEL, Agência Nacional de Energia Elétrica. (2015) Geração Distribuída - Micro e Minigeração Distribuídas.
- CRESESB, Centro de Referência para Energia Solar e Eólica Sérgio de Salvo Brito. (2004). *Manual de engenharia para sistemas fotovoltaicos*. Rio de Janeiro.
- Dias, M. P. A., Inácio, M. J., Maia, N. A., Carvalho Júnior, A. B. (2019). Aplicação de Redes Neurais Artificiais para previsão de incidência solar: Um estudo comparativo. 2019. 10 f. XXII Encontro Nacional de Modelagem Computacional (ENMC) e X Encontro de Ciências e Tecnologia de Materiais (ECTM). Juiz de Fora/MG.
- Djalab, A., Hafaifa, A., Rezaoui, M. M., Teta, A., Sabri, N. (2019). An Intelligent Faults Diagnosis and Detection Method Based on Artificial Neural Networks for Photovoltaic Array. 2019. rd International Conference on Applied Automation and Industrial Diagnostics. Elazig, Turquia.
- Guarnieri, R.A. (2006). Emprego de Redes Neurais Artificiais e Regressão Linear Múltipla no refinamento das previsões de radiação solar do modelo ETA. 171 f. *Dissertação (Mestrado)* - Curso de Pós-graduação em Meteorologia, Inpe, São José dos Campos.
- Haykin, Simon. (2001). *Redes Neurais: Princípios e prática*. 2. ed. Porto Alegre: Bookman. 900 p.
- Kayri, I., Genoglu, M.T. (2017) Prediction of power production from a single axis photovoltaic system by Artificial Neural Networks. In: *International Conference on Engineering of Modern Electric Systems (EMES)*. Romênia. Conferência. Romênia: IEEE, 2017. p. 212 - 215.
- Martins, M.A.S., Mette, F., Macêdo, G.R. (2008). A utilização de Redes Neurais Artificiais para a estimação dos preços da Petrobrás PN na Bovespa. 2008. 16 f. *ConTexto – Revista do Programa de Pós-Graduação em Controladoria e Contabilidade da UFRGS*. Porto Alegre.
- Silva, I.N., Spatti, D.H., Flauzino, R.A. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático*. São Paulo: Artliber.
- Torres, R.G. (2015). Desenvolvimento de metodologia para avaliação do potencial de utilização de sistemas de energia solar fotovoltaica em meios urbanos. 163 f. *Dissertação (Mestrado)* - Pós-graduação em Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- UFERSA, Universidade Federal Rural do Semi-Árido. (2017). Estação meteorológica Espaço Abelhas Semiárido.
- Zarkov, Z., Stoyanov, L., Draganovska, I., Lazarov, V. (2019). *Application of ANN for solar radiation forecasting - Case study of Oryahovo*. Electrical Engineering Faculty Conference (BULEF). Bulgária.