

Previsão pontual de radiação solar com redes neurais artificiais

Fellype S. Barroso¹

BCC/IEG/UFOPA, Santarém, PA

Helaine C. M. Furtado²

IEG/UFOPA, Santarém, PA

O desenvolvimento socioeconômico de uma sociedade está intimamente relacionado à produção e consumo de energia [3]. Em decorrência disso, as fontes de energia renováveis têm sido incentivadas e popularizadas nas últimas décadas. Entre as mais comuns, está a fonte de energia solar [7]. Redes Neurais Artificiais (RNAs) para a previsão de séries temporais é uma ferramenta consolidada [8], e ultimamente tem sido utilizada para a previsão de radiação solar [4, 6]. Assim, este trabalho se propõe a aplicar RNAs para previsão pontual de radiação solar e avaliar a capacidade preditiva de dois modelos de RNAs: a *Multi-layer Perceptron* (MLP) e a rede recorrente de Elman. A principal diferença entre essas arquiteturas está na maior capacidade para processamento de informações temporais. Enquanto a rede MLP armazena apenas o processamento atual (rede estática), a rede de Elman introduz a ideia de memória dinâmica a qual permite que processamentos anteriores possam ser armazenados e realimentados para a camada de entrada [2, 5].

A metodologia aplicada abrangeu a coleta e tratamento dos dados, implementação dos modelos preditivos e avaliação das previsões obtidas a partir de 3 (três) métricas estatísticas: coeficiente de determinação (R^2), *Mean Absolute Error* (MAE) e *Mean Squared Error* (MSE). Para a implementação dos modelos utilizou-se a linguagem de programação *Python* com auxílio dos *frameworks Scikit-Learn* e *Keras*. Os dados coletados são referentes as estações meteorológicas automáticas, localizadas na mesorregião do Baixo Amazonas, PA. Para o treinamento das redes foram utilizados: temperatura ($^{\circ}C$), umidade relativa (%), a radiação solar do passado, data e hora. Os dados foram coletados no período de 2009 a 2014, divididos de forma sequencial em 80% para treinamento e 20% para validação e normalizados entre 0,1 e 0,9. O algoritmo SGD - *Stochastic Gradient Descent* foi utilizado para treinamento [9].

Utilizou-se o algoritmo *Random Search* [1] para determinar os melhores hiperparâmetros para cada modelo. As melhores configurações encontradas para a MLP foram, 16 (dezesseis) neurônios na camada oculta, 3 (três) dados de entrada (temperatura, umidade e hora) e função de ativação ReLU. Para Elman 150 (cento e cinquenta) neurônios na camada recorrente, 7 (sete) dados de entrada (temperatura, umidade, radiação, hora, dia, mês e ano), função de ativação ReLU e valor 3 (três) para o *delay* da janela deslizante.

Após a otimização, verificou-se que ambos modelos preditivos conseguiram alcançar boa capacidade de generalização (Figura 1). A rede recorrente de Elman obteve as menores taxas de erro MAE = 0,028 e MSE = 0,001, consequentemente, previsões mais próximas dos dados reais com $R^2 = 0,952$. O modelo MLP obteve $R^2 = 0,930$; MAE = 0,034 e MSE = 0,002.

De acordo com os resultados obtidos, conclui-se que, a rede de Elman para a previsão pontual de radiação solar na área de estudo, obteve a estimativa mais próxima dos dados reais comparado com o modelo MLP. Portanto, esta é uma ferramenta em potencial para auxiliar em tomadas de decisões, implantação e manutenção de sistemas fotovoltaicos, planejamento de políticas ambientais e qualquer outro tipo de atividade que necessite do conhecimento da incidência futura de radiação solar.

¹fellypecsiqueira@gmail.com

²helaine.furtado@gmail.com




Figura 1: Comparação entre as previsões dos melhores modelos alcançados (MLP: curva verde; Elman: curva laranja) em relação aos dados reais (curva azul).

Agradecimentos

Os autores agradecem ao Instituto Nacional de Meteorologia (INMET) pelos dados disponibilizados e ao PET/FNDE/MEC pelo apoio financeiro por meio de bolsa de pesquisa.

Referências

- [1] Bergstra, J., Bengio, Y. Random search for hyper-parameter optimization, *JMLR*, 13:281–305, 2012. Disponível em: <https://www.jmlr.org/papers/volume13/bergstra12a/bergstra12a>
- [2] Elman, Jeffrey L. Distributed representations, simple recurrent networks, and grammatical structure. *Machine Learning*, 7:195–225, 1991. DOI: 10.1023/A:1022699029236.
- [3] Goldemberg, J., Lucon, O. *Energia, meio Ambiente e desenvolvimento, 3a. edição*. Editora da Universidade de São Paulo - EDUSP, São Paulo, 2008.
- [4] De Sousa, A. F. G., Furtado, H. C. M., Macêdo, W. N., Meneses, A. A. de M. Analysis of Artificial Neural Network Point Forecasting Models and Prediction Intervals for Solar Irradiance Estimation, *American Journal of Engineering and Applied Sciences*, 13:347–357, 2020. DOI: 10.3844/aje-assp.2020.347.357.
- [5] Haykin, S. *Redes neurais: princípios e prática, 2a. edição*. Bookman, Porto Alegre, 2001.
- [6] Premalatha, N., Armirtham, V. A. Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms, *Journal of applied research and technology*, 14:206–214, 2016. DOI: 10.1016/j.jart.2016.05.001.
- [7] Rehman, S., Mohandes, M. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy Policy*, 36:571–576, 2008. DOI: 10.1016/j.enpol.2007.09.033.
- [8] Tymvios, F. S., Jacovides, C. P., Michaelides, S.C., Scouteli, C. Comparative study of Ångström's and artificial neural networks' methodologies in estimating global solar radiation, *Solar Energy*, 78:752–762, 2005. DOI: 10.1016/j.solener.2004.09.007.
- [9] Toulis, P., Airoldi E., Rennie J. Statistical analysis of stochastic gradient methods for generalized linear models, *Proceedings of the 31st International Conference on Machine Learning*, volume 32, 2014. Disponível em: <http://proceedings.mlr.press/v32/toulis14.html>