

APLICAÇÃO DE REDE NEURAL ARTIFICIAL E ALGORITMOS DE PSO PARA PREVISÃO DE GERAÇÃO DE ENERGIA ELÉTRICA EM UMA USINA SOLAR FOTOVOLTAICA NO CEARÁ

Andre Wagner de Barros Silva¹, Erick Costa Bezerra², Ruth Pastôra Saraiva Leão³, Danielle Baltazar Cavalcante⁴, Raimundo Furtado Sampaio⁵

¹Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE, e-mail: andrewagner10@yahoo.com.br

²Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE

³Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE

⁴Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE

⁵Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE

Resumo

Tendo em vista a enorme inserção de geração fotovoltaica (FV) na matriz energética brasileira nos últimos anos e levando-se em conta o caráter intermitente deste tipo de geração, faz-se necessária a existencia de modelos de previsão de geração cada vez mais precisos, de modo a possibilitar um melhor planejamento da operação da planta FV bem como do sistema elétrico como um todo. Desta maneira, neste trabalho é realizada a previsão de geração de energia elétrica de uma usina solar fotovoltaica de 160 MW localizada no Ceará, a partir de um modelo de rede neural MLP com unidades de atraso, denominada rede FTDNN (*Focused Time Delay Neural Network*), aplicando-se diferentes técnicas de treinamento: *backpropagation* (BP), *Particle Swarm Optimization* (PSO) e duas variações do algoritmo PSO, quais sejam PSO-AWF e PSO caótico (CPSO). Foi utilizada uma série temporal com dados meteorológicos e de geração de energia com integração horária, contemplando o período de dois anos (junho de 2019 a junho de 2021). Para fins de comparação de desempenho, diferentes modelos além dos já citados foram aplicados aos dados, sendo eles *MLP Regressor* (MLPR), *Decision Tree Regressor* (DTR), *Linear Regressor* (LR) e Persistência. A performance dos modelos implementados foi avaliada utilizando-se métricas de erro e o modelo FTDNN com técnica de treinamento BP obteve o melhor resultado.

Palavras-chave. Previsão. Rede neural. Geração Fotovoltaica. Modelo. PSO.

1. Introdução

VII Congresso Brasileiro de Geração Distribuída, Belo Horizonte, MG – 2022.

A capacidade instalada da geração fotovoltaica mundial apresentou crescimento considerável entre os anos de 2017 e 2020, de 384,5 GW para 707,5 GW, em números aproximados (BP, 2021). Durante este mesmo período, observou-se um crescimento da potência total instalada também no Brasil, tanto de sistemas de geração centralizada como distribuída, tendo o país alcançado 7,9 GW de potência instalada em 2020. Ao final de 2021, o Brasil atingiu a marca histórica de 4 GW de capacidade instalada em usinas solares fotovoltaicas de grande porte (RIBEIRO, 2021).

Devido a esta geração ser dependente de fatores meteorológicos, a integração de sistemas de geração solar fotovoltaica à rede elétrica constitui-se num grande desafio. Nesse sentido, uma previsão segura de geração para dado intervalo de tempo futuro tende a diminuir incertezas, aumentando a confiabilidade e a viabilidade econômica dos sistemas elétricos (DIAGNE et. al., 2013).

2. Base de Dados e Modelos de Previsão Implementados

2.1 Base de Dados

O conjunto de dados utilizado neste trabalho foi obtido de uma usina solar fotovoltaica de 160 MW de potência instalada, localizada no estado do Ceará. Os dados abrangem o período de 30 de junho de 2019 a 29 de junho de 2021 (731 dias), consistindo em uma série temporal de geração de energia elétrica da usina bem como uma série temporal de dados meteorológicos da mesma. As grandezas meteorológicas foram obtidas a partir de uma estação meteorológica localizada dentro da planta fotovoltaica e compreendem: temperatura ambiente, umidade, irradiância horizontal e velocidade do vento. O período de amostragem das séries temporais mencionadas vai de 5h às 17h, em intervalos de 1h.

Antes da aplicação dos modelos de previsão buscou-se realizar o tratamento do conjunto de dados da usina solar fotovoltaica. Nesse sentido, avaliou-se a existência de dados zerados, o que representaria uma inconsistência do sistema de aquisição de dados.

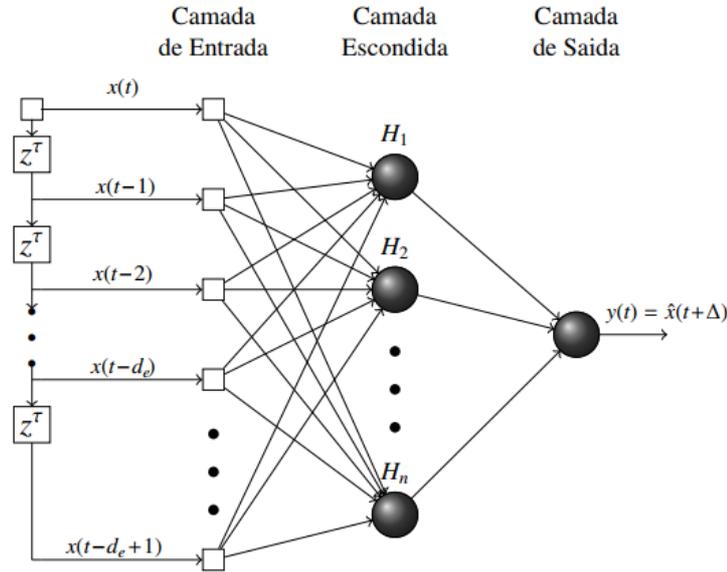
2.2 Rede Neural Artificial

A rede neural artificial utilizada neste trabalho trata-se de uma rede MLP com unidades de atraso, chamada de FTDNN (PRINCIPE et al., 1999). A FTDNN é uma rede multicamadas sem realimentação, onde seus pesos sinápticos podem ser ajustados com BP. Como uma típica *Artificial Neural Network feed-forward*, o sinal passa pela FTDNN em apenas um sentido e direção, da entrada para a saída, e os neurônios de uma mesma camada não são conectados entre si (BEZERRA, 2021). A figura 01 apresenta a arquitetura de uma rede neural FTDNN com d_e elementos da série contados a partir do elemento atual $x(t)$, espaçados um do outro de τ

VII Congresso Brasileiro de Geração Distribuída, Belo Horizonte, MG – 2022.

unidades de tempo (neste exemplo com valor igual a -1), $y(t)$ é a saída do neurônio e $\hat{x}(t+\Delta)$ é a variável escalar prevista.

Figura 01 – Rede Neural FTDNN com arquitetura genérica.



Fonte: (BEZERRA, 2021)

2.3 Particle Swarm Optimization (PSO) e suas Variações (PSO-AWF e CPSO)

O *Particle Swarm Optimization* (PSO) é uma técnica de otimização inspirada pelos comportamentos sociais cooperativos e competitivos de animais que se organizam em bandos e cardumes (ENGELBRECHT, 2017). Esta técnica mantém uma nuvem de partículas, onde as mesmas fluem através de um espaço multi-dimensional pré-definido, de modo que cada partícula é ajustada de acordo com sua própria experiência e a de seus vizinhos.

Em um espaço de busca multi-dimensional, inicialmente cada partícula é posicionada de maneira aleatória, e suas respectivas posições iniciais $x_i(t)$ são definidas como seus *Pbests*, que podem ser descritos como as suas melhores posições individuais até o momento. A melhor solução dentre todas as partículas é o *Gbest* da nuvem. Usualmente a velocidade inicial v de cada partícula é definida como zero e a nova velocidade $v_i(t + 1)$ que orienta todo o processo de otimização é descrita conforme equação 1.

$$v_i(t + 1) = v_i(t) + C_1 R_1 (Pbest_i(t) - x_i(t)) + C_2 R_2 (Gbest(t) - x_i(t)) \quad (1)$$

Em que C_1 e C_2 são respectivamente as constantes sociais e cognitivas, enquanto R_1 e R_2 são valores aleatórios entre $[0,1]$. A nova posição $x_i(t + 1)$ é então computada pela equação 2.

$$x_i(t + 1) = x_i(t) + v_i(t + 1) \quad (2)$$

Todas as partículas da nuvem tendem a se deslocar para o ponto ótimo. Durante a busca no espaço multi-dimensional, caso o *Gbest* não seja a solução ótima, uma das partículas pode encontrar uma solução melhor e tomar o lugar do *Gbest*. Esse ciclo continua até que a solução ótima global ou uma restrição de parada do algoritmo seja encontrada (ENGELBRECHT, 2021).

O PSO-AWF trata-se de uma variação do PSO que, além da adequação dos indivíduos ser determinada pelo valor da função objetivo, atribui um valor de vida útil para toda a nuvem. Assim, caso a vida útil de uma determinada partícula chegue ao fim, novas partículas emergem para desafiar e tomar a liderança da nuvem. Desta maneira, o mecanismo de envelhecimento prevê oportunidades para outras partículas liderarem o enxame e assim trazer diversidade (BEZERRA, 2021). No PSO caótico (CPSO), além de ser avaliada a função objetivo (idem ao PSO convencional), realiza-se uma busca caótica de modo a se tentar evitar mínimos locais. Entretanto, essa busca caótica normalmente necessita de um grande número de iterações para atingir um ótimo global e não é eficaz em grandes espaços de busca.

2.4 Modelos de *Baseline* Adotados

Para fins de referência, três modelos da biblioteca *Scikit-learn* do Python foram utilizados. São eles *MLP Regressor* (MLPR), *Linear Regressor* (LR) e *Decision tree Regressor* (DTR). A função MLPR, apesar de guardar certa semelhança com a rede FTDNN também aplicada neste trabalho, difere da mesma por não utilizar os dados de entrada de maneira sequencial (na forma de uma série temporal com unidades de atraso). Além dos modelos já citados, a persistência também foi utilizada. A persistência assume que a geração futura (no instante $t+1$) será igual à geração passada (no instante t), método de fácil implementação e bastante aplicado na literatura.

3. Resultados e Análise de Desempenho

Foram identificados 34 dias nos meses de novembro e dezembro de 2019 e 12 dias nos meses de maio e junho de 2020 com dados meteorológicos iguais a zero, os quais foram eliminados da base de dados. Os dias 08/09/2019, 21/10/2019 e 22/10/2019 da série temporal também foram eliminados por não apresentarem dados de geração. Desta maneira, dos 731 dias totais restaram 682 dias, sendo 50% dos dados utilizados para treino e 50% para teste. Outra análise realizada foi a existência de *outliers*, entretanto, devido à pequena quantidade de *outliers* identificados pela técnica *boxplot*, optou-se por não eliminar estes pontos até para se preservar as características reais da planta em estudo.

Para a FTDNN com técnica de treinamento BP foi realizado o ajuste de parâmetros manualmente, de modo a se buscar o melhor resultado em termos de métricas de erro. Os

parâmetros testados foram número de neurônios da camada escondida (4, 7, 10, 15, 25), função de otimização (Adam, SGD), função de ativação (Sigmoid, Relu, Tanh), função de perda (MAE, MSE), épocas de treinamento (50, 100, 250), atraso (1, 3, 5, 11) e taxa de aprendizagem (0.1, 0.01, 0.001, 0.05, 0.005, 0.0005, 0.09, 0.009, 0.0009). Os melhores parâmetros para a rede FTDNN com a técnica de treinamento BP foram 4, Adam, Sigmoid, MAE, 250, 11 e 0.001, respectivamente.

Para as funções de baseline foi realizada a técnica do *gridsearch* na busca dos melhores parâmetros, variando-se algumas entradas das funções pré-existentes do Python. Os algoritmos de PSO utilizados também foram testados para algumas faixas de dados, como número de neurônios da camada escondida (4, 7, 10), população (500, 1000, 1500), número de gerações (500, 1000, 1500) e valores limites dos pesos ([-1,1], [-1.5,1.5], [-2,2], [-2.5,2.5], [-3,3], [-5,5], [-7,7], [-10,10]). Os melhores parâmetros para os algoritmos PSO, PSO-AWF e CPSO na otimização dos pesos da rede FTDNN foram 4, 500, 500 e [-1.5,1.5], respectivamente. Variou-se também o atraso (1, 3, 5, 11), de modo que o atraso adotado para a técnica CPSO foi 1, enquanto para os modelos PSO e PSO-AWF adotou-se 11.

Para a avaliação dos resultados, utilizou-se como métricas de desempenho a Raiz do Erro Quadrático Médio (*Root Mean Squared Error – RMSE*) e o Erro Absoluto Médio (*Mean Absolute Error - MAE*), tendo em vista serem os indicadores mais utilizados na literatura (BOTCHKAREV, 2019). Os cálculos dos erros foram feitos a partir das funções pré-existentes na biblioteca Python *Scikit-learn*. Os resultados obtidos para todos os modelos implementados encontram-se apresentados na tabela 01.

Tabela 01 – RMSE, MAE e tempo de execução dos modelos.

Modelo	RMSE (MWh)	MAE (MWh)	Texec
FTDNN-BP	24.24	16.96	2min
FTDNN-PSO_AWF	24.37	18.42	11min
DTR	25.03	18.62	8seg
FTDNN-PSO	25.04	19.00	38min
MLPR	25.19	19.07	9min
FTDNN-CPSO	27.00	19.34	33min
LR	26.99	21.13	1seg
Persistência	27.18	19.27	5seg

Fonte: Próprio autor, 2022.

Conforme se pode perceber, a rede neural FTDNN com técnica de treinamento BP apresentou o melhor resultado dentre os modelos apresentados, sendo superior inclusive às funções pré-existentes do Python. O segundo melhor modelo dentre os analisados foi a rede

FTDNN com técnica de treinamento PSO-AWF, o qual apresentou ainda tempo de execução bem inferior às demais técnicas de PSO implementadas.

4. Conclusões

Neste trabalho foi avaliada a aplicação de modelos de previsão de geração de energia elétrica de uma usina solar fotovoltaica, visando beneficiar a operação e integração à rede de usinas de potência de saída variável. Modelos de diferentes topologias foram implementados, os quais receberam como entrada a série temporal de dados meteorológicos e tiveram como variável *target* a geração de energia elétrica futura (instante $t+1$) da usina.

Conforme os resultados obtidos, verificou-se que mesmo modelos consolidados, como os pré-existentes na biblioteca *Scikit-learn* do Python foram superados por um dos modelos propostos neste trabalho, no caso o FTDNN-BP. O segundo melhor modelo dentre os avaliados foi o FTDNN com técnica de treinamento PSO-AWF para otimização dos pesos da rede neural.

5. Referências Bibliográficas

AHMED, R., SREERAM, V., MISHRA, Y., ARIF, M.D. (2020). **A review and evaluation of the state-of-the-art in pv solar power forecasting: Techniques and optimization**, *Renewable and Sustainable Energy Reviews*, 124, 109792. doi:10.1016/j.rser.2020.109792.

BP (2021), **BP Statistical Review of World Energy 2021**. 70.

BEZERRA, E. C. (2021), **Abordagem auto-adaptativa baseada no conceito de expectativa de vida aplicada aos métodos *particle swarm optimization* e máquinas kernel para previsão da velocidade do vento e geração eólica**, capítulo 3: descrição do problema e ferramentas de inteligência computacional.

DIAGNE, M., DAVID, M., LAURET, P., BOLAND, J., SCHMUTZ, N. (2013), **Review of solar irradiance forecasting methods and a proposition for small-scale insular grids**, *Renewable and Sustainable Energy Reviews*, 27, 65-76. doi:10.1016/j.rser.2013.06.042.

ENGELBRECHT, A. P. **Computational intelligence: an introduction**. [S. l.]: John Wiley & Sons, 2007.

KALOGIROU, S., SENCAN, A. (2010). **Artificial intelligence techniques in solar energy applications**. In R. Manyala (ed.), *Solar Collectors and Panels*, chapter 15. IntechOpen, Rijeka. doi:10.5772/10343.

PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. **Neural and adaptive systems: fundamentals through simulations with CD-ROM**. [S. l.]: John Wiley & Sons, Inc., 1999.

RIBEIRO, S. (2021). **Usinas solares de grande porte atingem 4 GW.**
<https://revistapotencia.com.br/portal-potencia/energia/usinas-solares-de-grande-porte-atingem-4-gw/>. Acesso em: 21 jan. 2022.