

Uso de Redes Neurais Artificiais para Previsão de GHI

Use of Artificial Neural Networks for GHI Forecasting

Naiara Rinco de Marques e Carmo^{a,*} 

^a Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Mecânica, CEP 22453-390, Rio de Janeiro-RJ, Brasil.

*E-mail: naiararinco14@gmail.com

Recebido em: 2 de Abril de 2021

Aceito em: 6 de Maio de 2021

Publicado online: 11 de Fevereiro de 2022

Artificial Neural Networks are computational models inspired by the functioning of the central nervous system of animals. They are able to promote machine learning and pattern recognition with high quality. This study aimed to predict a step ahead of daily Global Horizontal Irradiation (GHI) using Artificial Neural Networks (ANRs) of two types: Nonlinear Autoregressive Network (NAR) and Nonlinear Autoregressive Network with Exogenous Inputs (NARX). The network structure was developed using the Matlab 2019b® NTSTOOL tool. The database used was provided by the network of the National Environmental Data Organization System (SONDA), covering the Brasília station. Different models of neural networks were tested, contemplating varied inputs, and combinations of them. In addition, two training algorithms were tested, as well as several numbers of processors in the hidden layer, input delay and percentages for training, validation and testing of the network. The main point was to find the best ANR structure possible, which has a configuration capable of providing the lowest possible errors with good generalization. The results were compared with the *naive* and exponential damping models. A structure was obtained that provided 5.75% for the test MAPE error and 29,383.55 W/m² for the test RMSE, standing out in relation to the *naive* forecast (MAPE: 19.28%; RMSE: 67,920.73 W/m²) and that provided by the exponential damping model (MAPE: 9.36%; RMSE: 35,091.81 W/m²).

Keywords: Artificial neural networks; time series prediction; global horizontal radiation.

1. Introdução

É fato que tecnologias renováveis como a fotovoltaica e a de aquecimento solar de água são muito promissoras, especialmente em um país tropical como o Brasil. Embora a energia solar seja uma fonte limpa, é importante notar que o caráter intermitente da radiação solar se mostra como um desafio à sua implementação. Deste modo, o conhecimento prévio do comportamento desta variável meteorológica permite ações mais efetivas de manutenção e operação de usinas eólicas e solares, por exemplo.

Este trabalho buscou a elaboração de Redes Neurais Artificiais (RNAs) para previsão um passo à frente da Irradiação Solar Global Horizontal (GHI) diária. Para tanto, foram comparadas diferentes redes neurais recorrentes, variando os seguintes parâmetros: variáveis de entrada do modelo, percentuais de treinamento, validação e teste, algoritmo de treinamento e número de neurônios na camada escondida. Buscou-se uma configuração destes parâmetros que atinja os menores erros possíveis, com boa generalização do comportamento da variável.

1.1. Radiação Solar e a influência de variáveis atmosféricas

Estudos mostram que a Irradiação Solar Horizontal (GHI) anual brasileira está entre 1.500 e 2.200 kWh/m². Tais valores são bem maiores que o caso da Alemanha, por exemplo, que está entre 900 e 1.250 kWh/m² ao ano, mas é um dos países com maior capacidade fotovoltaica instalada no mundo.¹ Tais informações refletem o amplo potencial de exploração desta fonte de energia no Brasil.

Dentre as tecnologias de geração de eletricidade a partir da energia solar, duas vêm se destacando no cenário nacional: os painéis fotovoltaicos e os de aquecimento solar de água. Em ambos os casos se emprega a GHI, que é o total da radiação solar que incide no planeta.

É importante destacar que existe uma diferença entre irradiação horizontal G_B e em plano inclinado G_{Bt} . Ambas são relacionadas a partir da Equação 1²:

$$G_{Bt} = G_B \cdot \frac{\cos\theta}{\cos\Phi}; G_{Bn} = \frac{G_{Bt}}{\cos\theta} = \frac{G_B}{\cos\Phi} \quad (1)$$

onde: G_{Bn} : Radiação solar incidente; θ : Ângulo entre G_{Bt} e G_B ; Φ : Ângulo entre G_B e G_{Bn} .

Estes conceitos são fundamentais para a instalação de painéis fotovoltaicos, por exemplo, onde o plano de inclinação geralmente utilizado é orientado para o norte (no caso do Brasil) a um ângulo de inclinação que corresponde à latitude local.

É importante notar que a GHI pode ser influenciada por outras variáveis atmosféricas. Dias nublados, por exemplo, tendem a receber menos irradiação direta do que dias ensolarados. Relações como estas podem favorecer a previsão de variáveis meteorológicas, como a GHI.

1.2. Redes Neurais Recorrentes

Redes Neurais Artificiais (RNAs) são estruturas de processamento altamente paralelo, capazes de adquirir, armazenar e utilizar conhecimento obtido de forma experimental. Elas são comparadas ao cérebro humano, uma vez que ambas possuem a habilidade de aprender e reconhecer padrões. Deste modo, são estruturas computacionais que, assim como o cérebro, possuem a capacidade de aprender, generalizar a informação aprendida, aprender por associações e reconhecimento de padrões.³

O funcionamento básico de uma rede neural está em sua estrutura unitária, o neurônio artificial. Ambos recebem informações de entrada, as quais são processadas internamente, e geram uma saída. O arranjo destes neurônios em camadas permite um processamento complexo das informações de entrada fornecidas, gerando saídas aprendidas pela rede.

No caso do neurônio artificial o processamento da informação é feito a partir de um vetor de pesos (w_0) e um bias (b). O somatório deste bias com o produto dos pesos e entradas gera uma informação que pode ou não ativar uma saída deste neurônio, que configura a entrada do neurônio seguinte, até o fim da rede neural.³

Redes recorrentes são estruturas de processamento capazes de representar comportamentos dinâmicos. Neste caso, a variável de saída da RNA possui um comportamento dependente do tempo, e esta dependência é utilizada no processo de aprendizado. Isto ocorre porque a saída da rede em um instante (t) funciona como entrada para obter a saída em $(t + 1)$.³

Este trabalho aborda dois tipos de redes recorrentes: os Modelos Não-Lineares Auto-Regressivos (NAR) e os Não-Lineares Auto-Regressivos com Entradas Exógenas (NARX). No primeiro, utiliza-se apenas uma variável, que é aquela que se busca prever. Além disso, a saída $y(t)$ é função da janela de dados anteriores ao instante que se deseja prever, como na Equação 2:

$$y(t) = f(y(t-1), y(t-2), y(t-3), \dots, y(t-d)) \quad (2)$$

Já no segundo, a entrada é composta não só pelo atributo que se deseja prever, como também por outros que podem auxiliar na previsão:

$$y(t) = f(x(t-1), \dots, x(t-d), y(t-1), \dots, y(t-d)) \quad (3)$$

Ambas foram utilizadas neste trabalho visando obter a previsão de GHI. Como variáveis exógenas foram utilizados outros atributos que caracterizam a atmosfera, como a temperatura, a pressão, a velocidade do vento, entre outras variáveis.

1.3. Aplicações de redes neurais na previsão de variáveis meteorológicas

Redes Neurais Artificiais têm se apresentado como um método consideravelmente assertivo para a previsão de variáveis meteorológicas, principalmente no caso daquelas intermitentes.⁴

De maneira geral, pode-se comparar a performance de uma rede neural com outro tipo de rede, por exemplo, uma *Multilayer Perceptron* (MLP), NAR, NARX,⁵ ou um modelo híbrido, como por exemplo, uso de lógica *neuro-fuzzy*. Outros modelos que podem ser usados são o de persistência, *Random Forest*,⁴ ou abordagens por séries temporais.⁶

Além disso, dentro de um mesmo tipo de rede, pode-se variar os parâmetros de entrada, como, por exemplo, os percentuais de dados destinados a treinamento, validação e teste, ou o número de neurônios na camada escondida.⁷

Quanto aos inputs fornecidos à RNA, é possível combinar não só dados brutos, como também imagens de satélite, que permitem avaliar inclusive condições de nebulosidade.⁸ Outra importante abordagem consiste no uso de *Numerical Weather Prediction* (NWP) como input do modelo.

Isto permite não só promover o refinamento das previsões fornecidas, como também prever a produção de uma usina eólica ou fotovoltaica no curto prazo.⁹ Afinal, tais dados podem informar a passagem de frentes frias, ou fenômenos diversos que possam influenciar no comportamento da variável de interesse.

Outro aspecto importante está na previsão de curto e curtíssimo prazo. O uso de ferramentas de previsão do comportamento da radiação solar ao longo de um dia ou de alguns dias à frente pode colaborar com uma gestão energética mais eficaz, uma vez que permite antever períodos de baixa geração de potência.¹⁰

2. Material e Métodos

Como dito anteriormente, este trabalho busca uma configuração de rede neural recorrente que realize a previsão um passo à frente da GHI. A base de dados provém da rede do Sistema de Organização Nacional de Dados Ambientais (SONDA),¹¹ e contempla a estação de Brasília/DF. O intervalo considerado foi de abril de 2008 a outubro de 2009.

As variáveis medidas pela estação são as seguintes: Temperatura do ar superficial ($^{\circ}\text{C}$), Umidade relativa do

ar (%), Pressão atmosférica (mbar), Velocidade (ms^{-1}) e Direção ($^{\circ}$) média do vento a 10m, Precipitação (mm), Média das radiações global horizontal (Wm^{-2}), direta normal (Wm^{-2}) e difusa (Wm^{-2}), Médias da ROL (radiação de onda longa) descendente (Wm^{-2}) com correção, da radiação fotossinteticamente ativa ($\mu\text{mol s}^{-1}\text{m}^{-2}$), e da iluminância (kLux).

Os dados apresentavam resolução de minuto, e foram convertidos em informações diárias da seguinte maneira: nas cinco primeiras citadas calculou-se o valor médio diário e para os demais casos utilizou-se a integral do período.

Para elaborar as redes foi utilizada a ferramenta *ntstool* do Matlab¹² 2019[®]. Buscou-se inicialmente comparar a influência isolada de cada atributo exógeno na rede neural, assim como a combinação entre diferentes arranjos de variáveis. A performance destas RNAs foi comparada a uma NAR com a mesma estrutura, exceto pelas variáveis auxiliares.

Feito isso, a configuração mais assertiva foi comparada a dois modelos estatísticos de previsão: modelo *naive* e amortecimento exponencial simples. O primeiro considera que a previsão o elemento ($t + 1$) da série é a repetição do termo anterior, t .¹³

Já o amortecimento exponencial simples¹⁴ é feito considerando alguns parâmetros que inicialmente são estimados e vão sendo substituídos à medida que a série é atualizada com novos dados. Assim, a previsão \hat{y}_{t+h} do instante t , h passos à frente, é:

$$\hat{y}_{t+h} = l_t; l_t = \alpha y_t + (1 - \alpha)l_{t-1} \quad (4)$$

O valor de l_t é calculado considerando o histórico da série e o hiperparâmetro α . Este é fixado entre 0 e 1, e representa o quão sensível o modelo é aos dados mais recentes. Pode-se expandir este termo até atingir os inputs iniciais do problema. Com isso, tem-se a previsão do instante ($t + 1$) da série como função dos valores anteriores somados a pesos que decaem exponencialmente:

$$l_t = \alpha y_t + \alpha(1 - \alpha)y_{t-1} + \alpha(1 - \alpha)^2 y_{t-2} + \dots + \alpha(1 - \alpha)^{t-1} y_0 \quad (5)$$

É importante destacar que os erros de cada rede de previsão foram calculados utilizando os erros MAPE e RMSE:

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{y_i - x_i}{x_i} \right|}{n}; RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}} \quad (6)$$

Buscou-se a configuração de rede neural que atingisse boa generalização do comportamento da GHI com os menores erros possíveis. Para isso, valores de erros baixos na validação indicam boa capacidade de a rede fazer previsões com diferentes conjuntos de dados, mas o principal foco está no teste. Como este conjunto não é apresentado à rede, menores erros indicam que ela conseguiu atingir o objetivo.

3. Resultados e Discussão

3.1. Sensibilidade a entradas isoladas e combinadas

Foram construídas diversas redes, variando os parâmetros mencionados, e os principais resultados são apresentados a seguir. A Tabela 1 sintetiza as principais redes, e seus respectivos erros.

Nos dois primeiros casos, foram considerados os seguintes parâmetros para a RNA:

- Algoritmo de treinamento: *Bayesian Reularization*.
- Percentuais de treinamento, validação e teste: 70%, 15% e 15% dos dados.
- Janela de 30 dias para compor a previsão de um dia à frente.
- Número de neurônios na camada escondida: 3.

Já no último, a melhor configuração testada, a estrutura da RNA foi mantida, exceto pelo número de neurônios na camada escondida (CA), definido como 4, que é a soma de entradas e saídas do modelo. De modo geral, notou-se que o uso de variáveis exógenas pode oferecer melhorias na performance da rede neural.

O caso que apresentou os melhores resultados com uma única variável exógena utilizou a precipitação como auxiliar, indicando que ela exerce influência na previsão. Outra variável que gerou bons resultados foi a direção do vento, em efeito combinado com a primeira.

Uma das explicações para este assunto está nos valores aleatórios dos pesos utilizados na inicialização da rede. Isto, no entanto, é feito de modo aleatório pela *toolbox*, não havendo possibilidade de alteração pelo usuário.

Outro fator importante está no comportamento das duas variáveis. A Figura 1 compara a evolução diária da GHI real e da precipitação diária acumulada. É possível perceber que quando a série de GHI real encontra-se mais estável (regiões destacadas em verde), não há chuva, e quando a série se torna mais instável (região destacada em roxo), há ocorrência de chuva. Além disso, picos de precipitação tendem a coincidir com vales de GHI real diária.

Tabela 1. Erros para a validação e o teste para a sensibilidade de variáveis exógenas

Variável exógena	MAPE_V	RMSE_V	MAPE_T	RMSE_T
Nenhum (NAR)	10,33%	39.119	13,39%	51.782
Precipitação de Chuva	9,70%	36.533	10,31%	41.297
Precipitação e direção do vento (4 neurônios na CA)	7,01%	29.149	5,75%	29.384




Figura 1. Evolução da GHI real e da precipitação diária acumulada.

A Figura 2 mostra um exemplo de meteograma, gerado pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC)¹⁵, em 19 de junho de 2019 para a cidade do Rio de Janeiro. Um meteograma contém informações sobre a previsão do tempo para os próximos dias a partir de algumas variáveis meteorológicas, como por exemplo, precipitação (mm/h), temperatura (°C), velocidade e direção do vento (°) a 10m de altura (m/s).

Destaca-se que as setas indicam a direção de onde parte o vento, como por exemplo, de Sul (↓). É possível perceber que, quando ocorre a chegada de um sistema frontal, no caso em questão, a chegada de uma frente fria, a direção do vento sofre uma mudança brusca. Segundo o meteograma, a partir das 18Z de 19 de junho, aproximadamente, a massa de ar frio entra em contato com o ar quente presente naquele momento, e a direção do vento, tipicamente de noroeste, gira no sentido anti-horário, tornando-se um vento de nordeste quando a precipitação inicia.

Esta mudança na direção do vento é característica da chegada de sistemas frontais, comuns no hemisfério Sul, e possivelmente foi aprendida pela rede neural, gerando erros mais baixos.

3.2. Comparação com Previsão *Naive* e Amortecimento exponencial

A Figura 3 apresenta a comparação entre a RNA que obteve melhor desempenho e a curva real da GHI, permitindo comparar o desempenho da rede.

A Tabela 2 ilustra os resultados obtidos para os dois modelos de previsão empregados e a Figura 4 apresenta a resposta dos outros dois modelos de previsão. Percebe-se que a previsão *naive* apresentou os maiores erros, provavelmente pela defasagem em um dia entre previsão e observação. Já no caso do amortecimento exponencial, observa-se que o modelo não conseguiu aprender os picos e vales da GHI real, algo que a NARX teve melhor desempenho.

4. Conclusão

Este trabalho utilizou redes neurais artificiais recorrentes, dos tipos NAR e NARX, para realizar a previsão um passo à frente da GHI na cidade de Brasília/DF. Foram ajustados




Figura 2. Meteograma para o Rio de Janeiro/RJ, a partir de 19 de junho de 2019. Fonte: CPTEC¹⁵ (2019), adaptado.



Figura 3. Rede NARX com melhor desempenho.

Tabela 2. Erros para a validação e o teste comparando a NARX com os modelos *Naive* e de Amortecimento exponencial

Previsão	MAPE_V	RMSE_V	MAPE_T	RMSE_T
NARX (precipitação e direção do vento)	7,01%	29.148,99	5,75%	29.383,55
<i>Naive</i>	11,23%	40.763,96	19,28%	67.920,73
Amortecimento Exponencial	0,06%	1.819,10	9,36%	35.091,81




Figura 4. Modelos *naive*, de amortecimento exponencial e a curva real da GHI.

diferentes parâmetros e combinações de variáveis exógenas no modelo, obtendo-se a configuração que ofereceu a melhor resposta, que apresentou os seguintes erros:

- MAPE: Validação (7,01%) e Teste (5,75%).
- RMSE: Validação (29.148,99 W/m²) e Teste (29.383,55 W/m²).

Isto mostra que o emprego de redes recorrentes pode ser uma boa alternativa à previsão de variáveis intermitentes como esta, que apresentam forte dependência do tempo.

Como sugestões para trabalhos futuros, pode-se empregar este modelo de redes para obter a previsão da irradiação direta normal, uma vez que ela é fundamental à produção de energia elétrica em plantas de Energia Solar Concentrada (*Concentrated Solar Power – CSP*).

Além disso, pode-se complementar este trabalho com dados de potência produzida por uma unidade fotovoltaica, visando obter não a GHI diária, mas a produção de energia elétrica para uma usina. Isto pode contribuir no planejamento energético de empreendimentos como este.

Referências Bibliográficas

1. Empresa de Pesquisa Energética Energia Renovável: Hidráulica, Biomassa, Eólica, Solar, Oceânica Rio de Janeiro, 2016. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/livro-sobre-energia-renovavel-hidraulica-biomassa-eolica-solar-oceanica>>. Acesso em: 1 junho 2019.
2. Kalougirou, S. A.; *Solar energy engineering: processes and systems*, 1a ed, Elsevier: California, 2009.
3. Haykin, S.; *Redes Neurais: Princípios e prática*, 2a ed, Bookman: São Paulo, 2008.
4. Benali, L.; Notton, G.; Fouilloy, A.; Voyant, C.; Dizene, R.; Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components. *Renewable Energy* **2019**, *132*, 871. [CrossRef]
5. Hussain, S.; Al Alili, A.; A hybrid solar radiation modeling approach using wavelet multiresolution analysis and artificial neural networks. *Applied Energy* **2017**, *208*, 540. [CrossRef]
6. Voyant, C.; Motte, F.; Fouilloy, A.; Notton, G.; Paoli, C.; Nivet, M. L.; Forecasting method for global radiation time series without training phase: Comparison with other well-known prediction methodologies. *Energy* **2017**, *120*, 199. [CrossRef]
7. Hussain, S.; Alili, A. A.; A pruning approach to optimize synaptic connections and select relevant input parameters for neural network modelling of solar radiation. *Applied Soft Computing Journal* **2017**, *52*, 898. [CrossRef]
8. Mazorra Aguiar, L.; Pereira, B.; David, M.; Díaz, F.; Lauret, P.; Use of satellite data to improve solar radiation forecasting with Bayesian Artificial Neural Networks. *Solar Energy* **2015**, *122*, 1309. [CrossRef]
9. Sobri, S.; Koohi-Kamali, S.; Rahim, N. A.; Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management* **2018**, *156*, 459. [CrossRef]
10. Aguiar, L. M.; Pereira, B.; Lauret, P.; Díaz, F.; David, M.; Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. *Renewable Energy* **2016**, *97*, 599. [CrossRef]
11. Instituto de Pesquisas Espaciais, Sistema de Organização Nacional de Dados Ambientais. Disponível em: <<http://sonda.cest.inpe.br/>>. Acesso em: 1 junho 2019.
12. Mathworks Matlab. 2019.
13. Ratnieks, I.; *Trabalho de Conclusão*, Universidade Federal do Rio Grande do Sul, 2010. [Link]
14. Gardner Jr, E. S.; Exponential Smoothing: The State of the Art - Part II. *International Journal of Forecasting* **2006**, *22*, 637. [CrossRef]
15. Centro de Previsão de Tempo e Estudos Climáticos, Instituto Nacional de Pesquisas Espaciais. Disponível em: <<https://www.cptec.inpe.br/>>. Acesso em: 19 junho 2019.