

A UTILIZAÇÃO DAS REDES NEURAIS ARTIFICIAIS NA PREVISÃO DE RADIAÇÃO SOLAR GLOBAL

IAN ARAUJO MENDES¹, RAFAEL AUGUSTO DIAS REZENDE^{2*}, THIAGO HENRIQUE FERREIRA NASCIMENTO³, JULIANA SEGTOWICK FONSECA E SILVA⁴, ORLANDO FONSECA SILVA⁵

¹Graduando de Engenharia Elétrica, UFPA, Belém-PA, ian.eletrica@gmail.com;

²Graduando de Engenharia Elétrica, UFPA, Belém-PA, rafael.augusto.d.r@gmail.com;

³Graduando de Engenharia Elétrica, UFPA, Belém-PA, thiago_hfn@hotmail.com;

⁴Graduanda de Engenharia Elétrica, UFPA, Belém-PA, julianasegtowick.eng@gmail.com;

⁵ Professor da Faculdade de Engenharia Elétrica, UFPA, Belém-PA, orfosi@ufpa.br

Apresentado no
Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC'2017
8 a 11 de agosto de 2017 – Belém-PA, Brasil

RESUMO: A capacidade de geração de energia elétrica por células solares está diretamente relacionada com a radiação de energia solar na área de instalação das placas. A previsão da radiação solar, portanto, permite o uso mais racional desta geração. Considerando que as técnicas de inteligência artificial fornecem ferramentas capazes de estimar dados de sistemas complexos, neste trabalho, utiliza-se redes neurais artificiais para a previsão da radiação de energia solar global, a partir dos dados disponibilizadas pelo Sistema de Organização Nacional de Dados Ambientais – SONDA. A Rede Neural Artificial utilizada é do tipo *Multilayer Perceptron* e a predição é feita utilizando a *Toolbox Neural Network* do software Matlab.

PALAVRAS-CHAVE: Energia solar, previsão da radiação solar, redes neurais artificiais, inteligência computacional.

THE USE OF ARTIFICIAL NEURAL NETWORKS IN THE GLOBAL SOLAR RADIATION FORECAST

ABSTRACT: The capacity of electric energy generation by solar cells is directly related to the solar energy radiation in the installation area of the boards. The solar radiation forecast, therefore, allows the rational use of this generation. Considering that the techniques of artificial intelligence provide capable tools to estimate data of complex systems, in this work artificial neural networks are used for the forecast of the radiation of global solar energy, from the data made available by the National Organization System of Environmental Data - PROBE. The type of Artificial Neural Network used is Multilayer Perceptron and the prediction is made using the Neural Network Toolbox of Matlab software.

KEYWORDS: Solar energy, Prediction of solar radiation, Artificial neural networks. Computational intelligence.

INTRODUÇÃO

O setor elétrico é fundamental ao abastecimento das infraestruturas mais importantes para a economia e sociedade, sendo essencial para a manutenção da saúde e saneamento, apresentando relação direta com a qualidade de vida (Relva et al., 2015), porém existe a necessidade de criar meios de atender essa crescente demanda sem degradar ainda mais o planeta (PUCRS, 2010).

A energia proveniente do Sol sobre o planeta Terra, que se dá através da sua irradiação, é responsável direta ou indiretamente por quase todas as fontes de energia. De forma direta, além de utilizada para o aquecimento de fluidos para geração de potência mecânica, tal energia pode ser convertida em elétrica através de materiais fotovoltaicos, sendo essa uma forma não poluente de gerar eletricidade. O principal empecilho para essa forma de geração em escala comercial é o elevado custo

das células solares, assim, torna-se imprescindível que o local aonde o sistema fotovoltaico venha a ser instalado tenha a maior capacidade de geração por células solares possível, capacidade essa que está diretamente relacionada com a radiação de energia solar na área em questão (ANEEL, 2008).

Existem duas formas de realizar o levantamento dos recursos de energia solar em regiões de vasta extensão: uso de radiômetros associados a técnicas de interpolação dos dados coletados; e utilização de modelos computacionais para determinar estimativas da radiação solar incidente baseadas em solução da equação de transferência radiativa na atmosfera, ou relações empíricas. Os resultados em cada um dos métodos apresentam alto grau de confiabilidade, porém para o primeiro, os radiômetros não podem estar em distâncias superiores a 45km (quarenta e cinco quilômetros), do contrário o nível de confiabilidade decai, assim, para grandes áreas utiliza-se o segundo método (Pereira *et.al.*, 2006).

A partir de dados de radiação solar disponibilizados ao público pelo Sistema de Organização Nacional de Dados Ambientais (SONDA), este trabalho objetiva aplicar uma rede neural artificial (RNA) *perceptron* de multicamadas como uma forma alternativa de realizar a previsão de radiação solar em uma área de interesse e caracterizar as vantagens da adoção de tal método.

MATERIAIS E MÉTODOS

A *Neural Network Toolbox* do *software* Matlab (Matlab, 2017) foi escolhida para as simulações, pois fornece algoritmos, funções e aplicativos para criar, treinar, visualizar e simular redes neurais. A RNA utilizada é do tipo *Multilayer Perceptron* (MLP), capaz de fazer qualquer mapeamento de entrada-saída desejado, desde que unívoco, e que o número de neurônios na camada intermediária seja satisfatório (Hecht-Nielsen, 1990).

Pode-se destacar na arquitetura de uma MLP três perfis de camadas (Chatfield, 1989). A primeira é a camada de entrada e não é constituída por neurônios, e sim pelas conexões dos sinais de entrada. A segunda, camada intermediária ou camada escondida, é composta por N neurônios, e realiza algumas transformações. Por fim, a camada de saída, onde existem tantos neurônios quanto o número de saídas desejadas, cada saída representa uma variável que se deseja realizar a previsão (Chatfield, 1989).

Para dimensionar os valores inexatos, que geralmente são provenientes da Estatística (Wonnacott & Wonnacott, 1990), neste trabalho, o erro será calculado de três maneiras distintas: na forma do Erro Médio Percentual (MAPE), Equação 1, erro médio absoluto (MAE), Equação 2 e Raiz do Erro Médio Quadrático Percentual (REMQP) Equação 2. Em ambas as expressões y_i consiste no valor real do período i , yp_i é a predição para o período i e N é o número de períodos no conjunto de validação.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - yp_i}{y_i} \right| \quad (1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - yp_i| \quad (2)$$

$$REMQP = \left\{ \frac{1}{N} \sum_{i=1}^N \left[\frac{y_i - yp_i}{y_i} \right]^2 \right\}^{\frac{1}{2}} \quad (3)$$

Em todo problema a ser solucionado através de uma RNA, é preciso a utilização de pares de entrada-saída já identificados, que devem ser separados em dois grupos bem definidos: o de treinamento e o de validação.

No experimento computacional utilizou-se as medições disponíveis em SONDA (2017), ou seja, considerou-se a série temporal de radiação global horizontal (W/m^2), durante os meses de julho e agosto de 2016. Cada série apresenta 44640 medições (medidas em intervalos de 1 minuto). Para o treinamento utilizou-se 35712 medições (80% do total) e para validação 8928 medições (20% do total), ambas do mês de julho. Para o teste da rede neural utilizou-se medições do mês de agosto.

A RNA foi desenhada para fornecer previsões um passo à frente, apresentando a seguinte configuração: 3 valores de entrada (velocidade do vento nos instantes $t-1$, $t-2$ e $t-3$); uma camada intermediária com diferentes valores de neurônios (1, 10, 20, 30, 40 e 50) e utilizando a função de ativação *tansig*; e 1 neurônio na camada de saída (função de ativação *purelin*). O ajuste da RNA foi realizado utilizando-se o algoritmo de treinamento *backpropagation*, aplicando os dados normalizados ao intervalo $[-1, 1]$.

RESULTADOS E DISCUSSÃO

Para cada experiência, é necessário procurar a melhor configuração, ou seja, no caso descrito, testar diversos números de neurônios na camada intermediária. A Tabela 1 apresenta as estatísticas MAPE, MAE e REMQP das amostras de treinamento e validação.

Tabela 1. Estatística de desempenho da rede neural para diferentes topologias de rede.

Topologia da rede neural	Amostras de Treino			Amostras de Validação		
	MAPE(%)	MAE (W/m ²)	REMQP(%)	MAPE(%)	MAE (W/m ²)	REMQP(%)
(3,1,1)	24.88	20.99	3.83	36.21	21.98	5.46
(3,10,1)	23.44	19.79	3.80	18.24	19.88	4.56
(3,20,1)	43.86	19.94	32.9	44.56	19.98	34.90
(3,30,1)	47.57	20.14	22.4	48.89	22.56	24.63
(3,40,1)	41.69	20.07	26.06	43.24	21.76	27.90
(3,50,1)	40.98	20.36	4.25	40.87	20.89	7.89

O treinamento foi realizado 5 vezes para cada topologia de rede usando na inicialização diferentes pesos. Os valores de MAPE, MAE e REMQP ilustrados na Tabela 1 são a média aritmética dos treinamentos realizados para cada topologia de rede, assim como para as amostras de validação. A melhor configuração da rede neural foi com a de 10 neurônios na camada intermediária, apresentando os menores valores de estatística de desempenho.

Para o teste da rede neural, foram utilizados 2 conjuntos de amostras do mês de agosto de 2016 cada uma com 1440 medições que representam um dia inteiro de medição amostrado de 1 em 1 minuto. Os conjuntos de teste correspondem aos dias 08 e 26 de agosto de 2016.

A seguir, as Figuras 1 e 2 mostram as previsões e os respectivos valores observados de radiação solar global. Na Tabela 2 são apresentadas as estatísticas MAPE, MAE e REMQP das amostras de teste obtidas nas duas situações propostas

Figura 1. Radiação solar prevista para o dia 08 de agosto de 2016.

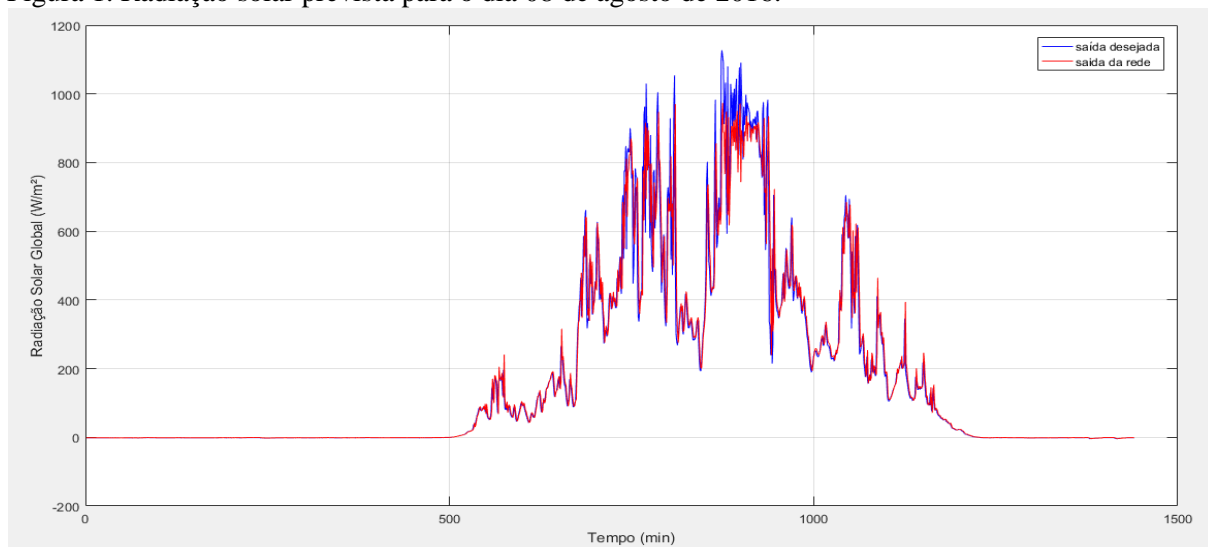


Figura 2. Radiação solar prevista para o dia 26 de agosto de 2016.




Tabela 2. Estatísticas de desempenho para as amostras de teste da rede neural.

Período	MAPE(%)	MAE (W/m ²)	REMQP(%)
08 de agosto de 2016	17.83	21.34	8.38
26 de agosto de 2016	12.19	18.69	5.37

Conforme explicitado na Figuras 1 e 2, os valores de radiação solar global previstos com a rede neural, produzem resultados satisfatórios e com um bom desempenho conforme retratado nas estatísticas apresentadas na Tabela 2.

CONCLUSÕES

Com o aumento de novas usinas solares, os responsáveis pela operação de sistemas elétricos necessitam de ferramentas capazes de prever a disponibilidade de recursos solares para a previsão de curto prazo. Para isso, destacam-se as técnicas de inteligência computacional, em particular as redes neurais artificiais. Os resultados apresentados nesse trabalho mostram a capacidade preditiva da RNA utilizada, conforme verificado nas estatísticas de desempenho (MAPE, MAE e REMQP).

O método de previsão com redes neurais artificiais pode ser aplicável a qualquer região do Brasil, e até mesmo em regiões em que não haja estações de monitoramento, possibilitando que os engenheiros possam desenvolver e localizar os sistemas de energia solar, aproveitando o melhor da capacidade fotovoltaica.

Em resumo, o trabalho apresentou a utilização de uma RNA para previsão de dados de modelos com características não lineares, onde se obteve êxito na previsão de radiação solar global. Deixa-se como proposta para trabalhos futuros a aplicação de arquiteturas diferentes de redes neurais, tal como a RNA de base radial, além de utilizar outras formas de tratamento e treinamento de dados para que a MLP seja capaz de melhorar ainda mais seu desempenho.

AGRADECIMENTOS

Ao Sistema de Organização Nacional de Dados Ambientais (SONDA) pelas medições confiáveis e validadas de informações climatológicas que são fornecidas ao público em geral.

REFERÊNCIAS

ANEEL. Atlas de Energia Elétrica do Brasil: Fontes Renováveis. 3. ed. – Brasília, 2008.
 Chatfield, C. The Analysis of Time Series – An Introduction. Chapman and Hall, New York, 1989.

- Hecht-Nielsen, R. Neurocomputing. Addison-Wesley Publishing Company, New York, 1990.
- Junior, L.A.T; Pessanha, J.F.M; Souza, R.C. Análise Wavelet e Redes Neurais Artificiais na Previsão da Velocidade de Vento. In: Simpósio Brasileiro de Pesquisa Operacional. SBPO 2011, Ubatuba, Anais... São Paulo, 2011.
- MATLAB, Neural Network Toolbox, disponível em:
<https://www.mathworks.com/programs/trials/trial_request.html?prodcode=NN>. Acessado em 1/2017.
- Pereira, E.B.; Martins, F.R; Abreu, S.L; Ruthër, R. Atlas Brasileiro de Energia Solar. São José dos Campos: INPE. 2006.
- PUC-RS. USE - Uso Sustentável da Energia: Guia de orientações. Grupo de Eficiência Energética. Faculdade de Engenharia. PUCRS - Porto Alegre, 2010. Disponível em:
<www.pucrs.br/biblioteca/manualuse.pdf>. Acessado em 30/12/2015.
- Relva, S. G.; Udaeta, M.E.M.; Grimoni, J.A.B.; Galvão, L.C.R.. Avaliação comparada da geração de energia por fontes renováveis e não renováveis nos sistemas elétricos. XXIII SNPTEE. Foz do Iguaçu – PR, 2015.
- SONDA. Sistema de Organização de Dados Ambientais. 2017. Disponível em:
<http://sonda.ccst.inpe.br/>. Acesso em: 01/05/2017.
- Wonnacott, T. & Wonnacott, R. Introductory Statistics for Business and Economics. John Wiley & Sons, New York, 1990.