

ANÁLISE DE TÉCNICAS PARA PREVISÃO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA COM O USO DE DADOS METEOROLÓGICOS

BRUNO A. DA CUNHA¹, FERNANDO P. MARAFÃO², ANTONIO C. G. MARTINS³

¹ Universidade Estadual Paulista (UNESP), Faculdade de Engenharia, Bauru, Grupo de Automação e Sistemas Integráveis (GASI), doutorando em engenharia elétrica, bruno.aguilar@unesp.br

² Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Grupo de Automação e Sistemas Integráveis (GASI), Professor Doutor, fernando.marafao@unesp.br

³ Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Grupo de Automação e Sistemas Integráveis (GASI), Professor Doutor, antonio.martins@unesp.br

Área de conhecimento (Tabela CNPq): 3.04.04.01-0 Geração da Energia Elétrica

Apresentado no

4º Congresso de Pós-Graduação do IFSP
27 e 28 de novembro de 2019- Sorocaba-SP, Brasil

RESUMO: O presente artigo visa analisar e discutir algumas das principais técnicas disponíveis na literatura, para a previsão de geração de energia fotovoltaica em intervalos de 24 horas, a partir de dados meteorológicos. Assim, algumas abordagens recentes foram descritas e discutidas, destacando-se a importância das previsões para o mercado de energia. Os resultados dos estudos, embora não possam ser comparados diretamente, por se tratarem de dados, variáveis e localidades diferentes, permitem apontar problemas que precisam ser resolvidos e possibilidades de inovação e novos estudos na área. A incerteza existente na classificação e agregação dos dados geralmente em três tipos climáticos (ensolarado, nublado e chuvoso) e a predição da geração em cada uma dessas condições, também impõem desafios quanto aos dados meteorológicos que devem ser efetivamente utilizados nos modelos em questão.

PALAVRAS-CHAVE: energia renovável; predição; dados meteorológicos; geração fotovoltaica; redes neurais artificiais.

ANALYSIS OF TECHNIQUES FOR PHOTOVOLTAIC ENERGY GENERATION FORECASTING WITH THE USE OF METEOROLOGICAL DATA

ABSTRACT: This paper aims to analyze and discuss some of the main techniques available in the literature, for the prediction of photovoltaic energy generation at intervals of the next 24 hours, based on meteorological data. Thus, some recent approaches have been described and discussed, highlighting the importance of forecasts for the energy markets and the description of recent approaches that have been successful. The results of the studies, although they cannot be directly compared, because they yield from different data, variables and locations, allow pointing out problems that need to be solved and possibilities for innovation and new studies in the area. The uncertainty in the classification and aggregation of data generally in three climate types (sunny, cloudy and rainy) and the prediction of generation under each of these conditions also pose challenges in terms of which weather data should be effectively used for the applied models.

KEYWORDS: renewable energy; predict; weather data; photovoltaic generation; artificial neural network.

INTRODUÇÃO

A crescente demanda por energia elétrica e a maior preocupação ambiental para buscar fontes alternativas menos poluentes propiciaram o desenvolvimento de recursos de energia renovável, com maior destaque para energia solar e eólica (CUI et. al., 2019). Com o advento das redes inteligentes, a energia solar fotovoltaica é uma das tecnologias que mais vem sendo utilizada, por uma série de motivos, como facilidade de instalação, baixo índice de manutenção, abundância de recurso energético, ausência

de ruídos em operação e pelo fato de não exigir grandes espaços para instalação (MARTINS; FERREIRA; LOPES, 2019).

Por se tratar de uma fonte intermitente, parâmetros climáticos podem influenciar no desempenho da geração de energia obtida por painéis fotovoltaicos, introduzindo desafios nos sistemas de energia que precisam ser administrados de forma eficiente (MARTINS; FERREIRA; LOPES, 2019).

Neste sentido, um operador de rede tem como uma das prioridades, buscar prever as alterações na produção de energia do sistema fotovoltaico, para gerenciar adequadamente suas diferentes fontes energéticas (intermitentes ou não), ajustando a oferta a demanda nos diferentes horários ao longo do dia. Ademais, a previsão de energia do sistema fotovoltaico é necessária para diferentes tipos de usuários, como provedores de serviços de energia, produtores independentes e comerciantes de energia que necessitam de um método adequado e confiável que permita planejar os momentos adequados para o uso, seja para consumo, armazenamento ou comercialização (CHEN et. al., 2011).

Sendo assim, o presente artigo tem como objetivo fornecer uma análise das técnicas e metodologias utilizadas atualmente para previsão da geração fotovoltaica e também conduzir uma discussão dos problemas e oportunidades que podem ser explorados ou métodos que podem ser aprimorados para ser possível obter previsões mais próximas a realidade e adequadas às necessidades do mercado de energia brasileiro e mundial.

MATERIAL E MÉTODOS

A metodologia adotada é uma ampla pesquisa bibliográfica para identificar as diferentes técnicas e abordagens encontradas na literatura que buscam resolver o problema da previsão de geração da energia fotovoltaica. É preciso ressaltar que os métodos de previsão são divididos e tratados de acordo com o horizonte de previsão (quantidade de tempo existente entre o momento real e o tempo efetivo da previsão). O foco do estudo realizado foi com as previsões de curto prazo (intra-diária), que tem como objetivo gerar a previsão das próximas horas (geralmente às 24h futuras) (NESPOLI et al., 2019).

Diversos trabalhos na literatura (CHEN et. al., 2011; YANG et al., 2014; LEE; KIM, 2019; NESPOLI et. al., 2019) têm utilizado Redes Neurais Artificiais para realizar classificações que busquem através de dados meteorológicos históricos, prever a saída (energia gerada) por painéis fotovoltaicos nas diferentes horas do dia. Na maioria dos trabalhos essa previsão passa em primeiro momento por uma rede neural artificial que busca classificar os dados em dois ou três tipos de clima: ensolarado, chuvoso ou nublado.

Cui et al. (2019) utilizou os dados de irradiação solar, temperatura e umidade relativa do ar para alimentar uma rede neural artificial do tipo SOM (*self-organization map*) que gera como saída a classificação desses dados nos três tipos climáticos já citados.

Sendo assim, de acordo com Yang et al. (2014), cabe salientar que a geração de energia solar possui padrões bem distintos, o que justifica essa classificação preliminar dos dados históricos. Em um dia de sol, a irradiação solar é alta e estável e, conseqüentemente, sendo responsável pelo maior pico de potência do sistema. Em dias nublados e chuvosos, a saída de energia fotovoltaica é baixa e não confiável e possuem curvas de geração distintas para cada uma dessas condições, sendo possível em alguns casos diferenciá-las facilmente. A figura 1 mostra as curvas características de geração de energia em diferentes dias do mês de novembro e dezembro e classificadas por diferentes categorias de clima (ensolarado, nublado e chuvoso).

Na abordagem de Cui et. al (2019), através de dados diários de energia, irradiação solar, pressão atmosférica, temperatura, umidade relativa do ar, precipitação e velocidade do vento, foi utilizado como entrada da rede somente três dados (irradiação, temperatura e umidade), por serem aqueles que possuíram as correlações mais altas com relação a energia diária gerada. Posteriormente, os autores utilizaram a saída da rede SOM como entrada para uma segunda rede neural artificial do tipo RBF (*Radial basis function*) para finalmente conseguir obter a posteriori, a previsão da geração solar para as 24 horas diárias.

Em outro trabalho, Lee e Kim (2019) utilizaram três métodos para prever a saída de energia fotovoltaica, com diferentes arquiteturas de redes neurais artificiais. As abordagens escolhidas foram: redes neurais profundas (DNN) e modelos baseados em memória de longo e curto prazo (LSTM) com o objetivo de trabalhar com uma modelagem capaz de entender relações existentes entre informações meteorológicas e saídas reais de painéis fotovoltaicos. Os dados utilizados para realizar a previsão foram

divididos em duas categorias: dados com fatores climatológicos (temperatura, radiação solar, umidade do ar e nebulosidade) e dados com fatores sazonais (dia e mês do ano).




FIGURA 1. Gráfico de curvas de potência (kW) de saída do sistema fotovoltaico em diferentes horários do dia e considerando três tipos de clima (ensolarado, nublado e chuvoso). Fonte: Cui et. al. (2019).

Nespoli et al. (2019) realizaram um interessante estudo, pouco encontrado na literatura, comparando resultados entre dois métodos usando RNAs comumente utilizados para previsão e que foram treinados com a mesma base de dados que foi agrupada em dias ensolarados e nublados para realizar o treinamento com os dados específicos de cada grupo por meio de redes neurais *feed-forward* (FFNNs). O estudo se baseou na análise de dois cenários, cujo o primeiro se baseia em um modelo que prevê a saída a ser gerada pelo painel fotovoltaico através de uma primeira previsão da irradiância para as 24h posteriores usando também uma rede multicamadas (MLP). A partir dos valores de irradiância, é realizado um filtro que diferencia em dois grupos, os dados horários cujo a irradiância média é superior (ensolarado) e inferior (nublado) a 150 W/m^2 para que duas outras redes neurais (FFNN) realizem de forma mais especializada a previsão de geração de energia para as 24 horas posteriores a previsão.

No segundo cenário, o método implementado para realizar as previsões é baseado em uma rede FFNN, mas, juntamente com as entradas de dados climáticos (neste caso, sem a existência de agrupamento pela irradiância média) é fornecida a irradiação em condições de céu claro (ou seja, os valores da curva característica de irradiação em condições em que não há nuvens).

Outros trabalhos nessa última década foram realizados e intensas pesquisas têm sido conduzidas usando diferentes arquiteturas de redes neurais artificiais e diversas categorias de dados de entrada e variando também o uso ou não de dados históricos e sua quantidade (BLAGA et. al., 2019; NESPOLI et. al., 2019). Há também estudos buscando compreender quais são as variáveis (climáticas ou não) que são essenciais para que as previsões sejam mais adequadas realizando para isso diversas análises utilizando abordagens estatísticas (KOMAR et. al., 2018).

RESULTADOS E DISCUSSÃO

Os resultados de Cui et. al (2019) para as previsões são mostrados na figura 2. A figura mostra os valores que eram previstos de potência (kW) em relação aos valores realmente obtidos no sistema fotovoltaico ao longo do tempo em três cenários: (A) dias ensolarados, (B) dias nublados e (C) dias chuvosos.

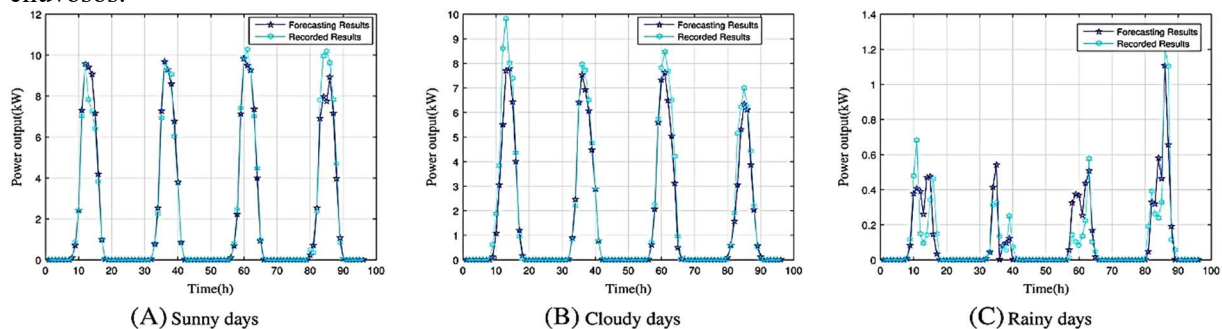


FIGURA 2. Gráficos que representam a potência (kW) obtida e a estimada para o sistema fotovoltaico ao longo do tempo em três cenários. Fonte: Cui et al. (2019).

Nespoli et al. (2019) obteve os resultados mostrados na figura 3 em dois cenários com abordagens distintas, contudo, considerando a mesma região geográfica e a mesma base de dados climáticas.

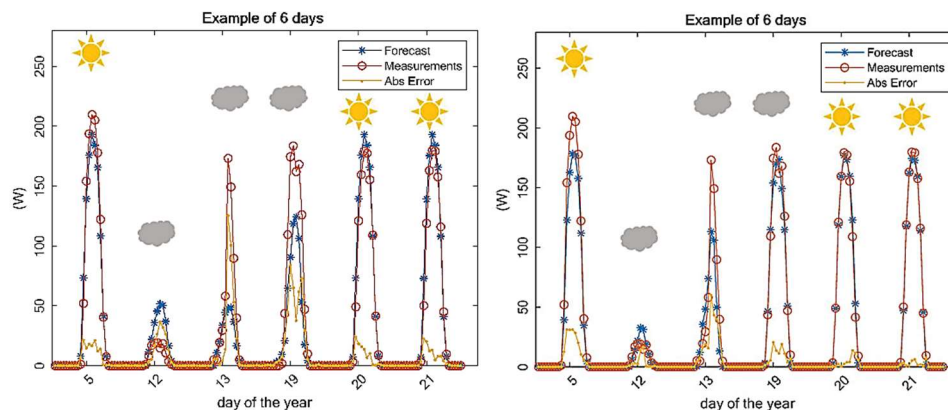


FIGURA 3. Gráficos da potência (W) obtida e a estimada para o sistema fotovoltaico e o erro absoluto da previsão para os Cenários 1 e 2 (à esquerda e a direita, respectivamente) considerando 6 dias, nos quais três foram nublados e três ensolarados. Fonte: Nespoli et al. (2019).

Para obter os resultados, Cui et. al (2019) coletaram dados entre 18 de agosto e 30 de novembro de 2006 em uma região da China e Nespoli et al. (2019) citam que seus dados correspondem a 286 dias de coleta em uma localidade da Itália. Ambos os dados foram coletados em períodos de 1 hora.

Embora uma comparação entre os resultados de Cui et. al (2019) e Nespoli et al. (2019) não possa ser conduzida por se tratar de cenários, base de dados e condições distintas, na figura 2 e na figura 3 é possível notar pela análise dos resultados que a maior dificuldade das abordagens propostas é a previsão adequada e mais próxima da realidade nas situações que possuem grande incerteza de qual será a geração a ser obtida pelo painel, ou seja, em dias nublados ou chuvosos. Para dias ensolarados, por não haver surpresas na geração, a potência obtida é muito próxima da estimada em praticamente todos os casos de ambos os estudos.

Conforme relatado pelos autores, as abordagens precisam melhorar as situações de maior dificuldade de classificação, ou seja, na diferenciação dos períodos de nublado e chuvoso para obter o agrupamento necessário para estimar a geração/potência do painel nessas condições. Ambas as situações possuem uma indefinição que precisa ser levada em consideração para melhoria do modelo. Uma abordagem híbrida usando RNAs e uma modelagem por lógica fuzzy, conhecida por ser adequada para o tratamento das incertezas, poderia trazer resultados promissores.

A quantidade de dados considerada para a realização das previsões é algo importante a ser analisado, afinal, uma maior quantidade de amostras do objeto de estudo pode levar a uma melhor classificação por meio da rede neural artificial com relação aos diferentes e complexos comportamentos do clima. Sendo assim, um ponto de crítica em ambos os resultados apresentados e nos demais encontrados na literatura, é que os períodos de captação dos dados são inferiores a 1 ano, ou seja, os dados utilizados não representam todas as variações sazonais no que diz respeito a temperatura, umidade e outros variáveis que consequentemente podem ser impactadas pelo volume e quantidade de nuvens, frequência e intensidade de chuvas ou mesmo condições de neve, nas diferentes estações do ano.

O que é também pouco discutido na literatura e documentado em resultados obtidos, é a relação da distância existente entre a estação climatológica e os painéis fotovoltaicos. O adequado é que esses dados tenham sido captados em posições geográficas muito próximas, para que estejam realmente correlacionados e representem com fidelidade a situação climática dos painéis no momento da captura e também possa representar melhor as variações ocasionadas por nuvens, que podem gerar grandes perturbações na curva de potência do painel em um intervalo de tempo de análise, devido a variação da irradiação solar, conforme é mostrado na figura 4, em três diferentes situações. Cabe destacar que na abordagem conduzida por Cui et. al (2019), os dados utilizados foram coletados no mesmo local.

Finalmente, embora as arquiteturas de redes neurais artificiais utilizadas sejam diversas, uma tendência que vale a pena ser mantida é com relação a agrupar os dados meteorológicos para os diferentes tipos climáticos em análise, contudo, é preciso alguns estudos mais aprofundados para

verificar quais variáveis efetivamente apresentam os melhores resultados quando consideradas e o quanto essas variáveis podem mudar dependendo do país e da região no qual as mesmas foram capturadas e conseqüentemente quais são os impactos em todo o modelo de previsão considerado.




FIGURA 4. Variação da irradiância solar global devido a passagem de nuvens em diferentes escalas de tempo: (a) nos primeiros 10 dias de junho de 2016; (b) em 3 de junho de 2016 e (c) entre 11:00 e 12:00, horário local, em 3 de junho de 2016. Fonte: Blaga et. al. (2019).

CONCLUSÕES

As técnicas para previsão de geração de energia fotovoltaica, embora tenham sofrido avanços ao longo dos anos, ainda possuem diversos problemas e, conseqüentemente, oferecem oportunidades para inovações por meio de novas abordagens. A análise realizada faz parte de um estudo mais amplo desenvolvido pelos autores que buscam aplicar essas técnicas com inovações que sejam pertinentes e adequadas para o clima e para tendências futuras do mercado de energia brasileiro.

As previsões de geração de energia fotovoltaica são extremamente importantes nos diferentes mercados de energia no mundo, para comercialização e planejamento a priori das operações de rede que visam atender a demanda. No caso das redes elétricas inteligentes, a predição com um alto índice de acerto é requisito para o funcionamento de usinas virtuais de energia na alta tensão e também na baixa tensão no gerenciamento inteligente de energia residencial, otimizando o uso, o armazenamento e a comercialização de energia dos painéis solares de forma a maximizar o lucro ou a redução de custos com a energia obtida ou injetada na rede, em mercados que existem variações no preço da energia elétrica ao longo do dia.

REFERÊNCIAS

- BLAGA, R. et al. A current perspective on the accuracy of incoming solar energy forecasting. *Progress in Energy and Combustion Science*, v. 70, p. 119-144, 2019.
- CHEN, C. et al. Online 24-h solar power forecasting based on weather type classification using artificial neural network. *Solar energy*, v. 85, n. 11, p. 2856-2870, 2011.
- CUI, S. et al. Residential virtual power plant with photovoltaic output forecasting and demand response. *Asian Journal of Control*, 2019.
- KOMAR, V. et al. Meteorological Parameters Analysis for hourly Forecast of Electricity Generation by Photovoltaic Power Station on the Day Ahead. In: 2018 IEEE 3rd International Conference on Intelligent Energy and Power Systems (IEPS). IEEE, p. 235-238, 2018.
- LEE, D.; KIM, K. Recurrent neural network-based hourly prediction of photovoltaic power output using meteorological information. *Energies*, v. 12, n. 2, p. 215, 2019.
- MARTINS, R. P.; FERREIRA, V. H.; LOPES, T. T. Artificial neural network for probabilistic forecasting of the output power of photovoltaic systems. In: 2018 Simpósio Brasileiro de Sistemas Elétricos (SBSE). IEEE, p. 1-6, 2018.
- NESPOLI, A. et al. Day-ahead photovoltaic forecasting: A comparison of the most effective techniques. *Energies*, v. 12, n. 9, p. 1621, 2019.
- YANG, H. et al. A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output. *IEEE transactions on sustainable energy*, v. 5, n. 3, p. 917-926, 2014.