

PREVISÃO DA VELOCIDADE DO VENTO A CURTO PRAZO USANDO REDES NEURAIS ARTIFICIAIS EM MUCURI, BAHIA.

Pedro Junior Zucatelli, pedrojrzucatelli@gmail.com¹
Erick Giovani Sperandio Nascimento, ericksperandio@gmail.com²
Georgynio Yossimar Rosales Aylas, ragy3008@gmail.com²
Noéle Bissoli Perini de Souza, noleperini@gmail.com¹
Yasmin Kaore Lago Kitagawa, ykaore@gmail.com¹
Alex Álisson Bandeira Santos, alex.santos@fieb.org.br²
Davidson Martins Moreira, davidson.moreira@gmail.com²

¹Universidade Federal do Espírito Santo, Av. Fernando Ferrari, 514, Goiabeiras, 29075-910, Vitória, ES, Brasil.

²Centro Integrado de Manufatura e Tecnologia SENAI CIMATEC, Av. Orlando Gomes, 1845, Piatã, 41650-010, Salvador, BA, Brasil.

Resumo: Entremado em um contexto de expansão da utilização da energia eólica no Brasil, o emprego da Inteligência Computacional, por intermédio das Redes Neurais Artificiais (RNA), para previsão da velocidade do vento é justificável pela sua conhecida capacidade de reconhecimento de padrões e ajuste funcional, e por proporcionar bons resultados em problemas que apresentem elevado grau de não linearidade. Contemplando este tema, este trabalho teve como objetivo treinar, validar e testar 7 arquiteturas de RNA (tipo Multilayer Perceptron com algoritmo de treinamento Feed-forward Backpropagation), via software MATLAB, a fim de definir qual seria a mais eficiente em realizar a previsão da velocidade do vento em 1 hora utilizando como referência dados observacionais coletados a uma altura de 151 metros em torre anemométrica situada na cidade de Mucuri, Bahia, nordeste do Brasil, referentes ao período compreendido entre 30 de novembro de 2015 às 14h até 31 de dezembro de 2015 às 13h. Dentre todas as 7 configurações analisadas, a Rede Neural Artificial com 4 camadas e 15 neurônios (sendo 9 nós na camada de entrada, 9 neurônios na primeira camada escondida, 6 neurônios na segunda camada escondida, e 1 nó na camada de saída) foi a que se destacou quanto ao cálculo dos dados estatísticos MAE (0,77821), MSE (0,99975), Erro mínimo (0,00396), Erro máximo (3,05602), Coeficiente de correlação de Pearson r (0,93546) e Coeficiente de regressão R^2 (0,99474). Este trabalho contribui para a tomada de decisão do Operador Nacional do Sistema Elétrico (ONS) em uma usina ou parque eólico afim de evitar prejuízos financeiros e técnicos, além de coadjuvar na análise da viabilidade técnica e econômica de implantação destes empreendimentos no Brasil e, em especial, na Bahia.

Palavras-chave: Inteligência Computacional, Redes Neurais Artificiais, Energia Eólica, Previsão da velocidade do vento.

1. INTRODUÇÃO

Dado o aumento da utilização das fontes de energias alternativas, em especial a fonte eólica no Brasil, sabe-se que para o Operador Nacional do Sistema Elétrico (ONS) que é o órgão brasileiro responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN) e pelo planejamento da operação dos sistemas isolados do país, sob a fiscalização e regulação da Agência Nacional de Energia Elétrica (Aneel), a variabilidade da direção e velocidade do vento ao longo do dia dificulta a tomada de decisão quanto ao acionamento (ou não) das usinas eólicas, isto porque, na prática, verifica-se que o recurso eólico apresenta variações temporais em várias ordens de grandeza: variações anuais (em função de alterações climáticas), variações sazonais (em função das diferentes estações do ano), variações diárias (devido o microclima local), variações horárias (brisas terrestres e marítimas) e variações de curta duração (rajadas). A variação espacial da energia eólica também é muito grande. Topografia e rugosidade do solo também têm grande influência na distribuição da frequência de ocorrência dos ventos e de sua velocidade em um local. Entende-se que prejuízos econômicos ocorrem caso as turbinas eólicas sejam submetidas a condições de tempo desfavoráveis. Portanto, faz-se necessário o desenvolvimento de ferramentas confiáveis para prever o campo de vento, mesmo que em curto prazo.

A principal motivação deste artigo está na relevância da discussão deste tema em um cenário que envolve o setor acadêmico-científico assim como o setor tecnológico-industrial. Sabe-se que para estimar com confiabilidade a energia

produzida por uma máquina eólica é necessário conhecer, além das características da máquina que será utilizada (curva de potência *versus* velocidade do vento), a distribuição estatística da velocidade do vento no local onde ela será instalada. Tais dados de vento, normalmente, só são obtidos por meio de levantamentos específicos do potencial eólico efetuado no próprio local de interesse.

A modelagem atmosférica e a previsão do vento aplicada ao setor energético possuem dois enfoques principais: a estimativa dos ventos médios levando em conta dados climatológicos e a previsão de vento para tempos futuros em curtos e médios prazos. O primeiro enfoque tem como finalidade a seleção de locais que apresentam melhores condições de vento para geração de energia eólica a fim de prover os dados necessários para avaliar a viabilidade econômica e estabelecer os parâmetros a serem adotados no desenvolvimento de unidades geradoras e fazendas eólicas. Quanto às estimativas de curto prazo, estas são particularmente úteis na identificação de períodos de maior ocorrência de vento, bem como a ocorrência de ventos que possam prejudicar o sistema. Já a previsão de vento em médio prazo é útil no gerenciamento dos recursos de energia elétrica, visando suprir as deficiências na oferta de geração eólica por energia elétrica proveniente de outras fontes (OLIVEIRA, 2013).

Os resultados deste trabalho contribuem diretamente para analisar a previsibilidade da velocidade do vento em Mucuri – BA, Brasil, por intermédio de um modelo de Inteligência Computacional conhecido por Redes Neurais Artificiais – RNA, pois o desenvolvimento bem-sucedido desta metodologia pode melhorar, consideravelmente, as perspectivas de atingir futuras metas do desenvolvimento de novos parques eólicos no estado da Bahia e, por consequência, em todas as regiões do Brasil propícias para estes investimentos. Na literatura, autores como Cadenas (2009), Nogay *et al.* (2012), Abhishek *et al.* (2012), Chang (2013), Dalto *et al.* (2014), Quadros (2015), Vieira *et al.* (2016) e Wasilewska *et al.* (2017) destacam seus estudos e resultados de modelagem e simulação para previsão a curto prazo com técnicas de Inteligência Computacional, em especial utilizando as Redes Neurais Artificiais (redes do tipo *Multilayer Perceptron* com algoritmo de treinamento *Feed-forward Backpropagation*), todos com bons resultados alcançados e baixos erros associados, o que incide confiança nesta metodologia computacional.

Inserido neste contexto, este artigo teve como objetivo treinar, validar e testar sete arquiteturas de RNA (via *software* MATLAB), todas do tipo *Multilayer Perceptron* com algoritmo de treinamento *Feed-forward Backpropagation*, a fim de definir qual seria a mais eficiente para prever a velocidade do vento em 1 hora por meio dos dados anemométricos da cidade de Mucuri, Bahia, nordeste do Brasil, referentes ao período compreendido entre 30 de novembro de 2015 às 14h até 31 de dezembro de 2015 às 13h. A metodologia científica e os procedimentos computacionais utilizados neste estudo são descritos a seguir.

2. PROCEDIMENTO COMPUTACIONAL


Neste trabalho, através da seleção de um caso de estudo, foi adotado a Inteligência Computacional utilizando Redes Neurais Artificiais do tipo *Multilayer Perceptron* com algoritmo de treinamento *Feed-forward Backpropagation* para a previsão da velocidade do vento em curto prazo (1 hora) em Mucuri – BA. De acordo com More e Deo (2003), Pessanha *et al.* (2010), Chang (2013), Quadros (2015) e Vieira *et al.* (2016), este tipo de rede é a mais usual, principalmente com 3 camadas. Pessanha *et al.* (2010), Lima (2015) e Cervone *et al.* (2017) descreve que o algoritmo supracitado é o principal algoritmo para o treinamento das redes. Cervone *et al.* (2017) informa ainda que as RNA são implementadas por meio de camadas com nós interconectados. Para tal autor, a definição do número de camadas é muito variável e depende das características de cada problema; as RNA requerem, no mínimo, três camadas, sendo uma camada de entrada, uma camada escondida e uma camada de saída, sendo que os neurônios estão presentes nas camadas escondidas.

Justifica-se a escolha da cidade de Mucuri porque o estado da Bahia está consolidando a posição de maior polo brasileiro de investimentos em energia eólica, bem como vem se tornando uma referência internacional nesta área. Inúmeros investimentos têm sido feitos por novas empresas, gerando oportunidades de emprego e renda para a população, inclusive com impacto positivo em regiões carentes. Uma nova cadeia produtiva, focada em energia eólica, foi implantada no Estado com bastante êxito e continua em expansão, dinamizando a economia como um todo, conforme a referência literária de Santos e Torres (2014).

O *software* utilizado para a programação e realização deste procedimento computacional foi o MATLAB versão 7.10.0 2010, juntamente com a interface gráfica *NNTool* (*Neural Network Toolbox*). Por intermédio da Tabela 1 (RNA com 3 camadas) e da Tabela 2 (RNA com 4 camadas) pode-se observar as informações de cada configuração analisada neste artigo, isto com relação às arquiteturas das Redes Neurais Artificiais (quantidade de nós da camada de entrada e da camada de saída, além da quantidade de neurônios da camada escondida).

Tabela 1. Arquiteturas das Redes Neurais Artificiais com 3 camadas.


<i>Redes Neurais Artificiais com 3 camadas</i>			
<i>Configuração</i>	<i>Camada de entrada</i>	<i>1 camada escondida</i>	<i>Camada de saída</i>
1	9 nós	9 neurônios	1 nó
2	9 nós	6 neurônios	1 nó
3	9 nós	3 neurônios	1 nó
4	9 nós	1 neurônio	1 nó



A seguir, tem-se a Tabela 2 com as configurações de RNA com 4 camadas.

Tabela 2. Arquiteturas das Redes Neurais Artificiais com 4 camadas.

<i>Redes Neurais Artificiais com 4 camadas</i>			
<i>Configuração</i>	<i>Camada de entrada</i>	<i>2 camadas escondidas</i>	<i>Camada de saída</i>
5	9 nós	9 e 6 neurônios	1 nó
6	9 nós	6 e 3 neurônios	1 nó
7	9 nós	1 e 1 neurônio	1 nó



As informações dos dados anemométricos aplicados neste estudo seguem abaixo:

Local do estudo: Mucuri, Bahia, nordeste do Brasil.

Altura de medição na torre: 151 m (velocidade), 148 m (direção).

Tipo da rede: *Multilayer Perceptron*.

Tipo do algoritmo da rede: *Feed-forward Backpropagation*.

Input: dia, mês, ano, hora, velocidade média horária do vento, direção média horária do vento, temperatura média horária, umidade média horária e pressão média horária.

Target: próxima velocidade média horária do vento (os *targets* foram preparados para a previsão em 1 hora).

Período de referência do estudo: 30/11/2015 às 14h até 31/12/2015 às 13h.

Quantidade total de dados do estudo: $744 \times 9 = 6696$ (100%).

Período de referência do treinamento, validação e teste: 30/11/2015 às 14h até 23/12/2015 às 11h.

Quantidade de dados para treinamento, validação e teste: $550 \times 9 = 4950$ (73,92%).

Período de referência da previsão: 23/12/2015 às 12h até 31/12/2015 às 13h.

Quantidade de dados para previsão: $194 \times 9 = 1746$ (26,08%).

Cada Rede Neural Artificial apresentada nas Tabelas 1 e 2, por meio das configurações 1 a 7, foi treinada, validada e testada para verificar-se qual seria a mais eficiente e então poder-se fazer a previsão da velocidade do vento em curto prazo (1 hora). As funções de ativação que definem as saídas dos neurônios em termos do nível de atividade do mesmo, neste artigo, foram as funções tangente hiperbólica (caracterizada como contínua, crescente, diferenciável e não-linear) para as camadas escondidas e a função linear para a camada de saída. A presença de não-linearidade na função de ativação da camada oculta é importante porque, do contrário, a relação de entrada-saída da rede poderia ser reduzida

àquela de um *perceptron* de camada única, já o uso da função linear na camada de saída é devido a necessidade de se obter uma saída linear, ou seja, aos moldes dos dados de entrada e assim se evitar problemas de ajustes de função.

O tratamento estatístico empregado resulta em valores de *Mean Absolute Error* – *MAE* (Erro Absoluto Médio), *Mean Squared Error* – *MSE* (Erro Quadrático Médio), ver Equações 1 a 3, os quais Cadenas (2009) destaca que tais valores são importantes para a tomada de decisão quanto à determinação da melhor arquitetura da Rede Neural Artificial, além disso, são descritos o Erro Mínimo, Erro Máximo, o Coeficiente de Regressão R^2 e Coeficiente de correlação de *Pearson* r (Equações 4 e 5, respectivamente). Para estes indicadores estatísticos são adequados valores próximos de 0,0 (zero) para os erros *MAE* e *MSE*, e valores próximos de 1,0 (um) para os coeficientes R^2 e r .

$$e_t = y_t - F_t \quad (1)$$

Em que:

e_t é o erro no período de tempo t ;

y_t é a atual observação no período de tempo t ;

F_t é a previsão no período de tempo t .

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (2)$$

Em que:

MSE é o Erro Quadrático Médio;

n é o número de períodos de tempo.

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (3)$$

Em que:

MAE é o Erro Absoluto Médio;

n é o número de períodos de tempo.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Em que:

R^2 é o Coeficiente de regressão.

y_i é o valor observado.

$\bar{y}$ é a média das observações.

$\hat{y}_i$ é o valor estimado (previsão) de y_i .

n é a quantidade de dados.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5)$$

Em que:

r é o Coeficiente de correlação de *Pearson*.

x_i são os dados da matriz 1.

y_i são os dados da matriz 2.

$\bar{x}$ é a média dos dados da matriz 1.

$\bar{y}$ é a média dos dados da matriz 2.

n é a quantidade de dados.

Observa-se, por intermédio da Figura 1, a série temporal usada neste estudo que consiste em 744 horas acumuladas no total, correspondendo à média horária da velocidade do vento para o período de 30 de novembro de 2015, 14h até 31 de dezembro de 2015, 13h. Tem-se que os dados são randômicos e se torna difícil para encontrar a tendência desta série temporal. Nesta mesma figura é registrada a média da velocidade média do vento para este período por meio da curva pontilhada.




Figura 1. Série temporal da velocidade média horária.

As medidas estatísticas correspondentes ao período de 30 de novembro de 2015, 14h até 31 de dezembro de 2015, 13h, podem ser visualizadas na Tabela 3, onde há o número de dados, média aritmética e desvio padrão da velocidade, além da velocidade máxima e mínima.

Tabela 3. Medidas estatísticas correspondentes ao período de estudo.

Número de dados de velocidade	Média (m/s)	Desvio padrão (m/s)	Velocidade máxima (m/s)	Velocidade Mínima (m/s)
744	8,38	2,75	15,15	1,18

Os resultados alcançados e as discussões sobre os mesmos são apresentados no próximo tópico.

3. RESULTADOS E DISCUSSÕES

Cada arquitetura das Redes Neurais Artificiais representadas pelas configurações definidas e expostas nas Tabelas 1 e 2 foi treinada, validada e testada. Por intermédio das Tabelas 4 e 5, os resultados da progressão e da regressão desta fase, referente às configurações 1 a 7, podem ser observados. Na Tabela 4 estão destacados os menores valores do erro MSE.

Tabela 4. Resultados do treinamento, validação e teste das Redes Neurais Artificiais: Progressão.

Configuração	Épocas (iterações)	Performance (MSE)	Gradiente	Taxa de aprendizado	Melhor performance de validação (MSE)
1	12	0,947	0,224	1,00	1,3803
2	15	1,070	0,165	0,01	1,0487
3	21	1,140	0,144	1,00	1,3710
4	30	1,190	9,08e-8	1,00e+10	1,3470
5	16	0,944	0,792	10,0	1,4130
6	11	0,940	0,356	1,00	1,6817
7	16	2,080	0,234	0,01	1,6297

Na Tabela 5 estão destacados os maiores valores do coeficiente R.

Tabela 5. Resultados do treinamento, validação e teste das Redes Neurais Artificiais: Regressão, coeficiente R .

<i>Configuração</i>	<i>R: treinamento</i>	<i>R: validação</i>	<i>R: teste</i>	<i>R: geral</i>
1	0,94058	0,91304	0,89503	0,92519
2	0,93733	0,91563	0,89919	0,92488
3	0,92376	0,89835	0,90667	0,91612
4	0,91225	0,91471	0,88231	0,90686
5	0,94873	0,90521	0,90983	0,93275
6	0,95381	0,83399	0,89525	0,91779
7	0,84713	0,88710	0,83330	0,85178

A seguir, utilizando as arquiteturas de redes das configurações 1 a 7, foram realizadas as previsões para a velocidade do vento em 1 hora e os resultados de *MAE*, *MSE*, Erro mínimo, Erro máximo, Coeficiente de regressão R^2 e Coeficiente de correlação de *Pearson* r estão registrados na Tabela 6. Nesta tabela, estão destacados os menores valores para *MAE*, *MSE*, Erro máximo e Erro mínimo, além dos maiores valores dos coeficientes r e R^2 .

Tabela 6. Resultados da simulação – Previsão em 1 hora da velocidade do vento.

<i>Configuração</i>	<i>MAE</i>	<i>MSE</i>	<i>Erro mínimo</i>	<i>Erro máximo</i>	<i>Coeficiente: r</i>	<i>Coeficiente: R^2</i>
1	1,17742	2,28810	0,00246	4,62454	0,89366	0,86569
2	0,82298	1,12070	0,00207	3,09391	0,92605	0,71201
3	0,81166	0,97046	0,00484	3,31052	0,93516	0,73599
4	0,87627	1,16324	0,01534	3,21958	0,91868	0,75507
5	0,77821	0,99975	0,00396	3,05602	0,93546	0,99474
6	0,93676	1,35837	0,00018	3,24759	0,92481	0,74939
7	0,87088	1,15505	0,02822	3,00533	0,91954	0,74148

Por intermédio da Tabela 6, observa-se que a melhor arquitetura da RNA para previsão em curto prazo (1 hora) seria a configuração 5 (RNA com 4 camadas e 15 neurônios, sendo 9 nós na camada de entrada, 9 neurônios na 1ª camada escondida, 6 neurônios na 2ª camada escondida e 1 nó na camada de saída) por apresentar o conjunto de dados estatísticos *MAE* (0,77821), *MSE* (0,99975), Erro mínimo (0,00396), Erro máximo (3,05602), Coeficiente de correlação de *Pearson* r (0,93546) e Coeficiente de regressão R^2 (0,99474). Uma representação esquemática desta RNA pode ser visualizada na Figura 2.




Figura 2. RNA representativa com 4 camadas e 15 neurônios.

Na Figura 3 observa-se a série temporal prevista em 1 hora por meio da configuração 5 comparada com os dados anemométricos.




Figura 3. Previsão em 1 hora utilizando a configuração 5.

Tem-se que dentre todas as configurações apresentadas, a mais adequada para a previsão em 1 hora com os dados anemométricos medidos a 151 m de altura em Mucuri – BA é a configuração 5 por apresentar o melhor resultado estatístico, como supracitado. Dentre as 4 configurações com 3 camadas, a mais eficiente é a configuração 3 que é a RNA com uma camada de entrada com 9 nós, uma camada escondida com 3 neurônios e uma camada de saída com 1 nó.

4. CONCLUSÃO

O estudo de mecanismos que auxiliam na previsão a curto prazo da velocidade do vento, tal como foi realizada neste trabalho em 1 hora, para a geração de energia em parques eólicos, tem se mostrado crítico para assegurar o correto funcionamento dos sistemas de energia tradicionais. De fato, com a crescente inserção de fontes de energias alternativas na matriz energética brasileira, em especial a energia eólica, a definição de estratégias que visam antecipar, com relativa confiabilidade, potenciais episódios de intermitência na geração de energia – que ocorrem em grande parte devido à natureza estocástica do vento – previne esses sistemas de eventuais prejuízos relacionados ao desbalanceamento entre a oferta e a demanda de energia, proporcionando assim maior segurança e estabilidade para todos os agentes. Por meio da metodologia de Inteligência Computacional fez-se o uso de RNA para prever a velocidade do vento e dentre todas as configurações analisadas, a Rede Neural Artificial com 4 camadas e 15 neurônios (sendo 9 nós na camada de entrada, 9 neurônios na primeira camada escondida, 6 neurônios na segunda camada escondida, e 1 nó na camada de saída) foi a que se destacou quanto ao cálculo dos dados estatísticos MAE (0,77821), MSE (0,99975), Erro mínimo (0,00396), Erro máximo (3,05602), Coeficiente de correlação de Pearson r (0,93546) e Coeficiente de regressão R^2 (0,99474). Por meio dos resultados alcançados, percebeu-se a importância de analisar várias arquiteturas das redes neurais antes de aplicá-las para a previsão, mesmo que em curto prazo, da velocidade do vento. Sugere-se, como trabalhos futuros, realizar a previsão da velocidade do vento em Mucuri – BA para 3, 6 e 12 horas por meio de dados anemométricos coletados a 100, 120 e 151 metros utilizando a metodologia de Inteligência Computacional, o que é interessante para a tomada de decisão do Operador Nacional do Sistema Elétrico (ONS) em uma usina ou parque eólico afim de evitar prejuízos financeiros e técnicos, além de contribuir para a análise da viabilidade técnica e econômica de implantação destes empreendimentos no Brasil e, em especial, na Bahia.

5. AGRADECIMENTOS

Os autores agradecem à Universidade Federal do Espírito Santo – UFES, em especial ao Programa de Pós-Graduação em Engenharia Ambiental, Doutorado em Engenharia Ambiental, Campus Integrado de Manufatura e Tecnologia, SENAI CIMATEC e FAPESB.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ABHISHEK, K. *et al.* (2012). Weather forecasting model using Artificial Neural Network. Kumar Abhishek, M.P. Singh, Saswata Ghosh, Abhishek Anand. *Procedia Technology* 4 (2012) 311 – 318. Published by Elsevier Ltd. doi: 10.1016/j.protcy.2012.05.047
- CADENAS, E. (2009). Short term wind speed forecasting in La Venta, Oaxaca, Mexico, using artificial neural networks, Erasmo Cadenas, 2009.
- CERVONE, G. *et al.* (2017). Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble. G. Cervone *et al.* *Renewable Energy* 108 (2017) 274e286. <http://dx.doi.org/10.1016/j.renene.2017.02.052>. 0960-1481. Published by Elsevier Ltd.
- CHANG, W.Y. (2013). Application of Backpropagation Neural Network for Wind Power Generation Forecasting. *International Journal of Digital Content Technology and its Application*, 7, 502-509.
- DALTO, M., Vasak, M., Baotic, M. (2014). Neural network based ultra-short term wind forecasting. Mladen Dalto, Mario Vašak, Mato Baotic. (2014). https://bib.irb.hr/datoteka/692827.EWEA_ultra_short.pdf
- LIMA, F.J.L. (2015). Previsão de irradiação solar no Nordeste do Brasil empregando o modelo WRF ajustado por redes neurais artificiais (RNAs) / Francisco José Lopes de Lima. – São José dos Campos : INPE, 2015. 628p.
- MORE, A. e Deo, M. C. (2003). Forecasting wind with neural networks. *Marine Structures*. Volume 16, Issue 1, January–February 2003, Pages 35–49. Anurag More, M. C. Deo. 2003. [https://doi.org/10.1016/S0951-8339\(02\)00053-9](https://doi.org/10.1016/S0951-8339(02)00053-9)
- NOGAY, H. S.; Akinci, Tahir Cetin; Eidukeviciute, Marija. (2012). Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey. *J. energy South. Afr.*, Cape Town, v. 23, n. 4, p. 2-7, 2012. http://www.scielo.org.za/scielo.php?script=sci_arttext&pid=S1021-447X2012000500001&lng=en&nrm=iso
- OLIVEIRA, S.S. (2013). Análise do potencial eólico do estado da Paraíba utilizando modelos de mesoescala. Tese de doutorado. Soetânia Santos de Oliveira. – Campina Grande, 2013.
- PESSANHA *et al.* (2010). Previsão da velocidade do vento com sistema de inferência neuro-fuzzy adaptativo. ISSN 2175-6295 Rio de Janeiro - Brasil, 12 e 13 de agosto de 2010.
- QUADROS, L.C. (2015). Emprego de redes neurais artificiais na correção de concentrações simuladas pelo modelo de qualidade do ar MODELAR. Lis Campos de Quadros. Curitiba, 2015.

VIEIRA, R.G.; Zuben, F.J.V.; Ballini, R. (2016). Previsão de Curto Prazo para a Geração de Energia Eólica usando um Modelo Ensemble de Maquinas de Aprendizado. Rafael Giordano Vieira, Fernando Jose Von Zuben e Rosangela Ballini. SBC ENIAC-2016, Recife - PE, p. 349.

WASILEWSKIA, J., *et al.* (2017). Short-term electric energy production forecasting at wind power plants in pareto-optimality context. J. Wasilewska, D. Baczynskib. 2017. <https://doi.org/10.1016/j.rser.2016.11.026>

7. RESPONSABILIDADE AUTURAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

SHORT TERM WIND SPEED FORECASTING USING ARTIFICIAL NEURAL NETWORKS IN MUCURI, BAHIA.

Pedro Junior Zucatelli, pedrojrzucatelli@gmail.com¹

Erick Giovani Sperandio Nascimento, ericksperandio@gmail.com²

Georgynio Yossimar Rosales Aylas, ragy3008@gmail.com²

Noéle Bissoli Perini de Souza, noeleperini@gmail.com¹

Yasmin Kaore Lago Kitagawa, ykaore@gmail.com¹

Alex Álisson Bandeira Santos, alex.santos@fieb.org.br²

Davidson Martins Moreira, davidson.moreira@gmail.com²

¹Federal University of Espírito Santo, Av. Fernando Ferrari, 514, Goiabeiras, 29075-910, Vitória, ES, Brazil.

²Manufacturing and Technology Integrated Campus SENAI CIMATEC, Av. Orlando Gomes, 1845, Piatã, 41650-010, Salvador, BA, Brazil.

Abstract. *Inserted in a context of expansion of wind energy use in Brazil, the use of Computational Intelligence, through Artificial Neural Networks (ANN), to predict the wind speed is justified by its known ability to recognize patterns and functional adjustment, and to provide good results in problems that present a high degree of non-linearity. Considering this theme, this work aimed to train, validate and test seven ANN architectures (type Multilayer Perceptron with Feed-forward Backpropagation training algorithm), through MATLAB software, in order to define which would be the most efficient to perform the prediction of the wind speed in 1 hour using as reference observational data collected at a height of 151 meters in anemometric tower located in Mucuri city, Bahia, northeastern Brazil, for the period from November 30, 2015 at 2:00 p.m. until December 31, 2015 at 1:00 p.m.. Of all the seven configurations analyzed, the Artificial Neural Network with 4 layers and 15 neurons (9 nodes in the input layer, 9 neurons in the first hidden layer, 6 neurons in the second hidden layer, and 1 node in the output layer) was the one that stood out for the calculation of the statistical data MAE (0.77821), MSE (0.99975), Minimum error (0.00396), Maximum error (3.05602), Pearson correlation coefficient r (0.93546) and R-square regression coefficient (0.99474). This work contributes to the decision of the National Electric System Operator (ONS) in a wind farm to avoid financial and technical losses, as well as assist in the analysis of the technical and economic feasibility of implementing these projects in Brazil and, in especially in Bahia.*

Keywords: *Computational Intelligence, Artificial Neural Networks, Wind Energy, Forecasting wind speed.*