

REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE VELOCIDADE DO VENTO: ESTUDO DE CASO PARA MARACANAÚ – CE

TATIANE C. CARNEIRO, HERON A. SANTOS, ARTHUR P. S. BRAGA, PAULO C. M. DE CARVALHO

*Departamento de Engenharia Elétrica, Universidade Federal do Ceará
Caixa Postal 6001, 60.455-760, Fortaleza, CE, Brasil*

*E-mails: tatianecarolyne@oi.com.br, santos.heron@gmail.com,
arthurp@dee.ufc.br, carvalho@dee.ufc.br*

Abstract—This paper presents two methodologies for hourly wind speed forecasting using Artificial Neural Networks (ANN). The estimation considered a wind speed database collected from the town of Maracanaú – CE. Two Neural Networks like FTDNN (Focused Time Delay Neural Network) are considered in this work. A network was trained only with data series of wind speed and other network was trained using as input data, together with data of wind speed, direction information, roughness and the air temperature. Historical data were collected during the period of one year. Performance measures of the system (correlation coefficient - r , mean square error - RMSE and relative bias - VR) were applied. The results generated by the ANN indicate that the applications have a good potential for wind speed forecasting. Based on the performance measures, it was observed that, despite the similar results in both applications, there was an improvement with the inclusion of meteorological parameters, suggesting the applicability of the methodology for predicting wind speed and its use in feasibility studies and wind potential, and its importance in reducing the impacts of variability of wind speed.

Keywords—Artificial neural networks, wind speed, multilayer Perceptron.

Resumo—O presente artigo apresenta duas metodologias para previsão horária da velocidade do vento, usando Redes Neurais Artificiais (RNA) para previsão de séries temporais. A estimação foi feita para dados de velocidade do vento para a cidade de Maracanaú – CE. Utilizou-se duas RNAs do tipo Perceptron com Múltiplas Camadas (MLP) com o auxílio da técnica de Focused Time Delay Neural Network (FTDNN), a qual adiciona características dinâmicas à rede por meio de atrasos no tempo. Uma rede foi treinada apenas com dados da série de velocidade do vento e outra rede foi treinada utilizando, como dados de entrada, além dos dados de velocidade do vento, informações de direção, rugosidade e temperatura do ar. Os dados históricos foram coletados durante o período de um ano. Foram aplicados medidores de desempenho do sistema (coeficiente de correlação - r , erro médio quadrático - RMSE e viés relativo - VR). Os resultados gerados pelas RNAs indicam que as aplicações possuem um bom potencial para previsão de séries temporais de velocidade do vento e, baseados nos medidores de desempenho, foi possível observar que, apesar dos resultados semelhantes nas duas aplicações, houve uma melhoria com o incremento de alguns parâmetros meteorológicos na entrada da rede, sugerindo a aplicabilidade da metodologia na previsão de velocidade do vento e sua utilização em estudos de viabilidade e potencial eólico, tendo sua importância na redução dos impactos da variabilidade da velocidade do vento.

Palavras-chave—Redes neurais artificiais, velocidade do vento, Perceptron com múltiplas camadas.

1 Introdução

O crescimento populacional e o aumento do nível tecnológico dos países nos últimos anos vêm gerando a necessidade de elevar significativamente a oferta de energia para o atendimento a estas crescentes demandas, tanto em termos de qualidade como de quantidade.

A matriz elétrica brasileira é predominantemente composta por fontes renováveis de energia, principalmente a hidrelétrica, complementada por termelétricas em períodos em que os reservatórios hídricos estejam com baixos níveis. Esse tipo de sistema é conhecido como “hidrotérmico”, e é nesse contexto que é possível entender a necessidade de recursos complementares na matriz energética, capazes de substituir essas térmicas, reduzindo a emissão de gases de efeito estufa e os custos com combustíveis nas termelétricas em períodos de reduzidos índices pluviométricos.

Nesse contexto complementar, destaca-se a energia eólica, originada da transformação da energia cinética contida nos movimentos de massas de ar em energia mecânica pelo giro de pás e depois em energia elétrica por meio de geradores. Os movimentos de massas de ar são conhecidos como vento, e estes

sofrem influência da associação entre energia solar e a rotação da terra, variando entre as regiões, ou seja, dependendo da localização no Globo Terrestre (Carvalho, 2003).

A energia eólica traz consigo uma incerteza relacionada à produção final, pois o vento tem características intermitentes, que muitas vezes limita sua aplicação. Diante disso, os sistemas de previsão de velocidade do vento para locais e regiões se tornam importantes, reduzem o impacto dessa incerteza, ajudam a inserir a energia eólica no mercado elétrico e também auxiliam na tomada de decisão no planejamento de outras fontes de energia, como as térmicas (Pereira et al., 2007).

Previsão de séries temporais, como séries de velocidade do vento, aplicadas neste estudo, vem se tornando um desafio da área de Mineração de Dados. Prever valores futuros, em função de valores passados, tem se tornado um assunto de especial interesse na academia e na indústria, com aplicações em planejamento de produção, matriz energética e mercado de ações, dentre outras. Existem diversos métodos para auxiliar na tarefa de previsão de séries temporais, tais como modelos provenientes da estatística, assim como modelos derivados de tecnologias de redes neurais e outras técnicas de inteligência computacio-

nal(Sánchez, 2006, Brito et al., 2006, Hong et al., 2007, Hatzigargyriou et al., 2007, Lobo et al., 2012).

Muitos esforços têm sido devotados para desenvolver bons métodos de previsão de velocidade do vento. As abordagens encontradas na literatura incluem métodos físicos, métodos estatísticos, modelos híbridos (físicos/estatísticos), e métodos baseados em técnicas de inteligência artificial (Costa et al., 2008; Lei et al., 2009; Morales et al., 2010; Fadare, 2010). Nos modelos baseados em Redes Neurais Artificiais, as Redes Neurais do tipo MLP (Multi-Layer Perceptrons) (Linetal., 1996, Alexiadis, 1998), RBF (Radial Basis Function) (Beyer et al., 1994) e Redes Neurais Recorrentes (Kariniotakis et al., 1996, More and Deo, 2003) têm sido usadas para esse fim.

Existem duas diferentes abordagens para aplicação na previsão de velocidade do vento, a abordagem física e a estatística, diferindo-se pelos dados de entrada utilizados nos modelos, além dos modelos híbridos que utilizam a junção das duas abordagens principais. Os modelos físicos, como o próprio nome diz, utilizam dados físicos obtidos no terreno como dados de entrada e dados meteorológicos, e os modelos estatísticos utilizam dados meteorológicos na forma de séries históricas. Modelos Computacionais não convencionais, como as RNA, conseguem encontrar essa relação entre os valores de entrada e saída de modo a se gerarem melhores previsões que os métodos clássicos de regressão linear, entre outros (Giebel, 2003).

As RNA são um ramo da inteligência artificial que surgem para extrair modelos e detectar tendências que são muito complexas para serem percebidas por humanos ou outras técnicas computacionais. Em vez de usar uma abordagem algorítmica, as RNA processam a informação de forma similar ao sistema nervoso biológico. Elas possuem um grande número de elementos fortemente ligados (neurônios) trabalhando em paralelo para resolver um problema específico. Estas ferramentas aprendem através de exemplos selecionados cuidadosamente, tornando-se muito eficazes para solução de sistemas não-lineares, na adaptação a circunstâncias, entre outras vantagens (Haykin, 1999; Farias et al., 2006; Farias, 2009).

Dentre diversos trabalhos que aplicam RNA para previsão de séries de velocidades de vento, este artigo tem como objetivo comprovar, por meio de estudo de caso, a viabilidade da utilização desta técnica em cidade nordestina, a partir de um conjunto de dados limitados (1 ano) e verificar se o desempenho da RNA é melhorado com o uso de mais parâmetros de entrada.

Os tópicos desta artigo estão organizados da seguinte forma: a) na segunda seção é feita uma breve revisão bibliográfica sobre as RNA e especificamente as redes FTDNN (Focused Time Delay Neural Network); b) na terceira seção é descrita a metodologia usada, com apresentação da cidade analisada, descrição da base de dados e especificações das RNA utilizadas; c) na quarta seção são apresentados os resultados obtidos e as discussões; e d) na quinta seção são apresentadas as conclusões do artigo.

2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são sistemas paralelamente distribuídos e constituídos por unidades de processamento capazes de modelar desde problemas simples até os mais complexos. Sua estrutura é distribuída em camadas, que são interligadas por conexões chamadas de pesos sinápticos e onde é armazenado o conhecimento adquirido através de um processo de aprendizagem (Braga et al. 2007).

2.1 Perceptron com Múltiplas Camadas (MLP)

A não-linearidade é inerente à maioria dos problemas e situações reais, e estruturas com características não-lineares são essenciais para a resolução desses problemas (Braga et al. 2007). Essas não-linearidades são incorporadas aos modelos neurais por meio das funções de ativação (não-lineares) de cada neurônio da rede e da composição da sua estrutura em camadas sucessivas. Uma arquitetura de RNA do tipo MLP é apresentada na Figura 1.




Figura 1. Perceptron de múltiplas camadas (MLP).

A rede MLP soluciona problemas linearmente não separáveis e são aproximadoras universais de funções. O algoritmo de treinamento dessa rede é conhecido como “back-propagation”, sendo uma generalização do algoritmo de treinamento “regra delta” da rede Adaline (Rumelhart et al., 1986).

O princípio do *back-propagation* é utilizar o gradiente descendente e estimar o erro nas camadas intermediárias, assim como o efeito que estes erros causam no erro da camada de saída.

O erro da camada de saída é calculado e, na sequência, é retropropagado para as camadas anteriores, permitindo o ajuste dos pesos proporcionais aos valores das conexões entre camadas utilizando as Equações 1 e 2.

$$w_{ij}^m(t+1) = w_{ij}^m(t) - \alpha \cdot \delta_i^m \cdot y_j^{m-1} \quad (1)$$

$$b_{ij}^m(t+1) = b_{ij}^m(t) - \alpha \cdot \delta_i^m \quad (2)$$

Onde $w_{ij}^m(t+1)$ é o peso atualizado, $w_{ij}^m(t)$ é o peso na iteração, α é a taxa de aprendizagem da RNA, δ_i^m é a sensibilidade, y_j^{m-1} é a saída da camada anterior, $b_{ij}^m(t+1)$ é o bias atualizado, $b_{ij}^m(t)$ é o bias na iteração, e o i e j identificam os

neurônios da camada posterior e anterior da conexão, respectivamente.

2.2 Focused Time Delay Neural Network (FTDNN) com MLP

O tempo é um parâmetro importante de várias tarefas onde se busca aproximar funções. O tempo pode ser representado pelo efeito que acarreta no processamento de sinais, o que significa oferecer características dinâmicas ao mapeamento realizado pela rede, tornando-a sensível aos sinais que variem no tempo. Para isso, é necessário introduzir atrasos de tempo (Braga et al., 2007).

Para que as redes MLP (Camadas Múltiplas) realizem o processamento temporal, são usadas janelas de tempo, em que a entrada da rede utiliza trechos dos dados temporais como se eles formassem um padrão estático. Uma arquitetura que consegue lidar com variações temporais são as RNAs com atraso de tempo focada – FTDNN (Focused Time Delay Neural Network), que consiste em uma rede de propagação para frente com atraso de tempo apenas na camada de entrada. É uma rede *feed-forward* multicamadas cujos pesos sinápticos são ajustados de acordo com o algoritmo de retropropagação convencional (Principe et al., 2000).

3 Metodologia

3.1 Área de Estudo e Descrição dos Dados

Os procedimentos e modelos desenvolvidos neste artigo foram realizados no Software MATLAB R2012a e foram aplicados para previsão horária de velocidade do vento em um município do Nordeste Brasileiro. Para a realização deste estudo, foram utilizados dados medidos a cada 10 minutos, obtidos por meio de uma estação anemométrica localizada no município de Maracanaú – CE, 18 km de Fortaleza, considerado o maior centro industrial do estado (IBGE, 2013). A localização geográfica da cidade é apresentada na Figura 2.

Os dados foram obtidos por meio de uma de três estações anemométricas financiadas pelo Projeto “Previsão de potencial eólico visando operação integrada ótima de unidades geradoras de eletricidade: estudo de caso para o Nordeste do Brasil”, financiado pelo CNPq.



Figura 2. Localização do município de Maracanaú – Ceará no Nordeste brasileiro, onde está localizada a torre anemométrica (<http://pt.wikipedia.org/wiki/Maracanaú>).

A estação anemométrica foi instrumentada com conjuntos de medições, constituídos de três anemômetros, do modelo NRG 40c, instalados, a 78, 50 e 20 m de altura, o Equipamento NRG 500P para medição de direção do vento, instalado a 78 m, um sensor de temperatura, da marca NRG 110S e um Piranômetro do modelo NRG LI – 200SA, instalado a 14m. Um sistema de aquisição Data Logger NRG Symphonie-plus, com faixa de medição entre 0 e 96 m/s, que permite o armazenamento de dados de velocidade média, para intervalos de 10 min. Essas médias são calculadas a partir de dados processados a cada 2 s. Algumas características da estação anemométrica estão representadas na Tabela 1.

Tabela 1. Informações referente à torre anemométrica.

Localização/Estação	Período Analisado	Altura (m)	Alturas (m) - Anemômetros
Maracanaú/Fazenda Raposa – Universidade Federal do Ceará	Fev/2012 até Jan/2013	80	78, 50 e 20

Os dados utilizados na pesquisa foram dados históricos de velocidade do vento. Foi utilizado um total de 8.784 valores horários (valores calculados a partir de dados obtidos de 10 em 10 minutos) de Maracanaú.

Na Figura 3 estão representadas as séries de médias horárias, diárias e mensais para a localidade. Analisando os gráficos é possível observar, no que se refere à sazonalidade, que existe uma tendência de melhores velocidades do vento nos períodos de julho à outubro (período com menores índices pluviométricos) no Nordeste brasileiro.




Figura 3. Séries de médias horárias, diárias e mensais em Maracanaú-CE.

Na Tabela 2, são representadas algumas informações estatísticas da série anual analisada.

No que se refere à geração eólica, é importante esse conhecimento, do comportamento horário, diário e mensal das séries e de suas estatísticas, para facilitar a inserção dessa fonte de geração na matriz elétrica, como para facilitar a operação do sistema e o planejamento de outras fontes complementares de energia.

Tabela 2. Dados estatísticos das séries anuais de velocidade do vento.

Dados de velocidade do vento (m/s)	Maracanaú
Mínimo	0,40
Máximo	14,80
Média	5,63
Mediana	5,60
Desvio Padrão	2,26
Variância	5,10
Número de Medições	52686,00

3.2 Modelo Implementado

O modelo de RNA utilizado foi o MLP treinado pelo conhecido algoritmo de retropropagação de erros (*back-propagation*) combinado com a técnica de Focused Time Delay Neural Network (FTDNN). Foram utilizadas duas aplicações responsáveis pela estimação de valores horários de velocidade do vento para o município de Maracanaú-CE, baseadas em dados passados.

Foram desenvolvidas duas diferentes RNA, uma rede onde são utilizados os dados da própria série de velocidade do vento, aplicados a uma rede MLP combinada com FTDNN (MLP_FTDNN_1) e uma outra RNA onde são acrescentados às entradas da rede informações meteorológicas da localidade: a) Direção; b) Temperatura do ar; e c) Rugosidade (medida que representa as irregularidades do terreno) (MLP_FTDNN_2).

3.2.1 Preparação dos Dados

A etapa de preparação dos dados envolve, entre outros aspectos, a forma de aquisição, o pré-processamento, a normalização e a definição dos conjuntos de treino e teste. Os dados foram normalizados utilizando a normalização linear, aplicando a Equação (3) e, deixando os dados entre 0 e 1 para serem aplicados às funções de ativação de forma adequada.

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (3)$$

Onde X_n é o valor normalizado, X_i é o valor observado, X_{min} é o menor valor do conjunto de dados e X_{max} é o maior valor do conjunto de dados.

Com o uso do método da validação cruzada, os dados foram divididos em 5 subconjuntos exclusivos de mesmo tamanho (20%), um desses subconjuntos é usado para teste e os subconjuntos restantes são utilizados para treinamento, esse processo é realizado iterativamente (n vezes) alternando os subconjuntos.

A estratégia utilizada na primeira RNA foi a aplicação de dados de velocidade do vento com três atrasos de tempo (escolha dos atrasos das duas redes foram obtidos por simulação, apresentados na Tabela 3), para prever a velocidade do vento na hora seguinte. A segunda RNA, além dos atrasos de tempo nos dados de velocidade do vento, foram aplicados os dados de direção, rugosidade e temperatura do ar para a previsão da hora seguinte.

Tabela 3. Erros obtidos nas Simulações realizadas para a escolha dos atrasos de tempo.

RNA	SIMULAÇÕES			
	RMSE			
ATRASOS →	1	2	3	4
MLP_FTDNN_1 (Treinamento)	2,95 e-5	1,27 e-5	6,75 e-6	5,19 e-4
MLP_FTDNN_2 (Treinamento)	2,12 e-3	4,45 e-3	5,50 e-6	1,93 e-3
MLP_FTDNN_1 (Teste)	0,0015	0,0016	1,35 e-4	0,0062
MLP_FTDNN_2 (Teste)	0,0048	3,32 e-3	1,32 e-3	4,32 e-3

3.2.2 Definição da Arquitetura das RNA com atrasos de tempo focados

As arquiteturas das RNA com atrasos no tempo são apresentadas nas Figuras 4 e 5. As duas arquiteturas são formadas por uma camada de entrada, uma oculta (ou intermediária) e uma de saída. A topologia da rede neural é do tipo alimentada adiante, ou seja, as conexões acontecem da camada de entrada para camada oculta e de camada oculta para camada de saída.




Figura 4. Arquitetura da MLP_FTDNN_1 responsável pela previsão horária de velocidade do vento em Maracanaú.

A primeira rede possui sua camada inicial composta por quatro entradas, que são as velocidades históricas: a) $V(t-3)$; b) $V(t-2)$; c) $V(t-1)$; e d) $V(t)$. Realizando simulações com diferentes atrasos de tempo (2, 3 e 4), obteve-se os melhores resultados com 3 atrasos de tempo, por isso a escolha de quatro entradas.

A camada de saída é responsável por fornecer o valor predito pela rede neural em função das entradas, como apresenta a Equação 4 ($n=3$).

$$V(t+1) = f(V(t), V(t-1), V(t-2), \dots, V(t-n)) \quad (4)$$




Figura 5. Arquitetura da RNA com atrasos de tempo e incremento de outros parâmetros meteorológicos responsável pela previsão horária de velocidade do vento em Maracanaú.

A segunda rede possui sua camada inicial composta por oito entradas, que são as velocidades históricas: a) $V(t-3)$; b) $V(t-2)$; c) $V(t-1)$; e d) $V(t)$; as informações de direção, temperatura do ar, rugosidade no tempo e uma variável para identificar o mês (janeiro = 1, fevereiro = 2, ..., dezembro = 12), chamadas de $D(t)$, $T(t)$, $R(t)$ e $M(t)$, respectivamente.

Na segunda arquitetura, a camada de saída também é responsável por fornecer o valor predito pela rede neural em função das entradas, como apresenta na Equação 5.

$$V(t+1) = f(V(t), V(t-1), V(t-2), \dots, V(t-n)) \quad (5)$$

$$\dots D(t), T(t), R(t) \text{ e } M(t)$$

O número de neurônios na camada oculta é obtido através do processo de tentativa e erro. Os melhores resultados foram obtidos com 6 neurônios na camada oculta, para a primeira e segunda RNA. A camada de saída é composta por um único neurônio, nas duas aplicações, que é o valor da velocidade na hora seguinte $V(t+1)$. São utilizadas funções de ativação sigmóides para os neurônios da camada oculta e da camada de saída, representadas na Equação 6.

$$\varphi[u(n)] = \frac{1}{1 + e^{-\lambda(u)}} \quad (6)$$

3.2.3 Indicadores de Desempenho

O treinamento da RNA é dividido em duas etapas principais que ocorrem de forma iterativa até que um erro estabelecido seja atingido: a primeira, que é a *forward* (propaga os sinais por toda a rede – da entrada para a saída), etapa onde a saída da rede é gerada e um erro é calculado; finalizada a etapa anterior, é feita a etapa de *backward* (erros são retropropagados da saída para a entrada) (Braga et al. 2007).

Realizado o treinamento, a RNA é testada e os resultados estimados, no treinamento e no teste, são avaliados com o auxílio de seguintes testes estatísticos: a) coeficiente de correlação (r); b) viés relativo (VR); e c) erro médio quadrático (RMSE), definidos nas Equações 7, 8 e 9.

$$r = \frac{\sum_i^N (X_i - X_{med}) \cdot \sum_i^N (Y_i - Y_{med})}{\sqrt{\sum_i^N (X_i - X_{med})^2 \cdot \sum_i^N (Y_i - Y_{med})^2}} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}} \quad (8)$$

$$VR = \frac{X_{med} - Y_{med}}{Y_{med}} \quad (9)$$

Onde X_{med} é o valor médio do conjunto de dados observados, Y_i é o valor previsto, Y_{med} é o valor médio do conjunto de dados previstos e N é o número total de dados previstos.

Para validar os modelos, são aplicados novos dados no período que compreende (Mar/2013 até Jun/2013).

4 Resultados e Discussões

As Figuras 6 e 7 mostram um comparativo entre as velocidades do vento obtidas com o modelo de MLP_FTDNN_1 e os correspondentes valores observados de velocidade do vento, para a localidade analisada. Vale notar que o gráfico da Figura 7 apresenta apenas os resultados para uma janela de cinco dias do período de teste.




Figura 6. Dados previstos e observados obtidos pelo MLP_FTDNN_1 para todo o período de teste.




Figura 7. Dados previstos e observados obtidos pelo MLP_FTDNN_1 para um período de 5 dias.

As Figuras 8 e 9 mostram um comparativo entre as velocidades do vento obtidas com o modelo de MLP_FTDNN_2 e os correspondentes valores observados de velocidade do vento.




Figura 8. Dados previstos e observados obtidos pelo MLP_FTDNN_2 para todo o período de teste.




Figura 9. Dados previstos e observados obtidos pelo MLP_FTDNN_2 para um período de 5 dias.

Os resultados obtidos no sistema de previsão, assim como o seu desempenho, foram avaliados por meio dos índices de correlação (r), viés relativo (VR) e RMSE. Os dados obtidos pelas redes aplicadas e para os períodos de treinamento e teste estão apresentados na Tabela 4 e 5.

Tabela 4. Correlação, viés relativo e RMSE entre as velocidades calculadas e observadas no período de Treinamento.

RNA	TREINAMENTO		
	r	VR	RMSE
MLP_FTDNN_1	0,9133	0,0013	7,6994e-6
MLP_FTDNN_2	0,9396	-2,8730e-4	1,7090e-6

Tabela 5. Correlação, viés relativo e RMSE entre as velocidades calculadas e observadas no período de Teste.

RNA	TESTE		
	r	VR	RMSE
MLP_FTDNN_1	0,9856	-0,0306	0,0010
MLP_FTDNN_2	0,9533	0,0024	0,0014

A correlação mede o grau de dependência linear entre as previsões e os valores observados de velocidade do vento, expressando o potencial de ajuste. O viés relativo, por sua vez, mostra se o sistema de previsão possui uma tendência a subestimar ou superestimar as velocidades observadas. Valores altos de correlação não significam, por si só, previsões com alta precisão.

Por exemplo, um sistema com um viés muito alto, mesmo que possua correlação igual à unidade ($r=1$), fornecerá previsões de velocidade do vento de baixa precisão, embora seja possível remover este viés através de modelos estatísticos. Um sistema perfeito de previsão teria $r = 1$ e $VR = 0$.

Os resultados mostram que as previsões do modelo de MLP_FTDNN_1 aplicado a Maracanaú possuem alta correlação com os valores observados, apresentando valores, no treinamento e teste, superiores a 90%. Os valores de viés relativo no conjunto de teste apresentaram-se bastante razoáveis, tendo em vista que uma das limitações das RNA é atingir os picos de velocidades do vento em virtude do pequeno número de exemplos de treinamento para eventos extremos de velocidade. A tendência é que esta limitação seja reduzida com o futuro aumento no número de dados observados. Os valores do RMSE no treinamento e no teste foram 7.6994e-6e 0.0010, respectivamente, o que indica que as previsões horárias de velocidades do vento possuem boa qualidade.

Os resultados relacionados às previsões realizadas pela rede MLP_FDNN_2 apresentam alta correlação, chegando a obter uma correlação de 93% no treinamento da rede. Os valores de viés relativo no conjunto de teste apresentaram-se bastante razoáveis, tendo uma leve tendência a subestimar os dados. Os valores do RMSE no treinamento e no teste, foram 1.7090e-6e 0.0014, respectivamente.

Observando o comportamento das duas aplicações, conclui-se que, com o incremento de novos parâmetros na entrada da rede, a mesma obteve al-

gumas melhorias nos resultados, sem um aumento significativo na qualidade das previsões. Estudos futuros, que venham a determinar as variáveis de maior relevância na previsão desse tipo de dados e conjuntamente o aumento no período de dados analisados, podem trazer benefícios e melhoria na qualidade e precisão desse tipo de aplicação.

As Figuras 8 e 9 apresentam os gráficos de dispersão dos valores calculados pela duas RNA (MLP_FTDNN_1 e MLP_FTDNN_2) em relação aos valores observados, para o período de teste, em Maracanaú.




Figura 8. Gráfico de dispersão entre os valores calculados e observados pelo MLP_FTDNN_1.




Figura 2. Gráfico de dispersão entre os valores calculados e observados pelo MLP_FTDNN_2.

Os altos valores de correlação combinados com os baixos valores de viés relativo entre as velocidades previstas e observadas para os períodos de treinamento e teste, as duas aplicações mostraram-se confiáveis para esse tipo de aplicação.

A Tabela 6 apresenta os erros obtidos na validação dos modelos, com o auxílio do novo período de dados (Mar/2013 até Jun/2013).

Tabela 6. Correlação, viés relativo e RMSE entre as velocidades calculadas e observadas na validação.

RNA	VALIDAÇÃO		
	r	VR	RMSE
MLP_FTDNN_1	0,9025	0,0033	0,0014
MLP_FTDNN_2	0,9136	0,0016	0,0025

Os bons resultados apresentados na validação mostram que as redes neurais aplicadas apresentam uma boa capacidade em representar a dinâmica do vento na região em análise.

5 Conclusão

Pode-se concluir que a utilização de RNA do tipo FTDNN apresenta bons resultados na aplicação para previsão de velocidade horária do vento baseadas em dados de curto prazo.

Foi possível observar que, utilizando somente os dados de velocidade do vento, o modelo apresentou um bom desempenho, e o incremento de novos parâmetros na entrada da rede não apresentou uma melhoria significativa, tendo as duas aplicações apresentado resultados próximos. As duas redes apresentaram bons resultados na validação realizada dados distintos dos utilizados no treinamento das redes.

A metodologia utilizada pode ser aplicada no estudo de viabilidade e planejamento de instalações e funcionamento de parques eólicos.

Estudos futuros de análise de relevância desses novos parâmetros para aplicações na previsão de velocidade do vento podem trazer melhorias nas aplicações. E juntamente a isso, o uso de outras técnicas de RNA pode contribuir para a realização de previsões de maior precisão.

Agradecimentos

À CAPES, pela concessão de bolsa no Curso de Mestrado em Engenharia Elétrica, ao autor principal deste artigo.

Ao CNPq, pelo financiamento do Projeto “Previsão de potencial eólico visando operação integrada ótima de unidades geradoras de eletricidade: estudo de caso para o Nordeste do Brasil”.

Referências Bibliográficas

- Alexiadis, M. Short-term forecasting of wind speed and related electrical power. *Solar Energy*, 63(1), 61–8, 1998.
- Beyer, H.G., Degner, T., Haussmann, J., Homan, M. and Rujan, P. Short term forecast of wind speed and power output of a wind turbine with neural networks. In: *Proceeding on the 2nd European Congress on Intelligent Techniques and Software Computing*. Aachen, Germany, 1994.
- Braga, A. P.; Carvalho, A. P. de L.; Ludermir, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. 2ª edição, Editora LTC, Rio de Janeiro, 2007.
- Brito, N. S. D.; Souza, B. A.; Melo Filho, A. C. M.; Lima, R. B. V.; Pamplona, F. M. P.: *Aplicação de Redes Neurais Artificiais para Previsão de Carga em Sistemas de Distribuição*. Simpósio Brasileiro de Sistemas Elétricos, Campina Grande – PB, Brasil, 2006.
- Carvalho, P.C.M. *Geração Eólica*. 146p. 1ª edição, Fortaleza – CE, Editora Imprensa Universitária, 2003.
- Costa, A., Crespo, A., Navarro, J., Lizcano, G., Madsen, H. and Feitosa, E. A review on the young history of the wind power short-term predic-

- tion. *Renew Sustain Energy Rev*, 12(6), p. 1725–44, 2008.
- Fadare, D.A. The application of artificial neural networks to mapping of Wind speed profile for energy application in Nigeria. *Appl Energy*, 87(3), p. 934–42, 2010.
- Farias, C. A. S. Derivation of hedging rules and forecasts by artificial neural networks for optimal real-time management of an integrated water resources system. Tese de Doutorado, EhimUniversity, Matsuyama – Japão, p. 127, 2009.
- Farias, C. A. S., A. B. Celeste, Y. Sakata, A. Kado-kaand K. Susuki. Use of Monte Carlo optimization and artificial neural networks for deriving reservoir operating rules, *Annual Journal of Hydraulic Engineering, JSCE*, 50(1), p. 25-30, 2006.
- Giebel, G. The State-Of-The-Art in Short-Term Prediction of Wind Power: A Literature Overview, Risø National Laboratory, Projeto Anemos, 2003.
- Hatziargyriou, N. D.: Sideratos, G.: An Advanced Statistical Method for Wind Power Forecasting, *IEEE Transactions on Power Systems*, 2007.
- Haykin S.: *Neural Networks: a Comprehensive Foundation*, 2 ed., Prentice Hall, Upper Saddle River, USA, 1999.
- Hong, J.; Wu, Y.: A literature review of wind forecasting technology in the world, *IEEE Power Tech*, 2007.
- <http://pt.wikipedia.org/wiki/Maracanau>, Acessado em 12 de Janeiro de 2014.
- Instituto Brasileiro de Geografia e Estatística – IBGE, <http://www.ibge.gov.br/>, Acessado em 12 de Janeiro de 2014.
- Kariniotakis, G., Stavrakakis, G.S. and Nogaret, E.F. Wind power forecasting using advanced neural network models. *IEEE Trans Energy Convers*, 11(4): p. 762–7, 1996.
- Lei, M., Shiyan, L., Chuanwen, J., Hongling, L. and Yan, Z. A review on the forecasting of wind speed and generated power. *Renew Sustain Energy Rev*, 13(4), p. 915–20, 2009.
- Lin, L., Eriksson, J.T., Vihriala, H. and Soderlund, L. Predicting wind behavior with neural networks. In: *Proceeding the 1996 European Wind Energy Conference*. Goteborg, Sweden, p. 655–8, 1996.
- Lobo, M. G.; Sánchez, I: Regional Wind Power Forecasting Based on Smoothing Techniques, With Application to the Spanish Peninsular System, *IEEE Transactions on Power Systems*, 2012.
- Morales, J.M., Mínguez, R. and Conejo, A.J (2010). A methodology to generate statistically dependent wind speed scenarios. *Appl Energy*, 87(3), p. 843–55, 2010.
- More, A. and Deo, M.C. Forecasting wind with neural networks. *Mar Struct*, 16(1), p. 35–49, 2003.
- Pereira, E. B.; Guarniere, R, A.; Martins, F. R. O Aproveitamento da Energia Eólica, *Revista Brasileira de Ensino de Física*, v. 30, n. 1, 2007.
- Principe, J.C., Euliano, N.R., Lefebvre, W.C. *Neural Adaptive Systems: Fundamentals Through Simulations*. John Willey and Sons, 2000.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J Learning representations by backpropagating errors. *Nature* 323, p. 533-536, 1986.
- Sánchez, I.: Short-term prediction of wind energy production, *International Journal of Forecasting* 22, 2006.