

ESTIMATIVA DA VELOCIDADE MÉDIA DIÁRIA DO VENTO NO MUNICÍPIO DE FORTALEZA UTILIZANDO REDES NEURAIS ARTIFICIAIS

Geraldo Luis Bezerra Ramalho
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE, Campus Maracanaú, Área da Indústria
gramalho@ifce.edu.br

Samuel Vieira Dias
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE, Campus Maracanaú, Área da Indústria
samueldias@ifce.edu.br

RESUMO

Este trabalho apresenta uma metodologia para estimar a velocidade diária do vento no município de Fortaleza a partir de dados históricos e do uso de redes neurais artificiais na predição de séries temporais. No projeto da rede neural, foram utilizados valores de velocidade do vento coletados no período de 2003 e 2004. Os dados foram divididos em duas partes, sendo a primeira utilizada na etapa de treinamento da rede neural e o restante dos dados no processo de validação. Medidas de avaliação de desempenho da estimativa da rede neural foram utilizadas para comparar os dados reais com a predição. Nos experimentos obteve-se um erro quadrático médio de 0,007378 e um coeficiente de desigualdade de Theil de 0,053203. Estes bons resultados sugerem a aplicabilidade da metodologia na predição da velocidade do vento e sua utilização no estudo de viabilidade de parques eólicos.

Palavras-Chave: energia eólica, estimativa da velocidade do vento, redes neurais artificiais.

ABSTRACT

This work presents a methodology to estimate wind speed in the Fortaleza city using historical wind speed data and neural networks for temporal series prediction. The neural network was trained using wind speed dataset between 2003 and 2004. The data were divided in two, one for the neural network training and the other one for its validation. Evaluation measures were taken in order to compare the neural network prediction data to the real data. The experiment results achieved mean square error 0,007378 and Theil inequality coefficient 0,053203. The good results leads to the use of this methodology in wind speed

prediction and to assess eolic plants viability.
Keywords: eolic energy, wind speed forecasting, neural networks.

1. INTRODUÇÃO

O aumento da população mundial, o desenvolvimento dos países e a escassez das fontes de combustíveis fósseis, a-lém dos impactos ambientais inerentes à queima de tais combustíveis, estimularam a busca por novas fontes alternativas de energia, ditas energias limpas [1]. Neste cenário, pode-se destacar a energia eólica como uma fonte abundante de energia, principalmente nas localidades próximas à linha do Equador, como é o caso do Nordeste brasileiro onde é alta a incidência dos ventos alísios [2].

O município de Fortaleza, situado na região litorânea do Nordeste, é caracterizado pela elevada e constante média de velocidade do vento. Ao longo de todo o ano apresenta valores médios em torno de 7,5 a 9m/s, medidos à altura de 50m [3]. Esta característica faz que essa região apresente um elevado potencial eólico. Contudo, a instalação de parques eólicos necessita de um estudo prévio para avaliar, dentre os mais variados fatores, se uma determinada região tem condições mínimas viáveis à instalação de tais parques. Este estudo é realizado por meio da análise de séries temporais dos dados coletados. Porém, é comum haver descontinuidade nestas medições ou dados insuficientes para estudar um comportamento futuro [4]. O processo de coleta de informações, bem como os estudos em campo, demanda tempo e elevado investimento financeiro. Daí a importância da utilização de técnicas de inteligência artificial que possam simular as variáveis ambientais de uma determinada localidade [5]. Neste cenário, surgem as redes neurais artificiais (ANN, Artificial Neural Network) como uma ferramenta de regressão não linear para estimar valores desconhecidos a partir de dados históricos.

Uma aplicação das ANNs em energia eólica consiste na estimativa da velocidade do vento em uma determinada região a partir dos valores coletados em regiões vizinhas. Bilgili et al. [5], utilizaram dados de 8 estações meteorológicas para estimar, através de uma ANN, a média mensal de velocidade do vento em uma estação alvo. Os autores obtiverem um resultado satisfatório apresentando erro percentual médio absoluto entre 4,49 e 14,13 na validação do método.

Mabel et al. [6] mencionam que podemos estimar o potencial eólico de uma determinada região em função dos valores de velocidade média do vento, pois o potencial de uma região é uma função do cubo da velocidade do vento. Em seu estudo, alimentaram uma rede neural com valores de velocidade do vento, umidade do ar e horas de geração coletados no período de 2002 a 2005.

Kalogirou et al. [1] trabalharam com valores de velocidade média do vento para dois níveis de altura, 2m e 7m, fazendo a estimativa para cada nível. Durante a execução de seu trabalho, observaram que não dispunham dos valores da velocidade média do vento no mês de março de 1997 para a

altura de 7m e destacaram que a ANN poderia completar a série temporal no referido mês com ótima precisão.

Um algoritmo neural foi utilizado por Cadenas [7] para estimar a velocidade média do vento de um dia à frente, baseando-se nos valores estimados de velocidade do vento de dois dias anteriores. Cadenas [7] trabalhou com várias estruturas de redes neurais e concluiu que não é necessária uma rede com muitas camadas escondidas e com elevada quantidade de neurônios para obter uma estimativa com erro pequeno. No seu trabalho, o menor erro foi obtido com uma estrutura contendo 3 neurônios, sendo 2 na camada escondida e 1 na camada de saída.

Neste trabalho, apresentamos uma metodologia de estimativa da velocidade do vento utilizando uma ANN para predição de séries temporais. É apresentado um estudo relacionando o tamanho da janela temporal utilizada (quantidade de dias anteriores ao dia alvo) e o número de neurônios da rede com suas taxas de erro de predição. Na seção 2 é apresentada a metodologia utilizada. Na seção 3 são apresentados os resultados experimentais utilizando-se dados coletados no período de 2003 a 2004. As conclusões do trabalho e as propostas de trabalhos futuros são apresentadas na seção 4.

2. METODOLOGIA

2.1. PREDIÇÃO DE SÉRIES TEMPORAIS ATRAVÉS DE REDES NEURAIS ARTIFICIAIS

Uma rede neural artificial (ANN) é um algoritmo computacional que pode ser utilizado para estimar séries temporais com considerável precisão e confiabilidade. Podem ser aplicadas nas mais variadas áreas, como em processos industriais, científicos e na economia [7]. Uma ANN é formada de neurônios, também chamados de perceptrons, conforme ilustrado na Figura 1. A rede de perceptrons de múltipla camada (MLP, Multilayer Perceptron) é uma das mais popularmente utilizadas em trabalhos dessa área.

Os parâmetros livres de uma MLP são ajustados durante um treinamento supervisionado. Este treinamento consiste em alimentar a entrada da rede com valores de um determinado dado de entrada, a fim de estimar os parâmetros (ou pesos), que constituem a memória da rede. Geralmente atribuem-se valores reduzidos ou nulos para os pesos iniciais. Em seguida, é feito um somatório entre os valores do produto produzindo assim o valor da ativação que alimentará a função de saída do neurônio.

Durante o processo de treinamento, a saída produzida pela rede neural é comparada com o valor real desejado, gerando um sinal de erro que servirá como parâmetro na atualização dos pesos. Os erros da saída são projetados no sentido inverso para atualização dos pesos e esse procedimento é conhecido como re-

tropropagação do erro (error backpropagation).

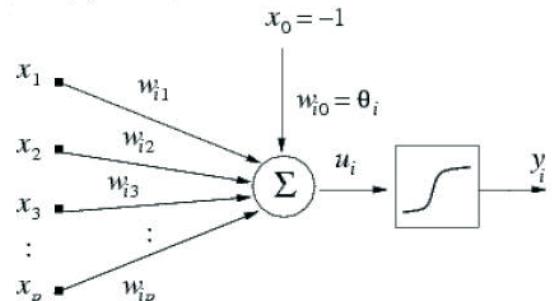


Figura 1: Modelo de um neurônio artificial (perceptron).

Na etapa de validação, é feita uma avaliação de quanto os valores estimados estão próximos aos valores reais coletados. Neste trabalho, faz-se o uso de técnicas estatísticas como o erro quadrático médio (*MSE*, Mean Square Error) e o coeficiente de desigualdade de Theil (*TIC*, Theil Inequality Coefficient), definidos pelas equações

$$MSE = \frac{\sum_{n=1}^N |d_n - y_n|^2}{N} \quad (1)$$

$$TIC = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N |d_n - y_n|^2}}{\sqrt{\frac{1}{N} \sum_{n=1}^N d_n^2} \sqrt{\frac{1}{N} \sum_{n=1}^N y_n^2}} \quad (2)$$

em que N representa o número de dados de entrada. O cálculo de TIC retorna um valor entre 0 e 1. Quanto menor o valor do TIC e do MSE, mais próximo está o valor estimado do valor real.

2.2. DADOS DA VELOCIDADE MÉDIA DIÁRIA DO VENTO EM FORTALEZA

Os dados de velocidade do vento foram coletados pela Fundação Cearense de Meteorologia e Recursos Hídricos – FUNCEME, entre julho de 2003 e junho de 2004, utilizando uma plataforma de coleta de dados cujos instrumentos estão instalados a 10m de altura do solo. Além da velocidade do vento, essas estações medem outras variáveis meteorológicas tais como temperatura do ar, radiação solar, umidade do solo e índice pluviométrico.

2.3. ESTRUTURA DA REDE NEURAL UTILIZADA NA PREDIÇÃO DE VENTOS

No desenvolvimento deste trabalho, foi utilizada uma estrutura de rede neural dinâmica que, através de valores coletados de velocidade do vento $x_t - l$, é capaz de efetuar a estimativa da velocidade do vento no dia

seguinte $y(n)$. Ou seja, a estimativa da velocidade do vento do dia atual é uma função da velocidade do vento coletada nos dias anteriores utilizando uma janela temporal de tamanho.

Haykin [8] chama essa configuração de redes alimentadas adiante (*feedforward*) focadas atrasadas no tempo (TLFN focada). Redes desse tipo são utilizadas quando se necessita processar padrões que evoluem no tempo. A resposta em um instante particular de tempo depende não apenas do valor presente da entrada, mas também de seus valores passados.

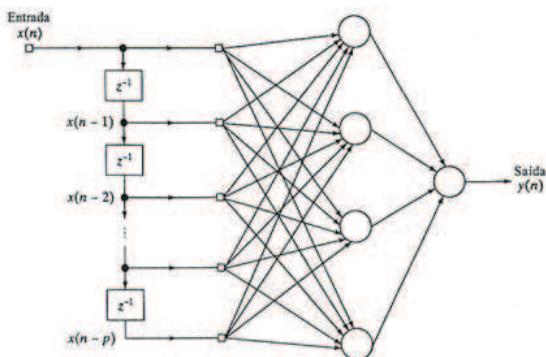


Figura 2: Rede Neural feedforward focada atrasada no tempo (TLFN focada).

De acordo com a observação da Figura 2, temos que a entrada da rede é representada pelo conjunto de vetores $x(n), x(n-1), x(n-2), \dots, x(n-p)$, produzindo uma saída $y(n)$.

A saída desta rede, assumindo que o perceptron de múltiplas camadas tem uma única camada oculta, é dada por

$$y(n) = \sum_{j=1}^{m_l} w_j y_j(n-l) + b_0, \quad (3)$$

em que, m_l é a quantidade de neurônios na camada oculta; w_j são os pesos de entrada do neurônio de saída; $y_j(n-l)$ são os valores de saída dos neurônios da camada oculta em um instante $n-l$; b_0 é o bias ou limiar do neurônio de saída.

$$y_i(n) = \sum_{l=0}^p w_{ij} x(n-l) + b_j \quad (4)$$

em que $\sigma(\cdot)$ é a função de ativação dos neurônios da camada oculta; w_{ij} são os pesos de entrada dos neurônios da camada oculta; $x(n-l)$ são os valores de entrada da rede neural; b_j é o bias ou limiar dos neurônios da camada oculta.

Substituindo a equação (4) em (3), temos

$$y(n) = \sum_{j=1}^{m_l} w_j \left(\sum_{l=0}^p w_{ij} x(n-l) + b_j \right) + b_0 \quad (5)$$

que relaciona a saída da rede neural com configuração (TLFN focada) com os valores de entrada $x(n-l)$.

O termo z^{-1} , presente no modelo da Figura 2, é uma função que relaciona o vetor de entrada atual $x(n)$ com seu respectivo valor em um instante anterior $x(n-1)$ e assim sucessivamente [8]. Baseando-se neste tipo de estrutura, a rede neural foi alimentada com valores de velocidade de vento coletados nos últimos três dias, a fim de realizar uma previsão da velocidade média do vento para o dia atual.

3. RESULTADOS E COMENTÁRIOS

Uma rede neural foi treinada com valores de velocidade do vento diárias do segundo semestre de 2003 e do primeiro semestre de 2004 como ilustrado na Figura 3 (b). A validação foi feita através da predição dos valores de velocidade do vento para o segundo semestre de 2004. Foram testados diversos tamanhos de janelas temporais e diversas arquiteturas de MLP, variando o número de neurônios na camada escondida.

Na Figura 3 (b), é exibido o gráfico dos dados obtidos com a ANN e dos dados reais do segundo semestre de 2004. O melhor resultado foi obtido com uma janela temporal (JAN) de três dias e quinze neurônios na camada escondida (NH). A partir desse gráfico, duas medidas de desempenho foram calculadas para avaliar a diferença entre os dados reais e os dados da previsão. Obteve-se um erro quadrático médio (MSE) de 0,007378 e um coeficiente de desigualdade de Theil (TIC) de 0,053203. O experimento foi repetido diversas vezes, testando várias arquiteturas de rede neural e tamanhos de janela temporal. As medidas de desempenho obtidas em todos os testes foram coerentes com os valores obtidos com a predição exibida da Figura 3 (b). A diferença entre a velocidade da predição em relação ao valor real medido, é de apenas ± 2 m/s.

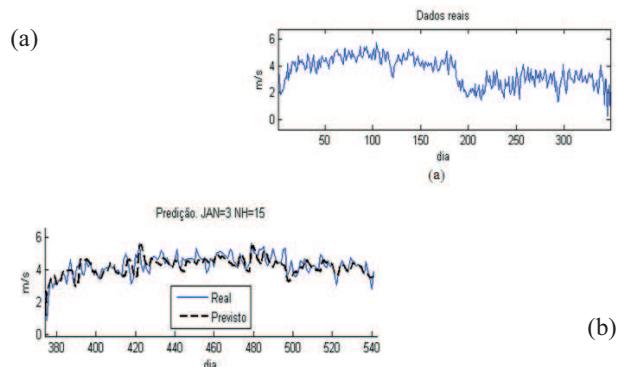


Figura 3: (a) Dados utilizados no treinamento. (b) Resultado da predição para o segundo semestre de 2004, utilizando-se uma janela temporal de 3 dias e 5 neurônios na camada escondida.

O número de neurônios na camada escondida foi escolhido através da análise das Figura 4. Quanto menor a diferença entre os dados coletados e os dados da previsão, menor é o valor

do MSE e do TIC. Os valores próximos a zero são um indicativo de boa precisão da estimativa obtida. Percebe-se que as medidas de desempenho MSE e TIC não variam significativamente com o aumento do número de neurônios. Portanto, foi utilizada a arquitetura de rede com $NH=15$, a fim de manter o custo computacional o menor possível.

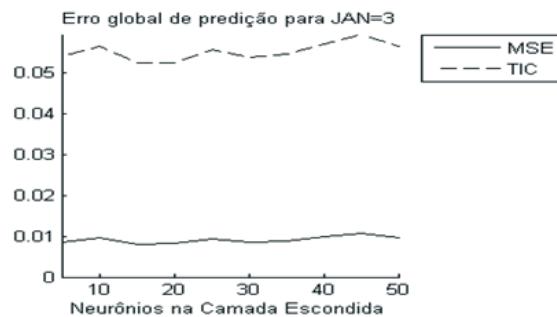


Figura 4. Variação do erro de predição com o número de neurônios da camada escondida.

Para definir o tamanho da janela temporal, foram realizados testes com janelas de três a cento e vinte dias. Os resultados são apresentados na Figura 5 e mostram que, como esperado, janelas menores resultam em erros de predição menores. Isto se deve ao fato de que uma memória recente contém dados mais confiáveis, dada a imprevisibilidade meteorológica.

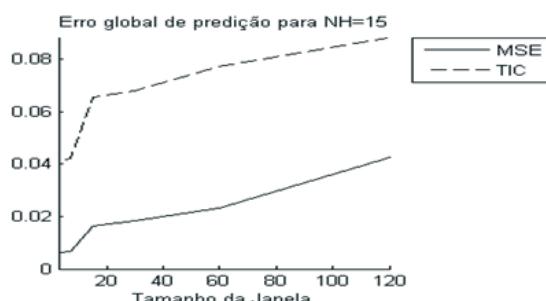


Figura 5. Variação do erro de predição com o tamanho da janela temporal.

4. CONCLUSÃO

Este trabalho apresenta uma aplicação de redes neurais artificiais na área de energia eólica. Através de uma rede neural é possível realizar uma predição confiável de velocidade do vento. Os resultados demonstram que é possível obter uma boa predição da velocidade de ventos com base numa memória de curto prazo, formada pelos três últimos dias de medições. A metodologia utilizada neste trabalho pode ser aplicada no estudo e planejamento de instalação e funcionamento de parques eólicos. Portanto, a metodologia é útil tanto na previsão de comportamento futuro dos aerogeradores, quanto na complementação de dados históricos para análise do potencial energético de uma região.

Os resultados também mostraram que, para a arquitetura de ANN utilizada, a previsão é mais precisa quando se utiliza uma memória de curta duração ou recente, refletida pelo menor erro obtido com janelas temporais pequenas.

Em trabalhos futuros, pretende-se expandir a pesquisa e estudar outros métodos de previsão de séries temporais através de redes MLP dinâmicas e de redes com função de base radial (RBF, Radial Basis Function), esperando-se ampliar o número de dias da previsão e a sua precisão.

5. AGRADECIMENTOS

Os autores agradecem a colaboração da FUNCEME por ter gentilmente fornecido os dados para a realização deste trabalho.

6. REFERÊNCIAS

- [1] S. Kalogirou, C. Neocleous, S. Pashiardis, C. Schizas. Wind Speed Prediction Using Artificial Neural Networks. European Symposium on Intelligent Techniques, 1999.
- [2] P. C. M Carvalho. Geração Eólica. Imprensa universitária. Fortaleza, 2003.
- [3] CRESESB. Atlas do potencial eólico brasileiro – 2008.http://www.cresesb.cepel.br/publicacoes/atlas_eolico_brasil/atlas-web.htm. Acessado em 01/11/2008.
- [4] S. V. Dias, P. C. M. Carvalho, G. L. B. Ramalho, M. R. B. Neto, A. P. Moreira. Estimativa da irradiação solar média diária no Município de Fortaleza através de Redes Neurais Artificiais. II Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES. Florianópolis, 2008.
- [5] M. Bilgili, B. Sahin, A. Yasar. Application of artificial neural networks for the wind speed prediction of target station using reference stations data. Renewable Energy 32. pp. 2350–2360. 2007.
- [6] M. C. Mabel, E. Fernandez. Analysis of wind power generation and prediction using ANN: A case study. Renewable Energy 33. pp. 986–992. 2008.
- [7] E. Cadenas, W. Rivera. Short term wind speed forecasting in La Venta, Oaxaca, México, using artificial neural networks. Renewable Energy (disponível on line). pp. 1–5. 2008.
- [8] S. Haykin. Redes neurais – Princípios e Prática. Ed. Bookman. 2ª edição. Porto Alegre, 2001.