

UTILIZAÇÃO DAS REDES NEURAIS ARTIFICIAIS NA PREVISÃO DE VELOCIDADE DO VENTO

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 Prof. 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 geração de energia elétrica por fonte eólica tem se mostrado competitiva pela contínua diminuição de seus custos. Como o vento é um fenômeno natural e estocástico, qualquer previsão de geração baseada nele, visando a produção de energia, torna-se um grande desafio. Dentre as técnicas de previsão que podem ser utilizadas para tal finalidade, destacam-se as técnicas de inteligência computacional, mais especificamente, as redes neurais artificiais. Como a potência gerada por uma turbina eólica tem uma relação direta com a velocidade do vento, neste trabalho analisa-se a vantagem da utilização das redes neurais artificiais como previsor da velocidade do vento. A análise é conduzida a partir de medições anemométricas disponibilizadas pelo SONDA (Sistema de Organização Nacional de Dados Ambientais). Os resultados mostraram boa precisão e eficiência, demonstrando a capacidade das redes neurais artificiais na previsão de velocidade do vento.

PALAVRAS-CHAVE: Energia eólica, inteligência computacional, previsão de velocidade do vento, redes neurais artificiais.

USE OF ARTIFICIAL NEURAL NETWORKS IN WIND SPEED FORECAST

ABSTRACT: The generation of electricity by wind power has been considered competitive by continuous decrease of its costs. As wind is a natural and stochastic phenomenon, any forecast of power generation, aiming at an energy production, becomes a great challenge. Among the prediction techniques that can be used for the final purpose, stand out as computational intelligence techniques, more specifically, as artificial neural networks. As a power generated by a wind turbine has a direct relation with a wind speed, in this work an advantage of the use of the artificial neural networks as predictor of the wind speed is analyzed. The analysis is conducted using anemometric measurements provided by SONDA (Environmental Data Organization System). The results showed good accuracy and efficiency, demonstrating an artificial neural network capability in wind speed prediction.

KEYWORDS: Wind power, computational intelligence, wind speed forecast, artificial neural networks.

INTRODUÇÃO

O setor de energia elétrica tem expandido a geração por fontes não poluentes e com baixos riscos de desastres ambientais. Dentre as alternativas, a geração de energia por fonte eólica possui sua tecnologia consolidada e tem apresentado a maior taxa de crescimento (Lara et al., 2009).

No Brasil, a implementação da tecnologia eólica se deu pelo Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA), lançado em 2004, baseado em uma estrutura de financiamento e políticas regionais. Até o início de 2017, o país detinha uma capacidade eólica instalada de 10.850 MW, valor que representa 7,1% de sua matriz energética. No período, os empreendimentos em fase de construção totalizavam 2.776,9 MW e 4.318,3 MW contratados (Hiruma et al., 2017).

Nos estudos para implementação de empreendimentos eólicos, sabe-se que a geração eólica depende fundamentalmente da velocidade do vento incidente no aerogerador e que sua potência é proporcional ao cubo da velocidade do vento, assim, pequenas alterações no vento incidente provocam grandes mudanças na geração. A previsão de geração eólica é de difícil determinação, embora seja imprescindível para o setor elétrico. O operador da rede elétrica, por exemplo, deve manter uma capacidade de reserva no programa de despacho para que garanta equilíbrio entre carga e energia. A previsão, nesse contexto, serve para reduzir o custo de tal reserva. O operador do parque eólico, por outro lado, tem interesse nessas informações para gerir, de forma otimizada, as ações de operação e manutenção do empreendimento (Tong, 2010).

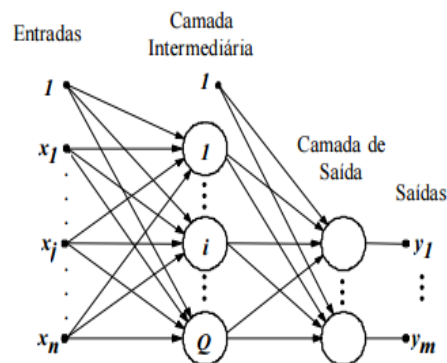
Assim, para prever a potência eólica gerada, pode-se começar pela previsão da velocidade do vento. Usualmente, é utilizado o modelo de séries temporais. A análise desse modelo conta com uma ampla variedade de métodos estatísticos e de inteligência artificial. Esta abordagem tem a vantagem de fornecer e atualizar as previsões na escala do tempo em que são tomadas as decisões operativas do setor elétrico. Seja qual for a abordagem utilizada, a qualidade dos registros anemométricos é fundamental para a precisão das previsões.

Este trabalho tem a finalidade de analisar a eficiência e eficácia da aplicação da rede neural artificial (RNA) *perceptron* de multicamadas (MLP) na previsão de velocidade do vento. Para exemplificar a aplicação da RNA proposta considerou-se a série temporal de velocidade do vento na cidade de São Luís, no Estado do Maranhão, onde está localizada uma das estações anemométricas do projeto SONDA, que fornece acesso público às informações climatológicas de algumas cidades no Brasil.

MATERIAIS E MÉTODOS

As Redes Neurais Artificiais procuram simular, por técnicas de computação inteligente, o funcionamento do cérebro humano, órgão capaz de solucionar problemas em que não existam regras, e que tem também a capacidade de aprender mediante exemplos. Tais redes são, dessa forma, capazes de manusear dados que contenham ruídos e que sejam incompletos e proceder com problemas não lineares e complexos da vida real. O neurônio artificial *perceptron* de multicamadas, ilustrado na Figura 1, é composto por entradas, camada intermediária e camada de saída.

Figura 1. Arquitetura da rede neural MLP



Fonte: Haykin (2001).

De forma análoga ao processamento no cérebro humano os pesos nas conexões entre as camadas são ajustados durante o processo de aprendizagem de uma RNA. A primeira camada da RNA é a camada de entrada, sendo a única exposta às variáveis de entrada. Esta camada transmite os valores das variáveis de entrada para os neurônios da camada intermediária para que estes extraiam as características relevantes (ou padrões) dos sinais de entrada e transmitam os resultados para a camada de saída. A definição do número de neurônios em cada camada é realizada de forma empírica. O treinamento de uma RNA consiste em um processo iterativo de obtenção dos pesos das conexões entre as unidades de processamento (Junior et al., 2011).

O principal algoritmo de treinamento é o *backpropagation* cujo ajuste dos pesos ocorre mediante um processo de otimização realizado em duas fases: *forward* e *backward*. Na fase *forward*, é calculada a resposta fornecida pela rede para um dado padrão de entrada. Na fase *backward*, o desvio

(erro) entre a resposta desejada (alvo) e a resposta fornecida pela RNA é utilizado para o ajuste dos pesos das conexões. Ao longo do treinamento da rede neural os vários padrões de entrada e as respectivas saídas desejadas são apresentados à RNA, de forma que os pesos das sinapses sejam corrigidos, de forma iterativa, pelo algoritmo de treinamento, com a finalidade de minimizar a soma dos erros quadráticos (Junior et al., 2011).

Todo problema de previsão possui uma metodologia própria de resolução. Neste trabalho, serão utilizadas algumas características e definições particulares, como estatísticas de desempenho: erro médio percentual absoluto (MAPE), Equação (1), erro médio absoluto (MAE), Equação (2) e raiz do erro médio quadrático percentual (REMQP), Equação (3), para avaliação do erro aceitável na previsão da velocidade do vento, conforme estabelecido por Wonnacott & Wonnacott (1990).

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

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

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

Onde:

y_i é o valor real no período i ;

y_{pi} é a previsão no período i ;

N é o número de períodos no conjunto de validação.

No experimento computacional utilizou-se as medições contidas em SONDA (2017), especificamente a série temporal de velocidade do vento (m/s), a 10m de altura, durante os meses de fevereiro e março de 2016. Cada série apresenta 44640 medições (medidas em intervalos de 1 minuto). O *software* utilizado no experimento foi o MATLAB (MathWorks, 2017).

Para o treinamento utilizou-se 35712 medições (80% do total) e para validação 8928 medições (20% do total), ambas do mês de fevereiro. Para o teste da rede neural utilizou-se medições do mês de março.

A rede neural artificial foi treinada 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 números 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 (m/s)	REMQP(%)	MAPE(%)	MAE (m/s)	REMQP(%)
(3,1,1)	39.989	0.154	11.627	36.211	0.178	12.567
(3,10,1)	17.692	0.169	9.960	18.245	0.190	9.865
(3,20,1)	17.335	0.227	8.841	17.998	0.225	8.256
(3,30,1)	17.017	0.205	9.384	19.668	0.252	9.972
(3,40,1)	19.879	0.199	7.966	18.721	0.182	8.860
(3,50,1)	16.091	0.138	7.741	16.651	0.144	7.922

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 50 neurônios na camada intermediária, apresentando os menores valores de estatística de desempenho.

Para o teste da rede neural, foram utilizados 2 dois conjuntos de amostras do mês de março de 2016, cada um com 1440 medições realizadas em 24 horas à intervalos de 1 minuto. Os conjuntos de teste correspondem aos dias 15 e 30 de março de 2016.

As previsões e os respectivos valores observados de velocidade do vento são ilustrados nas Figuras 2 e 3. Na Tabela 2 são apresentadas as estatísticas MAPE, MAE e REMQP das amostras de teste obtidas nas duas situações propostas

Figura 2. Velocidades do vento previstas para o dia 15 de março de 2016.

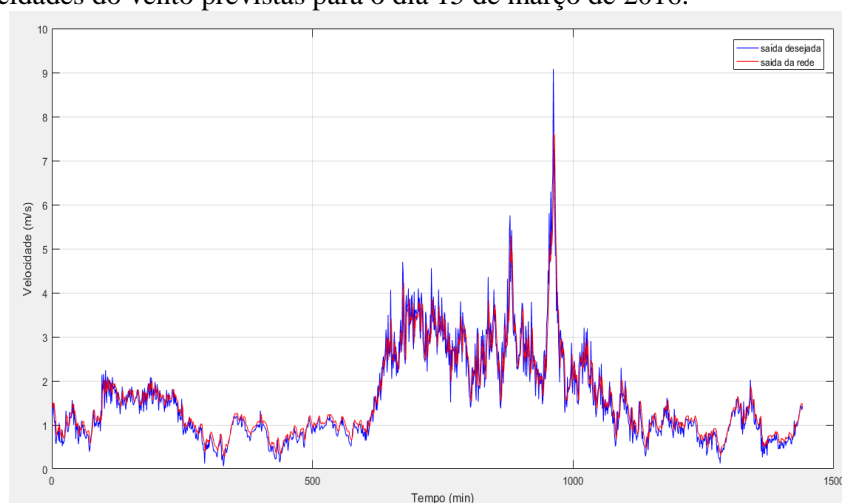


Figura 3. Velocidades do vento previstas para o dia 30 de março de 2016.




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

Período	MAPE(%)	MAE (m/s)	REMQP(%)
15 de março de 2016	17.85	0.26	9.89
30 de março de 2016	13.96	0.189	7.42

Conforme explicitado nas Figuras 2 e 3, os valores de velocidade do vento previstos com a rede neural mostram resultados satisfatórios e eficientes, refletindo o bom desempenho retratado nas estatísticas da Tabela 2.

Observa-se que a discrepância maior ocorre um pouco antes de 1000 minutos, onde se tem uma variação mais acentuada da velocidade do vento. Uma das possíveis causas pode estar relacionada à quantidade de medições não ser suficiente para uma generalização eficaz da rede neural nesses intervalos. Outra explicação é que o número de neurônios na camada intermediária não é suficiente para processar uma grande quantidade de dados.

Uma possível solução, seria aumentar o número de camadas intermediárias, variando empiricamente o número de neurônios, e distribuindo cada camada em faixas do dia (manhã, tarde e noite), mas uma investigação mais detalhada deveria ser realizada no intuito de avaliar melhor as razões que possam amenizar essas discrepâncias.

CONCLUSÕES

Os resultados obtidos evidenciam que o método de previsão com redes neurais artificiais mostra-se eficiente e 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 eólica aproveitando de melhor forma a capacidade eólica.

Em resumo, o artigo apresentou a utilização da RNA para analisar modelos de previsão com características não lineares, foi obtido êxito na modelagem de previsão de velocidade do vento e deixa-se como proposta para trabalhos futuros a aplicação de arquiteturas diferentes de redes neurais, tal como a RNA de base radial; considerar as variáveis meteorológicas (temperatura, pressão e umidade relativa do ar) como dados de entrada ao treinamentos das redes neurais; combinar outras técnicas de previsão (modelos híbridos) e além de utilizar outras formas de tratamento e treinamento de dados para MLP que 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 disponibilizadas ao público em geral.

REFERÊNCIAS

- Haykin, S; Neural networks: A comprehensive foundation. Prentice-Hall. 2001.
- Hiruma, F.S; Guetter, A.K; Souza, F.T. Previsão da geração de energia eólica com Redes Neurais Artificiais. Revista Espaço Energia v.26, n.1, p.9-25, 2017.
- 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.
- Lara, O.A; Jenkins, N.; Ekanayake, P.; Hughes, M. Wind Energy Generation: Modelling and Control. Chichester: John Wiley & Sons. 2009.
- MathWorks Products and Services. Disponível em: <http://www.mathworks.com>. Acesso em: 01/05/2017.
- SONDA. Sistema de Organização de Dados Ambientais. 2017. Disponível em: <http://sonda.ccst.inpe.br/>. Acesso em: 01/05/2017.
- Tong, W. Wind Power Generation and Wind Turbine Design. WIT Press. 2010.
- Wonnacott, T; Wonnacott, R; Introductory Statistics for Business and Economics. New York. 1990.