

Previsão de Curto Prazo para Geração Fotovoltaica a partir de Dados Meteorológicos via RNA

Darlan R. Fischer, Joelson L. Paixão, Jordan P. Sausen,
Alzenira R. Abaide

Universidade Federal de Santa Maria, Santa Maria, RS, Brasil (darlan_f@hotmail.com).

Abstract: The dissemination of photovoltaic systems at distribution level as a complement to centralized generating units motivates the hourly capacity forecasting of distributed generation. Due to the dependence on weather conditions, photovoltaic systems present considerable variability in terms of output power. To predict this intermittence, the present study uses meteorological and generation data from a 100kWp photovoltaic system located in the South of Brazil to predict short-term generation through Artificial Neural Networks (ANN). As model input, local characteristics are used to analyze the influence of different input variables. As a result, the number of neurons in the ANN is presented, as well as the factors that have the greatest influence on the generation forecast for one hour ahead.

Resumo: A disseminação de sistemas fotovoltaicos em nível de distribuição de energia como complemento as unidades geradoras de grande porte centralizadas motivam a pesquisa relacionada a previsão da capacidade horária de geração distribuída de eletricidade. Em função da dependência das condições climáticas, os sistemas fotovoltaicos apresentam variabilidade considerável em termos de potência de saída. Para prever essa intermitência, o presente estudo faz uso de dados meteorológicos e de geração de um sistema fotovoltaico de 100kWp, localizado no Sul do Brasil, para prever a geração de curto prazo a partir de Redes Neurais Artificiais (RNAs). Características locais são as informações de entrada do modelo, que visa analisar a influência de diferentes variáveis de entrada. Como resultado, é apresentado a quantidade de neurônios da RNA, bem como os fatores que exercem maior influência na previsão da geração para uma hora a frente.

Keywords: forecast; distributed generation; photovoltaic systems; Artificial neural networks; meteorological data.

Palavras-chaves: previsão; geração distribuída; sistemas fotovoltaicos; redes neurais artificiais; dados meteorológicos.

1. INTRODUÇÃO

O aquecimento global e a considerável variabilidade dos preços dos combustíveis fósseis nas últimas décadas incentivaram a disseminação de sistemas de geração baseados em fontes de energias renováveis (RES – *Renewable Energy Sources*), ou seja, fontes de energia alternativas e sustentáveis. Segundo (Qin, Hu and Li, 2020) a porcentagem de eletricidade gerada a partir de fontes renováveis aumentará de 6% em 2015 para 38% em 2040. Embora as fontes de energia solar, eólica, hidrelétrica e geotérmica auxiliem na descarbonização da matriz energética, surgem problemas inerentes a intermitência de geração em função da dependência de condições climáticas (Sobri, Koohi-Kamali and Rahim, 2018). Devido às vantagens relacionadas a abundância e por ser inesgotável, a energia solar vem aumentando gradualmente a atenção como uma boa solução para a geração de energia alternativa (Wang, Su and Shu, 2016).

Conforme relatado por (Mellit, Sağlam and Kalogirou, 2013), a capacidade fotovoltaica global foi aumentando a uma taxa média de crescimento anual superior a 40% desde 2000 e possui um potencial significativo de crescimento a longo prazo nas próximas décadas. Até 2050, a energia solar fotovoltaica fornecerá 11% da eletricidade global, isto é, 4500 TWh por ano, correspondendo a 3000 GW de capacidade fotovoltaica instalada cumulativa.

Um grande desafio das fontes de energia renováveis é sua natureza volátil. Ao contrário das usinas convencionais, não se pode acessar o recurso a qualquer momento. A mudança das condições meteorológicas e climáticas do local são fatores estocásticos na produção de energia solar fotovoltaica. Por este motivo, previsões precisas são vitais para a integração da energia renovável na rede (Wolff *et al.*, 2016).

A previsão da produção de energia solar fotovoltaica pode contribuir para um uso mais eficiente e econômico desse recurso e permite gerenciar a quantidade de energia obtida a partir das plantas fotovoltaicas, a fim de compatibilizar com a

demanda emergente. Além disso, o crescente desenvolvimento de sistemas elétricos inteligentes vem demandando o conhecimento do montante de energia gerada pelas fontes renováveis, a fim de gerenciar os fluxos de energia dentro da própria rede inteligente. Sendo assim, a previsão da potência de uma usina fotovoltaica nas próximas horas ou dias é necessário para a integração ideal dessa produção nos sistemas de energia, bem como do controle do seu despacho ótimo (De Leone, Pietrini and Giovannelli, 2015).

A literatura aponta que uma boa exatidão na previsão da geração fotovoltaica pode contribuir com a redução da variabilidade resultante da incerteza da potência de saída do sistema fotovoltaico, melhoria da estabilidade do sistema, aumento do nível de penetração do sistema fotovoltaico em sistemas de distribuição, redução do custo de manutenção de dispositivos auxiliares, além de ajudar os operadores da rede a prever um caso de escassez ou abundância de energia solar fotovoltaica (De Giorgi, Congedo and Malvoni, 2014).

Desta forma, este trabalho tem como objetivo desenvolver uma metodologia para realizar a previsão de geração de energia para curto prazo de um sistema fotovoltaico de 100kWp, localizado no município de Santa Maria-RS, para o período de uma hora a frente, considerando um histórico de dados de diferentes variáveis meteorológicas e de geração de energia fotovoltaica.

2. REVISÃO BIBLIOGRÁFICA

A geração de energia elétrica por meio da radiação solar é considerada uma geração de energia limpa, renovável, silenciosa, de baixa manutenção, baixo impacto na fauna e flora e adequada para o desenvolvimento sustentável, tendo uma vasta gama de aplicação, dentre as principais se podem citar: iluminação pública, bombeamento de água, agricultura, sistemas fotovoltaicos integrados em edificações, dessalinização de água, monitoramento meteorológico, telecomunicações (Farret, 2014; Pinho and Galdino, 2014). Entretanto, os altos custos dos sistemas fotovoltaicos (SF) sempre foram uma barreira para a disseminação desta tecnologia (El Chaar, Lamont and El Zein, 2011).

Por via de regra, um SF é composto pelo conjunto gerador, unidade de controle e, opcionalmente, banco de armazenamento. Os elementos necessários para a instalação de um SF irão depender da configuração do sistema e de sua aplicabilidade. Deste modo, os principais componentes de um sistema fotovoltaico são: módulos fotovoltaicos, condutores, inversores, dispositivos de proteção, supervisão, controle e medição. No caso de sistemas isolados, opcionalmente, é comum a presença de um banco ou conjunto de baterias e controladores de carga (Pinho and Galdino, 2014).

2.1 Influência das variáveis meteorológicas

A eficiência dos SFs é determinada a partir da razão entre a energia elétrica gerada na saída do sistema e a energia solar recebida pelo módulo ou célula fotovoltaica. A eficiência de um sistema pode ser facilmente determinada através dos

valores de potência de entrada na célula (radiação incidente em um intervalo de tempo) e a potência de saída (produto da corrente de saída e a tensão de saída).

No entanto, muitos fatores influenciam na eficiência dos módulos fotovoltaicos, internos ou/externos. Dentre os fatores internos pode-se destacar a composição e a pureza dos materiais, os métodos de fabricação, a estrutura das células, cabos e conexões elétricas. Dentre os fatores externos podem ser citados o sombreamento por árvores e/ou nuvens, chuva, poeira, radiação, temperatura ambiente, umidade relativa do ar, além da velocidade e direção do vento (Cantor 2017).

Em termos de variáveis meteorológicas, de acordo com (Francisco *et al.*, 2019; Cerqueira, 2019; Tamizhmani *et al.*, 2003) a radiação solar possui relação direta com a geração de energia fotovoltaica, sendo um dos dois principais fatores. Outro importante fator climático que interfere diretamente na geração de energia fotovoltaica é a temperatura ambiente (Andrade, 2008; Silva, 2018).

2.2 Previsão de geração fotovoltaica

A instalação de usinas fotovoltaicas em grande escala conectadas à rede introduz volatilidade significativa, o que traz grandes desafios relacionados à estabilidade do sistema, confiabilidade, balanço de energia elétrica, compensação de potência reativa e resposta de frequência. Deste modo, a previsão de energia fotovoltaica é uma das alternativas para amenizar essas adversidades (Wan *et al.*, 2016).

A previsão da produção de energia fotovoltaica é baseada na abordagem clássica da previsão de séries temporais de geração fotovoltaica e condições climáticas, que são usadas para calcular a energia elétrica de SFs, modelos autoregressivos, média móvel e médias móveis autorregressivas, frequentemente usados para modelar estruturas dinâmicas lineares. Além disso, diferentes pesquisas mostram que modelos não lineares e não estacionários são mais flexíveis na captura de características desses dados e que, em alguns casos, são melhores em termos de estimativa e previsão. Hoje em dia, modelos avançados, baseados em abordagens não lineares, estão se espalhando rapidamente nas previsões de produção de energia, usando rede neural, máquinas de vetores de suporte e modelos híbridos (Da Silva Fonseca *et al.*, 2011).

Nos últimos anos, a previsão de energia fotovoltaica tem sido amplamente estudada. Em (Mellit, Sağlam and Kalogirou, 2013) foram desenvolvidos dois modelos de redes neurais artificiais (RNA) para previsão de energia fotovoltaica em um módulo de silício policristalino de 50 Wp. O primeiro modelo foi utilizado para estimar a energia produzida em dias nublados com uma irradiação solar média diária menor ou igual a 400 W/m²/dia. Já, o segundo modelo é utilizado para estimar a energia produzida em dias ensolarados com sua irradiação solar média superior à 400 W/m²/dia. Para avaliar o desempenho dos modelos projetados, foram levados em consideração os seguintes parâmetros: coeficiente de correlação (R), raiz do erro quadrático médio (RMSE) e erro de viés médio (MBE).

Em (Izgi *et al.*, 2012), foi empregada a metodologia de RNAs, para prever a energia fotovoltaica derivada de um SF de 750 Wp em diferentes horizontes de tempo. No mesmo segmento (Yona *et al.*, 2013) utilizou um conjunto entre teoria Fuzzy, Rede Neural Recorrente (RNN) e relato de dados do tempo para prever a potência de saída de um sistema fotovoltaico baseado na previsão de insolação para um dia à frente. A teoria difusa foi utilizada para determinar a insolação horária a partir de dados meteorológicos, como quantidade de nuvens, umidade e temperatura, em seguida, a saída do modelo difuso foi utilizada como valor de entrada para treinar a RNN.

Um modelo de previsão de potência de saída fotovoltaica foi desenvolvido em (Hossain *et al.*, 2017) para a previsão de uma hora à frente em três instalações fotovoltaicas a partir do algoritmo *Extreme Learning Machine* (ELM). Para prever a potência de saída fotovoltaica do dia seguinte, os modelos desenvolvidos foram treinados e testados usando radiação solar média diária (W/m^2), velocidade do vento (m/s), temperatura ambiente e do módulo ($^{\circ}C$). Os resultados obtidos no modelo proposto foram comparados com outros dois modelos, sendo eles o de regressão por vetores de suporte (SVR) e RNA.

Deste modo, os modelos de previsão dependem fortemente da resolução espacial e temporal das variabilidades meteorológicas, seleção de parâmetros de entrada e algoritmos de treinamento. Para um sistema fotovoltaico, existem muitos fatores que podem influenciar na potência de saída, como radiação solar, temperatura, insolação, velocidade do vento e ângulo de instalação. Devido à variabilidade da irradiação solar e demais fatores ambientais, a potência de um sistema fotovoltaico pode mudar dinamicamente com o tempo.

3. METODOLOGIA

Inicialmente são definidas as etapas que serão executadas, e também estabelecidas as ferramentas que serão utilizadas nas modelagens e simulações, para alcançar os objetivos pretendidos, que são estabelecer o número de neurônios de uma RNA para a previsão de geração de energia e a influência das variáveis meteorológicas na geração fotovoltaica.

Desta maneira, propõe-se uma previsão de geração fotovoltaica de curto prazo para uma hora à frente, a partir de um modelo baseado em Redes Neurais Artificiais (RNA). Neste caso a rede é do tipo Perceptron de Múltiplas camadas (MLP), sendo esta recorrentemente utilizada em problemas de reconhecimento de padrões e previsões para diferentes aplicações. A Fig. 1, apresenta o diagrama estrutural da metodologia de previsão de geração desenvolvida, demonstrando as principais conexões entre o conjunto de informações (banco de dados), o tratamento dos dados de entrada e saída e o modelo de previsão.

Desta forma, inicialmente realiza-se a etapa de tratamento de dados (entrada e saída), em seguida o desenvolvimento da RNA, e por fim, os resultados são obtidos através da

avaliação da capacidade de previsão. Na Fig. 2, é possível observar a sequência das etapas a serem realizadas.

Os bancos de dados utilizados na metodologia proposta, conforme a Fig. 1, são compostos por dois grupos de informações gerais, sendo um com informações meteorológicas locais e outro com os dados históricos de geração da planta fotovoltaica adotada no estudo. Esses dados são utilizados para realizar o treinamento RNA e também a previsão da geração fotovoltaica.

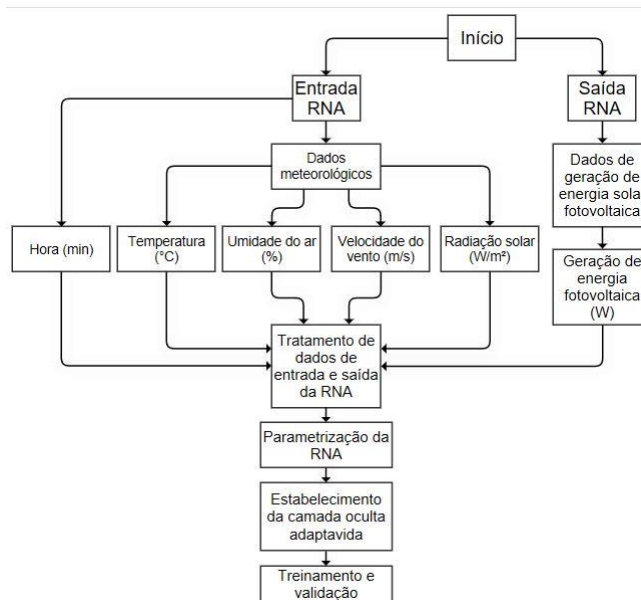


Fig. 1 Diagrama estrutural da metodologia desenvolvida.




Fig. 2 Sequência das etapas desenvolvidas.

Se considera, nesta metodologia, a análise de quatro variáveis meteorológicas como entradas do modelo proposto, sendo elas: a temperatura ($^{\circ}C$), a umidade relativa do ar (%), a velocidade do vento (m/s) e a radiação solar (W/m^2). Além disso, o valor horário (min) das variáveis também foi empregado como entrada do modelo. A determinação da utilização destas variáveis foi baseada em estudos bibliográficos. Para a saída do modelo proposto, foi considerado a variável de geração de energia fotovoltaica (W).

Como o objetivo do trabalho é a estimação da geração fotovoltaica de curto prazo considerando uma hora a frente, a padronização dos dados se deu da seguinte forma: as variáveis de entrada foram consideradas no instante atual (t) e a saída do modelo para uma hora a frente ($t+60$). Avaliando o período de incidência solar no município de estudo,

verificou-se que o mesmo ocorre predominantemente entre 7:00h (420 minutos) e 18:00 h (1080 minutos).

Desta forma, os dados de entradas foram padronizados com início às 6:00h (360 minutos) para realizar a primeira previsão às 7:00h, e com fim às 17:00h (1020 minutos) para realizar a última previsão às 18:00h. A Tabela 1 exemplifica a padronização de dados.

Tabela 1. Dados de entrada e saída padronizados

Entrada (t)					Saída (t+60)	
Hora (min)	Temperatura (°C)	Umidade do ar (%)	Velocidade do vento (m/s)	Radiação solar (W/m²)	Hora (min)	Geração fotovoltaica (Wp)
360	17,6	87	2,3	0,014444	420	0
1020	21,3	69	1,5	178,6944	1080	2050

A Fig. 3, apresenta o diagrama da rede neural do tipo *feedforward MLP* projetada, relacionando as cinco variáveis de entrada do modelo principal, atreladas aos “n” neurônios da camada oculta, que por sua vez, encontra-se conectada a camada de saída, composta por um neurônio.

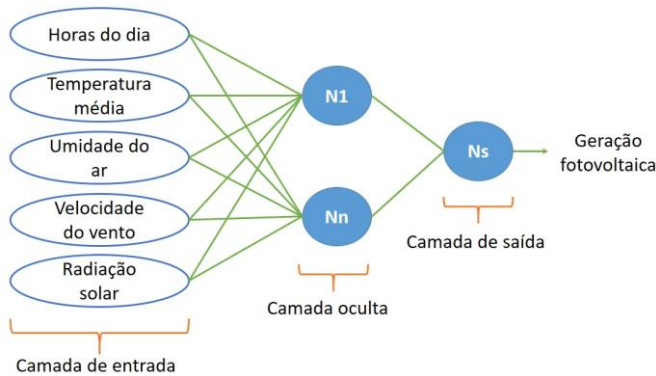


Fig. 3. Diagrama da RNA projetada.

A Tabela 2, apresenta um resumo relacionado aos parâmetros empregados no modelo da RNA. Conforme (Pelland *et al.*, 2013), várias métricas foram propostas e utilizadas para quantificar a precisão das previsões de geração fotovoltaica. No entanto, alguns autores como (Beyer *et al.*, 2009) e (Madsen *et al.*, 2005), buscaram estabelecer as principais métricas utilizadas, que compreendem o erro médio absoluto (MAE), conforme expresso em (1), raiz do erro médio quadrático (RMSE), conforme expresso em (2), e erro de viés médio (MBE), conforme expresso em (3).

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

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

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

Sendo e_i definido em (4), por:

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

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 até o N ésimo valor.

Estas mesmas métricas, citadas por (Beyer *et al.*, 2009) e (Madsen *et al.*, 2005), foram também utilizadas por (Teo, Logenthiran and Woo, 2016; Mellit, Sağlam and Kalogirou, 2013; Yona *et al.*, 2013; Shi *et al.*, 2012), em seus estudos de previsão de geração fotovoltaica.

Segundo a (Pelland *et al.*, 2013), o MAE representa a magnitude média dos erros de previsão, ou seja, demonstra a distância média entre os valores medidos e as previsões do modelo. Já o RMSE, é uma métrica que fornece mais peso aos maiores erros de previsão. Por fim, a métrica MBE, conforme explicado por (Ahmad e Anderson, 2014), é uma indicação do desvio médio dos valores previstos dos dados medidos, tendo em vista fornecer informações a respeito do desempenho a longo prazo dos modelos.

A função de ativação aplicada, tanto na camada oculta como na camada de saída, é a sigmoide tangente hiperbólica. Esta função é aplicada principalmente em problemas de Perceptron Multicamadas, devido a sua assimetria, apresentando resultados negativos e positivos. A função sigmoide hiperbólica tem a possibilidade de assumir valores na faixa de -1 e +1.

Tabela 2. Parâmetros empregados no modelo da RNA

Critério	Valor definido
Número de entradas	5
Número de camadas ocultas	1
Número de neurônios da camada intermediária	Adaptativo (10 a 120)
Número de neurônios da camada de saída	1
Função de ativação da camada oculta	Sigmoide tangente hiperbólica
Função de ativação da camada de saída	Sigmoide tangente hiperbólica
Porcentagem de dados de treinamento	70%
Porcentagem de dados de validação	15%
Porcentagem de dados de teste	15%

A avaliação do desempenho de treinamento da rede neural é realizada predominantemente a partir do coeficiente de correlação de Pearson. O coeficiente de Pearson (CP), é uma medida de correlação entre duas variáveis, sendo assim, é capaz de apontar o grau de relação entre os pares quando estes apresentam comportamento linear. Este coeficiente,

normalmente representado por ρ apresenta valores entre -1 e 1 (Santos, 2018).

4. ESTUDO DE CASO

Para aplicação da metodologia, tomou-se para estudo de caso uma usina fotovoltaica, presente na Universidade Federal de Santa Maria (UFSM), e os respectivos dados históricos de geração da mesma e meteorológicos do local. Esses dados estão divididos em dois grupos. O primeiro grupo de dados utilizados neste trabalho, refere-se aos dados meteorológicos da estação do Instituto Nacional de Meteorologia (INMET), localizada no município de Santa Maria – RS. O segundo conjunto de informações, corresponde aos dados de geração fotovoltaica da usina de geração distribuída de energia elétrica (INCT-GD) da UFSM. A usina fotovoltaica é composta por 16 *strings*, onde cada *string* possui 24 módulos fotovoltaicos de 270 Wp conectados em série, tendo como potência total um valor de 103,68 kWp.

A base de dados utilizada neste trabalho corresponde ao período de 4 meses, compreendendo os meses de fevereiro de 2019 até maio de 2019. Sendo que os meses de fevereiro, março e abril foram utilizados para treinamento da rede e o mês de maio para previsão. O intervalo de coleta do conjunto de informações provenientes da estação meteorológica e da usina de geração distribuída foi de uma hora.

O total de dados utilizados para realizar o treinamento da rede, compreende 5280 dados de entrada e 1056 dados de saída. Inicialmente, foi definido um intervalo de quantidade de neurônios para serem aplicados no modelo. A faixa determinada no estudo foi de {10, 15, 20, 25, 30, 35, 40, 45, 60, 90 e 120}, a fim de analisar onze redes neurais, com seu respectivo treinamento para comparação. Em seguida foi realizado a previsão para o mês de maio de 2019 para cada uma das redes treinadas.

Para o treinamento das redes neurais, os dados foram divididos em três subconjuntos, sendo que o primeiro utiliza 70% do banco de dados para calcular e realizar o ajuste dos pesos da rede, posteriormente 15% do total dos dados foi utilizado para validar os dados, e por fim, 15% do total dos dados utilizados para testar a efetividade da rede.

Para a avaliação do desempenho de treinamento de cada neurônio, foi levado em consideração o valor do coeficiente de correlação Pearson. Na Tabela 3, é mostrado os valores do coeficiente de Pearson (R) encontrados durante o treinamento.

Após efetuado o treinamento de cada uma das redes, foi realizada a previsão de geração fotovoltaica para o mês de maio de 2019. Esta etapa foi desenvolvida a partir do cálculo das métricas conforme metodologia utilizada, nos quais

foram determinados os seguintes erros: o erro médio absoluto (MAE), raiz do erro médio quadrático (RMSE) e o erro médio (MBE).

Tabela 3. Valores do coeficiente de correlação R

Número de Neurônios	Correlação (R)			
	Treinamento	Validação	Teste	Todos
10	0,8728	0,89974	0,8501	0,87417
15	0,89118	0,82367	0,86088	0,87584
20	0,88246	0,89358	0,85769	0,88037
25	0,8765	0,88481	0,86945	0,8767
30	0,88797	0,86105	0,85303	0,87946
35	0,89325	0,86823	0,86828	0,88478
40	0,8666	0,85052	0,83709	0,8596
45	0,88454	0,86324	0,82716	0,87244
60	0,90768	0,87935	0,81038	0,88887
90	0,90833	0,80027	0,85778	0,88538
120	0,86975	0,87891	0,84659	0,86771

A Tabela 4 apresentada os resultados obtidos. Com base nos erros de previsão da geração, dados em função da quantidade de neurônios utilizados na RNA, verificou-se que a predição mais assertiva ocorre com 90 neurônios.

Tabela 4. Comparação dos erros MAE, RMSE e MBE para o provisionamento

Número de Neurônios	MAE	RMSE	MBE
10	9571,0	13100	1938,8
15	9456,2	13376	1688,6
20	9742,4	13757	3530,3
25	10223	13879	4496,9
30	11799	16120	3992,3
35	10492	14631	2784,1
40	11079	14420	1658,6
45	11704	14966	6218,0
60	10521	14853	3415,2
90	9318,1	13714	1149,8
120	13083	15209	7141,0

Desse modo, a distribuição dos dados de geração fotovoltaica para o treinamento, validação e teste da RNA é apresentada na Fig. 4.

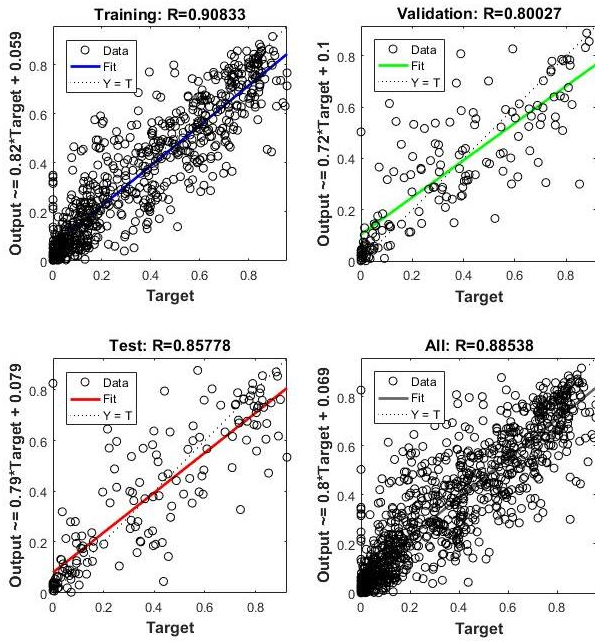


Fig. 4. Treinamento da RNA com 90 neurônios.

A partir das correlações obtidas entre a saída da RNA e cada conjunto de dados utilizado, o valor de R ficou em 0,88538 que pode ser considerável aceitável para o estudo. Além disso, é possível observar (Tabela 3) que os resultados de treinamento mostram que os valores do coeficiente de correlação possuem proximidade e pouca variação, mostrando estabilidade da RNA.

Analisando as Tabelas 3 e 4, é possível concluir que a rede com 90 neurônios apresentou um coeficiente de correlação favorável e a melhor previsão de geração fotovoltaica para o mês de maio, conforme pode ser visto na Fig. 5. Na mesma, é possível observar os valores de geração reais (linha vermelha) e os valores de geração previstos (linha azul) pelo modelo desenvolvido.




Fig. 5. Comparação dos valores reais x previsto da geração fotovoltaica para o mês de maio.

Após realizar o estudo da rede com todas as variáveis meteorológicas de entrada, analisou-se o impacto que cada variável meteorológica possui no modelo desenvolvido.

Deste modo, realizou-se um segundo estudo intercalando as variáveis meteorológicas que abrange o modelo completo. Os demais parâmetros utilizados para a modelagem do estudo completo foram mantidos os mesmos.

O número de neurônios utilizado para treinamento da rede foi equivalente a 90 neurônios, remetendo a quantidade que apresentou melhor desempenho no modelo apresentado anteriormente. A Tabela 5 apresenta a comparação dos valores do coeficiente de correção do modelo completo em relação aos demais modelos com a alternância das variáveis meteorológicas de entrada.

Analisando a Tabela 5 é possível verificar que a radiação solar é a variável meteorológica que possui maior influência no desempenho da RNA. Esse fato, também identificado na literatura (Francisco *et al.*, 2019; Zhu *et al.*, 2016; Cantor, 2017), aponta que quanto maior o nível de radiação sobre os painéis fotovoltaicos, maior a corrente elétrica gerada na saída, e conseqüentemente, maior a geração de energia. Por outro lado, a variável meteorológica que possui menor impacto no desempenho da RNA é a umidade, isto devido, ela possui uma relação inversa com a energia gerada, ou seja, uma maior umidade do ar pode indicar formações de nuvens e precipitação, causando um bloqueio parcial da radiação solar, e conseqüentemente uma redução na geração solar, porém, no estudo realizado foram utilizados meses em que a umidade do ar é baixa, sendo assim, o mesmo não apresentou grande impacto no estudo.

Tabela 5. Influência das variáveis meteorológicas no modelo estudado

Variáveis meteorológicas	Correlação (R)			
	Treinamento	Validação	Teste	Todos
Todas as variáveis	0,90833	0,80027	0,85778	0,88538
Sem a variável radiação	0,84761	0,81673	0,7793	0,83288
Sem a variável temperatura	0,9029	0,83151	0,80363	0,87871
Sem a variável umidade	0,89269	0,86096	0,85164	0,88152
Sem a variável velocidade do vento	0,89075	0,8433	0,80806	0,87311

5. CONCLUSÕES

Devido a crescente preocupação com o meio ambiente e o aquecimento global, novas fontes de energia alternativas, entre elas a fotovoltaica, vem se destacando. Porém, um grande desafio das fontes de energia renováveis é sua natureza volátil. Por este motivo, previsões precisas são vitais para a integração da energia renovável na rede. A previsão da produção de energia solar fotovoltaica pode contribuir para um uso mais eficiente e econômico desse recurso e permite gerenciar a quantidade de energia obtida a partir das plantas fotovoltaicas, a fim de compatibilizar com a demanda emergente.

Deste modo, este trabalho buscou desenvolver um modelo para a previsão de geração de energia fotovoltaica a curto

prazo através da utilização de RNA. No estudo, foram desenvolvidas onze redes, construídas com a arquitetura de uma camada de entrada com a análise de quatro variáveis meteorológicas (temperatura, umidade relativa do ar, a velocidade do vento e a radiação solar) e o valor horário das variáveis; uma camada e uma camada de saída, na qual foi considerada a variável de geração de energia fotovoltaica. Para o treinamento da RNA foi utilizado um banco de dados de três meses, compreendendo os meses de fevereiro, março e abril. Já para o provisionamento, utilizou-se o mês de maio. O treinamento da RNA foi realizado a partir do algoritmo de *Levenberg-Marquardt*, e a avaliação do desempenho de treinamento da rede neural foi realizada predominantemente a partir do coeficiente de correlação de Pearson. Após a realização do treinamento da RNA, foram realizados o cálculo das métricas para a previsão, nos quais foram determinados o erro médio absoluto (MAE), a raiz do erro médio quadrático (RMSE) e o erro médio (MBE). Após a análise dos resultados de treinamento e também dos cálculos das métricas, foi possível concluir que a rede com 90 neurônios apresentou um coeficiente de correlação favorável e a melhor previsão de geração fotovoltaica para o mês de maio. A mesma apresentou um coeficiente de correlação de 0,88538 e um valor de MAE de 9318,1; RMSE de 13714 e MBE de 1149,8.

Após a realização do estudo completo, utilizando todas as variáveis meteorológicas na entrada do modelo, analisou-se o impacto que cada variável possui no modelo desenvolvido. Sendo assim, foi possível verificar que a radiação solar é a variável meteorológica que possui maior influência no desempenho da RNA, sendo que sem ela, o coeficiente de correlação ficou em 0,83288, ou seja, 0,0525 abaixo do modelo principal. Por outro lado, a variável meteorológica que possui menor impacto no desempenho da RNA é a umidade, na qual obteve uma diferença de apenas 0,00386 em relação ao modelo principal. Uma das justificativas, foi que no estudo realizado foram utilizados meses em que a umidade do ar era baixa, sendo assim, o mesmo não apresentou grande impacto no estudo.

Para estudos futuros, será considerado uma abrangência maior na análise do período dos dados de treinamento, ou seja, uma quantidade maior de dados, verificando qual o impacto que se tem no coeficiente de correlação. No trabalho de (Mellit, Sağlam and Kalogirou, 2013), utilizou-se um registro de dados que variam de 01/01/2011 à 24/02/2012, compreendendo um período de aproximadamente um ano e dois meses, e alcançou-se um coeficiente de correlação entre 94% e 96%. Desta forma, é possível constatar que a quantidade de dados utilizadas no treinamento da RNA está atrelada ao valor do coeficiente de correlação.

REFERÊNCIAS

Ahmad, A. & Anderson, T., 2014. Global Solar Radiation Prediction using Artificial Neural Network. *52nd Annual Australian Solar Council Scientific Conference*, Maio.

Andrade, A. C. d., 2008. *Análise e simulação da distribuição de temperaturas em módulos fotovoltaicos*, Porto Alegre: s.n.

Beyer, H. G. *et al.* (2009) *D 1.1.3 Report on Benchmarking of Radiation Products, MESOR Project report*.

Cantor, G. A. R., 2017. *Influência dos fatores climáticos no desempenho de módulos fotovoltaicos em regiões de clima tropical*, João Pessoa: s.n.

Cerqueira, M. A., 2019. *Desenvolvimento de atividades experimentais e de um kit de experimentos sobre geração fotovoltaica*, Petrópolis: s.n.

El Chaar, L., Lamont, L. A. and El Zein, N. (2011) 'Review of photovoltaic technologies', *Renewable and Sustainable Energy Reviews*. doi: 10.1016/j.rser.2011.01.004.

Farret, F. A., 2014. *Aproveitamento de pequenas fontes de energia elétrica*. 3º Ed ed. Santa Maria: Editora UFSM.

Francisco, A. C. C. *et al.* (2019) 'Influência de parâmetros meteorológicos na geração de energia em painéis fotovoltaicos: um caso de estudo do Smart Campus Facens, SP, Brasil', *urbe. Revista Brasileira de Gestão Urbana*. doi: 10.1590/2175-3369.011.e20190027.

Da Silva Fonseca, J. G. *et al.* (2011) 'Photovoltaic power production forecasts with support vector regression: A study on the forecast horizon', in *Conference Record of the IEEE Photovoltaic Specialists Conference*. doi: 10.1109/PVSC.2011.6186475.

De Giorgi, M. G., Congedo, P. M. and Malvoni, M. (2014) 'Photovoltaic power forecasting using statistical methods: Impact of weather data', *IET Science, Measurement and Technology*. doi: 10.1049/iet-smt.2013.0135.

De Leone, R., Pietrini, M. and Giovannelli, A. (2015) 'Photovoltaic energy production forecast using support vector regression', *Neural Computing and Applications*. doi: 10.1007/s00521-015-1842-y.

Hossain, M. *et al.* (2017) 'Application of extreme learning machine for short term output power forecasting of three grid-connected PV systems', *Journal of Cleaner Production*. doi: 10.1016/j.jclepro.2017.08.081.

Izgi, E. *et al.* (2012) 'Short-mid-term solar power prediction by using artificial neural networks', *Solar Energy*. doi: 10.1016/j.solener.2011.11.013.

Madsen, H. *et al.* (2005) 'Standardizing the performance evaluation of short-term wind power prediction models', *Wind Engineering*. doi: 10.1260/030952405776234599.

Mellit, A., Sağlam, S. and Kalogirou, S. A. (2013) 'Artificial neural network-based model for estimating the produced power of a photovoltaic module', *Renewable Energy*. doi: 10.1016/j.renene.2013.04.011.

Pelland, S. *et al.* (2013) 'Photovoltaic and Solar Forecasting', *Report IEA PVPS T1401:2013*.

Pinho, J. T. and Galdino, M. A. (2014) *Manual de engenharia para sistemas fotovoltaicos*, Ediouro Gráfica

e Editora

- Qin, J., Hu, E. and Li, X. (2020) 'Solar aided power generation: A review', *Energy and Built Environment*. doi: 10.1016/j.enbenv.2019.09.003.
- Santos, A. N. V. d., 2018. *Coeficiente de correlação como métrica de avaliação das estratégias de controle inteligente FEL e MNFEL*, São Luís: s.n.
- Shi, J. *et al.* (2012) 'Forecasting power output of photovoltaic systems based on weather classification and support vector machines', in *IEEE Transactions on Industry Applications*. doi: 10.1109/TIA.2012.2190816.
- Silva, P. R., 2018. *Estudo do efeito da composição solar no desempenho de módulos FV caracterizados em condições reais de operação*, Belo Horizonte: s.n.
- Sobri, S., Koochi-Kamali, S. and Rahim, N. A. (2018) 'Solar photovoltaic generation forecasting methods: A review', *Energy Conversion and Management*. doi: 10.1016/j.enconman.2017.11.019.
- Tamizhmani, G. *et al.* (2003) 'Photovoltaic Module Thermal/Wind Performance: Long-Term Monitoring and Model Development For Energy Rating', in *NCPV and Solar Program Review Meeting*.
- Teo, T. T., Logenthiran, T. and Woo, W. L. (2016) 'Forecasting of photovoltaic power using extreme learning machine', in *Proceedings of the 2015 IEEE Innovative Smart Grid Technologies - Asia, ISGT ASIA 2015*. doi: 10.1109/ISGT-Asia.2015.7387113.
- Wan, C. *et al.* (2016) 'Photovoltaic and solar power forecasting for smart grid energy management', *CSEE Journal of Power and Energy Systems*. doi: 10.17775/cseejpes.2015.00046.
- Wang, G., Su, Y. and Shu, L. (2016) 'One-day-ahead daily power forecasting of photovoltaic systems based on partial functional linear regression models', *Renewable Energy*. doi: 10.1016/j.renene.2016.04.089.
- Wolff, B. *et al.* (2016) 'Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data', *Solar Energy*. doi: 10.1016/j.solener.2016.05.051.
- Yona, A. *et al.* (2013) 'Determination method of insolation prediction with fuzzy and applying neural network for long-term ahead PV power output correction', *IEEE Transactions on Sustainable Energy*. doi: 10.1109/TSTE.2013.2246591.
- Zhu, H. *et al.* (2016) 'A power prediction method for photovoltaic power plant based on wavelet decomposition and artificial neural networks', *Energies*. doi: 10.3390/en9010011.