



## Análise do Potencial de Previsão da Velocidade do Vento Utilizando Rede Neural Artificial Wind Speed Forecast Potential Analysis Using Artificial Neural Network

Iwldson Guilherme da Silva Santos<sup>1</sup> & Roberto Fernando da Fonseca Lyra<sup>2</sup>

<sup>1</sup> Universidade Federal de Alagoas, Instituto de Ciências Atmosféricas, Programa de Pós-graduação em Meteorologia, Avenida Lourival de Melo Mota s/n, Tabuleiro do Martins, 57072-970, Maceió, AL, Brasil

<sup>2</sup> Universidade Federal de Alagoas, Instituto de Ciências Atmosféricas, Avenida Lourival de Melo Mota s/n, Tabuleiro do Martins, 57072-970, Maceió, AL, Brasil

E-mails: iwldson@gmail.com; roberto.ufal@gmail.com

Recebido em: 20/09/2019 Aprovado em: 16/04/2020

DOI: [http://dx.doi.org/10.11137/2020\\_4\\_11\\_17](http://dx.doi.org/10.11137/2020_4_11_17)

### Resumo

O objetivo deste trabalho é avaliar o potencial de previsibilidade da velocidade do vento com antecedência de 24 horas, usando a técnica de Rede Neural Artificial (RNA) Não Linear Auto Regressiva (NAR). Os dados observados de velocidade do vento (OBS) são médias de 10 minutos, obtidos por meio de anemômetro instalado a 50 metros de altura em uma Torre anemométrica situada no Município de Craíbas, região Agreste de Alagoas. A técnica de RNA-NAR foi treinada e calibrada com os dados observacionais fornecendo as condições iniciais. Após a calibração, a técnica foi aplicada na previsão da velocidade do vento para o dia seguinte. Os resultados mostraram que o prognóstico RNA-NAR representou bem a evolução temporal diária do vento no período estudado (abril de 2015). A análise estatística das séries de dados observados e previstos indica que a velocidade média do vento foi de ordem de 5,26 m.s-1 e 5,24 m.s-1, a velocidade máxima foi de 12,29 m.s-1 e 13,92 m.s-1, e a velocidade mínima foi de 0,01 m.s-1 e 0,36 m.s-1, respectivamente. As métricas estatísticas indicam desvio médio quase nulo (cerca de -0,01 m.s-1), raiz do erro quadrático médio de 1,14 m.s-1, erro percentual absoluto médio de 22% e coeficiente de correlação de 0,71. Esses resultados, apesar de considerar um período curto de dados indica o potencial de aplicação da RNA-NAR na previsão de 24 h da velocidade do vento em 50 m.

**Palavras-chave:** *Variável Meteorológica; Energia Eólica; Inteligência Artificial*

### Abstract

The objective of this work is to evaluate the potential predictability of the wind speed 24 hours in advance, using the Artificial Neural Network (ANN) nonlinear autoregressive (NAR). The observed wind speed (OBS) data are 10 minutes averages, obtained by means of an anemometer installed at 50 meters height in an anemometric tower located in the town of Craíbas, in the Agreste region of Alagoas, Brazil. The ANN-NAR technique was trained and calibrated with the observational data providing the initial conditions. After calibration, the technique was applied to forecast the wind speed for the next day. The results showed that the ANN-NAR prognosis well represented the daily temporal evolution of the wind speed in the studied period (April 2015). The statistical analysis of the observed and predicted data series indicated that the average wind speed was 5.26 m.s-1 and 5.24 m.s-1, the maximum speed was 12.29 m.s-1 and 13.92 m.s-1, and the minimum speed was 0.01 m.s-1 and 0.36 m.s-1, respectively. Statistical metrics indicate an almost zero mean deviation (about -0.01 m.s-1), root mean square error of 1.14 m.s-1, mean absolute percentage error of 22%, and correlation coefficient of 0.71. Despite the short period of data, these results indicate the potential application of ANN-NAR in the 24 h forecast 50 m wind speed.

**Keywords:** *Meteorological Variable; Wind Energy; Artificial Intelligence*

## 1 Introdução

O vento é uma variável meteorológica cujo conhecimento de suas características, tais como intensidade, direção e perfil vertical, são fundamentais no planejamento de diversas atividades humanas, como por exemplo, construção civil, arquitetura, agricultura, transporte (aéreo e marítimo), assim como na regulação das condições climáticas locais e dispersão de poluentes de grandes cidades. A velocidade e direção do vento são variáveis meteorológicas e essenciais na caracterização do clima e microclima de uma determinada região (Lyra *et al.*, 1998). Atualmente, existe uma necessidade de informações para entender e quantificar o regime e persistência da velocidade do vento, especialmente em áreas costeiras e planaltos interioranos, que ajudem a dimensionar o potencial de geração de energia eólica dessas áreas.

A energia eólica é a transformação da energia cinética dos ventos em energia útil, como na utilização de aerogeradores para produzir eletricidade, moinhos de vento para produzir energia mecânica ou velas para impulsionar veleiros. É uma energia que está permanentemente disponível, não libera substâncias poluentes para o meio ambiente durante a produção de energia elétrica e o impacto ambiental é menos problemático do que outras fontes de energia como a hidrelétrica (Fthenakis & Kim, 2009).

De acordo com GWEC (Global Wind Energy Council) cerca de 51,3 GW (Gigawatt) de energia eólica foram incorporados a matriz energética mundial em 2018, elevando o potencial instalado de produção de energia eólica para 591 GW. Os cinco países que mais se destacaram no ranking e capacidade eólica nova *onshore* (energia eólica no continente) instalada em 2019, foram China, EUA, Alemanha, Índia e Brasil, nesta ordem (GWEC, 2019).

No Brasil a capacidade total instalada de produção de energia eólica é da ordem de 15,1 GW, distribuída em 601 parques eólicos e mais de 7.000 aerogeradores em 12 Estados, segundo a Associação Brasileira de Energia Eólica (ABEEólica). Os Estados da região Nordeste despontam como maiores produtores de energia eólica, destacando-se o Rio Grande do Norte, com 151 parques e cerca de 4 GW de capacidade instalada em seu território. Em seguida, está a Bahia, com 153 parques eólicos e 3,9 GW de potência instalada. O Ceará vem em terceiro lugar com 79 parques eólicos e uma capacidade instalada de 2 GW (ABEEólica, 2019).

Alagoas é o único Estado do Nordeste que ainda não possui parque eólico. Com base no Atlas Eólico do Estado de Alagoas, o Estado tem potencial de produzir pelo menos 2/3 da energia elétrica que demanda (ELETROBRAS, 2008). A produção de energia eólica é dependente das condições meteorológicas e, portanto, de informações que permitam avaliar e quantificar a produção de energia real,

atual e futura. A base de informações atuais é a rede de estações meteorológicas de superfície e as previsões dos modelos de mesoescala disponíveis operacionalmente. Contudo, tais modelos ainda apresentam resoluções espaciais de ordem de 5 km em escala nacional, e necessitam de calibração e validação, portanto, ainda limitados na captura da variabilidade do relevo e interação atmosférica em escala regional.

O desenvolvimento e o melhoramento de técnicas e modelos para previsão de ventos em pequena escala espacial e de curto prazo, é de extrema importância no que diz respeito à prospecção, produção e distribuição de energia eólica.

Os métodos de previsão da velocidade do vento de curto prazo envolvem diversos tipos de técnicas, como o uso de modelos atmosféricos de mesoescala (Ramos *et al.*, 2013; Silva *et al.*, 2018), métodos baseados em inteligência artificial e estatística (Rodrigues, 2007; Cadenas & Rivera, 2009; Gonçalves, 2011). A combinação de qualquer dois ou mais métodos de previsão do vento são denominados de modelos híbridos (Moura, 2014; Camelo *et al.*, 2018).

Diante do exposto, o objetivo deste trabalho é avaliar o potencial e previsibilidade da velocidade do vento com antecedência de 24 horas, usando a técnica de Rede Neural Artificial (RNA) Não Linear Auto Regressiva (NAR).

## 2 Material e Métodos

### 2.1 Dados

Os dados utilizados foram cedidos pelo Projeto Previsão do Vento em Parques Eólicos no Nordeste do Brasil (PVPN), e obtidos pelos anemômetros instalados em uma Torre situada no Município de Craíbas região Agreste de Alagoas, cujas coordenadas geográficas são: 9°37'04" S e 36°46'03" W, a uma altitude de 258 metros.

As medições da velocidade, direção e rajadas do vento foram obtidas a 50, 70 e 100 metros de altura, com taxa de aquisição de 15 segundos, e cálculo de médias a cada 10 minutos, cujos valores foram registrados em *datalogger* CR1000 (Campbell Scientific Inc. - EUA). Os dados utilizados nas análises foram de velocidade do vento medida a 50 m de altura para o mês de abril de 2015.

### 2.2 Rede Neural Artificial

As RNAs-NAR são redes Recorrentes ou Realimentadas, também conhecidas como redes de Hopfield. Tais redes são arquiteturas neurais que possuem laços de realimentação, ou seja, os valores de saída de uma camada neural podem realimentar a camada de entrada. Seu funcionamento inicial é parecido com as redes do tipo Feedforward, onde sua informação segue sempre na direção

da camada de saída, porém a camada de saída realimenta a entrada. Essa rede também é caracterizada pela variável  $Z$  que é o atraso temporal, também conhecido como delay. O atraso da rede serve como uma memória que proporciona valores de entrada atuais e valores anteriores a eles (Haykin, 2008; Silva *et al.*, 2010).

Dentre as várias arquiteturas de RNA a escolhida para este trabalho foi a NAR, pois é uma rede bastante utilizada para previsão de séries temporais já que consegue descrever comportamentos dinâmicos (sistemas variantes em relação ao tempo), identificação de sistemas, possibilidade de armazenamento de informações e capacidade de memorizar relacionamentos.

### 2.3 Treinamento, Calibração e Verificação da Previsão RNA-NAR

Neste experimento computacional, considerou-se a série temporal das médias de 10 minutos da velocidade do vento (m.s-1), determinadas para o nível de 50 metros de altura, o que totalizou 144 valores por dia.

A série de dados observados é extraída e convertida para o Workspace do software computacional MATLAB® (versão R2013a) para iniciar o processo de treinamento, calibração e validação da RNA-NAR. Esses dados são os sinais de entrada e também são os dados de alvo. Conseqüentemente, os dados observados funcionam como

input/target ao mesmo tempo. A RNA-NAR faz a previsão da velocidade do vento tomando como base apenas a série de dados observados e a configuração dos parâmetros utilizados teve como referência os trabalhos de Gonçalves (2011), Moura (2014) e Santos (2019).

A Tabela 1 mostra os parâmetros utilizados na fase de treinamento da RNA-NAR.

A RNA-NAR é construída para fornecer previsão um passo à frente, neste caso a previsão será para o dia seguinte. Os três últimos dias de março (29, 30 e 31) são valores OBS iniciais utilizados para treinar, calibrar e validar a RNA que após esta fase extrapola a previsão da velocidade do vento para o dia seguinte (01 de abril de 2015). Novamente, utiliza-se três dias (30, 31 e 01) na fase de treinamento da RNA para depois gerar a previsão para o dia posterior (02 de abril de 2015). E assim por diante até utilizar os dias (27, 28 e 29 de abril) na fase de treino da RNA e na seqüência produzir a previsão para o dia consecutivo (30 de abril de 2015).

A Tabela 2, resume os parâmetros utilizados na fase de previsão da RNA-NAR.

Ao final, a série de dados observada (OBS) e a série prevista (RNA) são comparadas por meio dos índices estatísticos do coeficiente de correlação de Pearson ( $r$  – Equação 1), desvio médio (DM – Equação 2), raiz do erro quadrático médio (REQM – Equação 3) e erro percentual absoluto médio (EPAM – Equação 4), determinados de acordo com as equações a seguir.

PARÂMETROS	DADOS/VALORES
SÉRIE DE ENTRADA/ALVO	OBS
NÚMERO DE DADOS NA CAMADA DE ENTRADA	432
NÚMERO DE PREVISÃO	144
ÉPOCAS	1000
ALGORITMO DE TREINAMENTO	LEVENBERG-MARQUARDT (LM)
ALGORITMO DE DESEMPENHO	ERRO MÉDIO QUADRADO
VERIFICAÇÃO	10
GRADIENTE	0,00001
TREINAMENTO	70% (302 valores)
TESTE	15% (65 valores)
VALIDAÇÃO	15% (65 valores)
CAMADA ESCONDIDA	1
ATRASO DE ENTRADA	1:2
NEURÔNIOS NA CAMADA ESCONDIDA	26
FUNÇÃO DE ATIVAÇÃO	TANGENTE HIPERBÓLICA ( <i>Tansig</i> )
CAMADA DE SAÍDA	1
FUNÇÃO DE ATIVAÇÃO	LINEAR ( <i>Purelin</i> )
NEURÔNIOS NA CAMADA DE SAÍDA	1

Tabela 1 Parâmetros utilizados na fase de treinamento da RNA-NAR.

PARÂMETROS	DADOS/VALORES
y(t)	OBS
CAMADA ESCONDIDA	1
ATRASO DE ENTRADA	0:1
NEURÔNIOS NA CAMADA ESCONDIDA	26
FUNÇÃO DE ATIVAÇÃO	TANGENTE HIPERBÓLICA ( <i>Tansig</i> )
CAMADA DE SAÍDA	1
FUNÇÃO DE ATIVAÇÃO	LINEAR ( <i>Purelin</i> )
NEURÔNIOS NA CAMADA DE SAÍDA	1
W	PESOS SINÁPTICOS
b	LIMIAR DE ATIVAÇÃO
y(t+1)	PREVISÃO DE OBS PARA O DIA SEGUINTE

Tabela 2 Parâmetros utilizados na fase de previsão da RNA-NAR.

Os três dias 29, 30 e 31 de março dos dados observados são utilizados unicamente para treinamento da RNA e não entram na fase de análise estatística. Assim como os dados observados a série de dados prevista pela RNA também é feita com frequência de 10 minutos. Como são utilizados 30 dias na análise estatística, consequentemente a amplitude da amostra (N) equivale a 4.320 dados da velocidade do vento para OBS e RNA. O índice (i) varia de 1 a N;  $RNA_i$  e  $OBS_i$  são os valores previstos e observados com seus respectivos índices;  $\overline{RNA}$  e  $\overline{OBS}$  são os valores previstos e observados médios.

$$r = \frac{\sum_{i=1}^N (RNA_i - \overline{RNA}) \cdot (OBS_i - \overline{OBS})}{\sqrt{\sum_{i=1}^N (RNA_i - \overline{RNA})^2} \cdot \sqrt{\sum_{i=1}^N (OBS_i - \overline{OBS})^2}} \quad (1)$$

$$DM = \frac{1}{N} \cdot \sum_{i=1}^N (RNA_i - OBS_i) \quad (2)$$

$$REQM = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (RNA_i - OBS_i)^2} \quad (3)$$

$$EPAM = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{RNA_i - OBS_i}{OBS_i} \right| \cdot 100 \quad (4)$$

### 3 Resultados e Discussão

Nesta seção são apresentados e discutidos os resultados da previsão da velocidade do vento no mês de abril de 2015 usando a técnica de RNA-NAR.

A Figura 1 mostra a série temporal da velocidade do vento observada (preto) e prevista (vermelho) no período

estudado. Verifica-se que a série prevista RNA reproduz o padrão diário de variabilidade da velocidade do vento, e também captura com certa similaridade a magnitude das velocidades máximas e mínimas diárias da velocidade do vento. No entanto, em alguns casos ocorreram diferenças acima da média entre os valores previstos e observados, como nos dias 03, 08, 09, 12, 13, 20, 26 e 30.

Quando OBS apresenta uma variabilidade diária diferente dos dias anteriores RNA não consegue representar bem esta mudança de comportamento do vento. Deste modo, a RNA transporta as características dos dias usados para treinamento para o dia seguinte e desses três dias o terceiro é o que exerce mais peso na acurácia da previsão. Assim, se o dia que vai ser previsto for muito diferente dos três dias anteriores, principalmente do último dia, então a previsão não será precisa. Isso também explica o fato da discordância entre previsão e observação ser consecutiva.

A velocidade média mensal foi de 5,24 m.s<sup>-1</sup> para a série RNA e de 5,26 m.s<sup>-1</sup> para a série OBS. O máximo da série OBS foi de 12,29 m.s<sup>-1</sup> no dia 27 às 19:30 e mínimo foi de 0,01 m.s<sup>-1</sup> no dia 04 às 08:00. O máximo da série RNA foi de 13,92 m.s<sup>-1</sup> no dia 12 às 17:40 e o mínimo foi de 0,36 m.s<sup>-1</sup> no dia 05 às 08:00. Em todos os casos, a velocidade mínima ocorreu no período da manhã e a máxima é no fim da tarde ou começo da noite.

A Figura 2 mostra a série temporal dos desvios entre os dados previstos e observados. A série apresenta forte variabilidade na escala diurna e diária. O maior desvio positivo foi de 7,12 m.s<sup>-1</sup> no dia 06 às 18:30. O maior desvio negativo foi de -7,71 m.s<sup>-1</sup> no dia 08 às 18:00. O desvio médio mensal foi de apenas -0,01 m.s<sup>-1</sup>.

Os maiores desvios ocorreram entre 05-06h e 18-19h nos dias 06, 07 e 08, e estão associadas às mudanças bruscas na velocidade do vento na transição do período diurno e noturno e vice-versa. A forte variabilidade da

velocidade do vento nos três dias que antecedem a previsão reduziu o desempenho da técnica RNA sistematicamente nesses períodos.

A Figura 3 mostra a distribuição de frequência relativa dos desvios entre as velocidades do vento previstas (RNA) e observadas (OBS). Os intervalos de classe da distribuição de frequência foram baseados nos valores arredondados dos desvios de forma que cada classe representa uma janela de 1,0 m.s-1 com variação de 0,5 m.s-1. Por exemplo, a classe 0 vai de -0,5 m.s-1 a +0,5 m.s-1.

A distribuição resultante é uni modal e simétrica. A maior frequência relativa do desvio RNA ocorre na classe 0 (24%). Mais da metade da frequência dos desvios foram distribuídos nas classes -1 a +1 somando 61% dos casos. As classes de maiores desvios (maiores que 3 m.s-1) representaram cerca de 17% da amostra.

A Tabela 3 apresenta a estatística univariada (médias, máximos e mínimos), a estatística bivariada (DM, REQM, EPAM e r), e compara os resultados obtidos com alguns trabalhos que aplicaram RNA na velocidade do vento no Agreste de Alagoas (CR – Craíbas e GP – Girau do Ponciano), no Nordeste Brasileiro (BA – Bahia e RN – Rio Grande do Norte) e outro país (EUA – Estados Unidos da América). As unidades de medidas são dadas em m.s-1, apenas DPAM é porcentagem e r é adimensional.

Os resultados dos prognósticos RNA mostram as métricas estatísticas equiparáveis aos encontrados na literatura. Entretanto, as particularidades de cada trabalho devem ser consideradas uma vez que vários fatores influenciam os resultados, como o tamanho das séries temporais de velocidade do vento, frequência de aquisição dos dados (segundos, minutos ou hora), resolução temporal, método de modelagem, altura da torre anemométrica e avaliação das métricas estatísticas empregadas (Gonçalves, 2011).

Os valores do DM dos trabalhos analisados estão variando entre -0,32 m.s-1 e 0,15 m.s-1 enquanto neste estudo foi de -0,01 m.s-1. Os valores de REQM obtidos em trabalhos analisados estão entre 0,65 m.s-1 e 1,41 m.s-1 enquanto neste estudo foi de 1,14 m.s-1. O EPAM deste estudo foi de 22%, ficando dentro do intervalo dos trabalhos analisados (15,30% a 33,10%). Já as correlações dos trabalhos analisados variaram entre 0,68 e 0,89 e neste estudo foi de 0,71.

Gonçalves (2011) desenvolveu um modelo de refinamento estatístico para previsão da velocidade do vento usando a técnica de RNA alimentada por saídas do modelo de previsão do tempo ETA. As correlações obtidas pelo pesquisador estão entre 0,75 e 0,90 e a REQM varia entre 0,93 m.s-1 e 1,39 m.s-1.




Figura 1 Série temporal da velocidade do vento (m.s-1) sendo observada (preto) e prevista (vermelho) no período de 01 a 30 de abril de 2015.




Figura 2 Série temporal de desvios (m.s-1) entre RNA e OBS no período estudado.

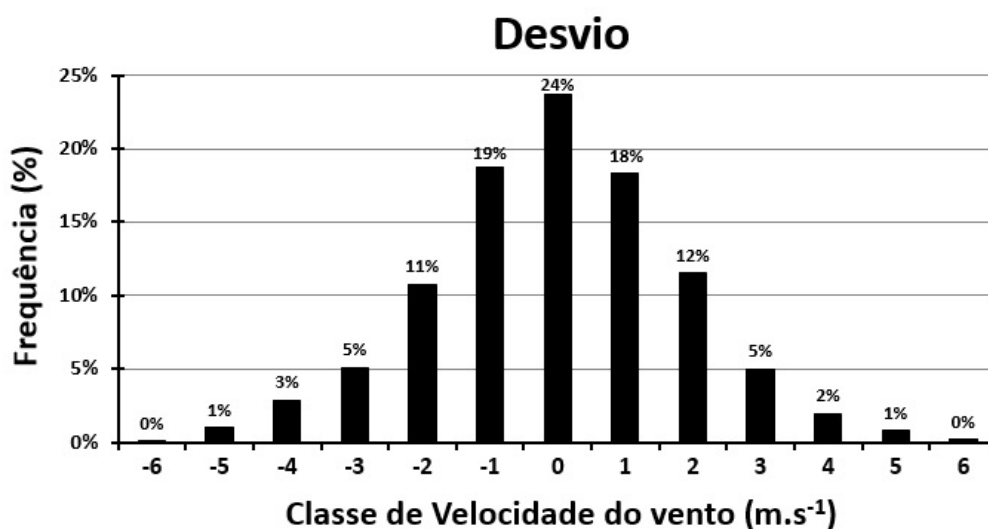


Figura 3 Distribuição de frequência relativa (%) dos desvios (m.s-1) entre as velocidades do vento prevista (RNA) e observada (OBS).

	OBS Médio	RNA Médio	OBS Máx e Mín	RNA Máx e Mín	DM	REQM	EPAM	r
Santos & Lyra (2020) – CR	5,26	5,24	12,29 e 0,01	13,92 e 0,36	-0,01	1,14	22	0,71
Gonçalves (2011) – GP	–	–	–	–	0,15	1,33	–	0,87
Cao <i>et al.</i> (2012) – EUA	23,08	–	32,62 e 12,38	–	–	–	33,10	0,68
Moura (2014) – GP	7,25	7,30	15,34	11,00	0,05	–	–	0,71
Silva <i>et al.</i> (2017) – GP	6,31	5,99	12,65 e 2,16	8,18 e 3,62	-0,32	1,41	–	0,86
Camelo et al (2018) – RN	–	–	–	–	–	0,96	15,30	–
Zucatteli et al. (2018) – BA	8,38	–	15,15 e 1,18	–	–	1,18	–	0,89
Santos (2019) – CR	5,30	5,32	7,2 e 3,0	7,2 e 3,1	-0,02	1,18	–	0,70

Tabela 3 Levantamento estatístico descritivo e comparação de resultados.

Cao *et al.* (2012) apresentaram uma análise comparativa da previsão da velocidade do vento através dos modelos ARIMA (Autoregressive Integrated Moving Average) e RNA recorrente, encontrando que a precisão do modelo RNA foi superior ao modelo ARIMA.

Moura (2014) refinou as saídas do modelo WRF (Weather Research and Forecasting) da velocidade do vento através da técnica RNA. Seus resultados mostraram que os dados refinados apresentaram uma melhora significativa quando comparados aos dados observados.

Silva *et al.* (2017) implementaram um modelo físico-estatístico para avaliar a velocidade do vento. Seus resultados sugerem que o modelo foi mais eficiente com os dados WRF refinados via RNA, com aumento da correlação de 0,36 para 0,89 e redução da REQM de 5,89 m.s-1 para 1,29 m.s-1.

Camelo *et al.* (2018) propuseram um modelo híbrido de previsão da velocidade do vento, elaborado a partir

da combinação do modelo ARIMAX (Autoregressive Integrated Moving Average with external input) e RNA.

Zucatteli *et al.* (2018) compararam diferentes arquiteturas de RNA para definir qual seria a mais eficiente em realizar a previsão da velocidade do vento. Seus melhores resultados são referentes a rede neural com 4 camadas e 15 neurônios.

Santos (2019) utilizou dados observados e dados simulados pelo modelo WRF para previsões da velocidade do vento através da técnica RNA. O levantamento estatístico mostrou erros menores produzidos pela série RNA. Os resultados da RNA foram melhores que os resultados do WRF quando comparados com OBS.

Na Tabela 3, vale salientar que o valor do desvio médio (-0,01 m.s-1) deste estudo entre os prognósticos RNA e OBS, foi inferior a margem de erro dos anemômetros (0,2 m.s-1). Apesar da pequena diferença média entre os dados, o coeficiente de correlação (r) foi mediano. Esse

fato ocorre pelo caráter intermitente da velocidade do vento, variabilidade diária, oscilações bruscas do vento de um dia para o outro. Isso dificulta a previsão de RNA e diminui a correlação com OBS. Portanto, as métricas estatísticas (DM, REQM, EPAM e r) utilizadas neste estudo corresponderam aos resultados dos trabalhos similares analisados, com destaque para o menor desvio médio encontrado, consolidando um bom resultado.

## 4 Conclusão

Este estudo teve como objetivo avaliar o potencial de previsibilidade da velocidade do vento com antecedência de 24 horas, usando a técnica RNA-NAR.

Ficou evidente que o período escolhido para o treinamento (3 dias) implica em desvios grandes quando existe muita variabilidade na série OBS. A previsão carrega características dos dias usados para treinamento e desses três dias o terceiro é o que exerce mais peso na precisão da previsão, ou seja, se o dia que vai ser previsto for muito distinto dos três dias anteriores, principalmente do último dia, então a previsão não será precisa.

Por fim, o uso de RNA-NAR, se mostrou uma ótima opção para previsões da velocidade do vento. Nota-se que não houve velocidade negativa, a maior frequência relativa dos desvios entre OBS e RNA ocorreu na classe 0 (24%) e mais da metade desta frequência estão distribuídos entre as classes -1 a +1. Ademais todos os valores das métricas estatísticas utilizadas corresponderam aos resultados de trabalhos similares analisados.

Este estudo analisou apenas um mês de dados porque é voltado para aplicações em geração de energia eólica e o planejamento das operações dos sistemas de energia foca principalmente na previsão de curto prazo, com horizonte de 1 até 3 dias a frente.

## 5 Referências

ABEEólica. 2019. Associação Brasileira de Energia Eólica. Disponível em: <<http://abeeolica.org.br/>>. Acesso em: 12 jul. 2019.

Cadenas, E. & Rivera, W. 2009. Short term wind speed forecasting in La Venta, Oaxaca, México, using artificial neural networks. *Renewable Energy*, 34:274-278.

Camelo, H.N.; Lucio, P.S.; Junior, J.B.V.L. & Carvalho, P.C.M. 2018. Proposta para previsão de velocidade do vento através modelagem híbrida elaborada a partir dos modelos ARIMAX e RNA. *Revista Brasileira de Meteorologia*, 33 (1):115 – 129.

Cao, Q.; Ewing, B.T. & Thompson, M.A. 2012. Forecasting wind speed with recurrent neural networks. *European Journal of Operational Research*, 221:148 – 154.

ELETOBRAS. 2008. Atlas Eólico do Estado de Alagoas. Disponível em: <[http://www.cresesb.cepel.br/publicacoes/download/atlas\\_eolico/atlas\\_eolico\\_A\\_L.pdf](http://www.cresesb.cepel.br/publicacoes/download/atlas_eolico/atlas_eolico_A_L.pdf)>. Acesso em: 12 jul. 2019.

Fthenakis, V. & Kim, H.C. 2009. Land use and electricity generation: A life cycle analysis. *Renewable and Sustainable Energy Reviews*, 13:1465-1474.

Gonçalves, A.R. 2011. Refinamento estatístico das previsões de vento do modelo ETA aplicado ao setor eólico-elétrico do Nordeste Brasileiro. Programa de Pós- graduação em Meteorologia, Instituto Nacional de Pesquisas Espaciais, Dissertação de Mestrado, 180p.

GWEC. 2019. Global Wind Energy Council. Disponível em: <<https://bit.ly/2FKCath>>. Acesso em: 12 jul. 2019.

Haykin, S. 2008. *Redes Neurais Princípios e Prática*. 2ª ed. Porto Alegre: Bookman, 900p.

Lyra, R.F.F.; Silva Junior, R.S.; Moura, M.A.L. & Amorim, M.C.A.L. 1998. Prognóstico da velocidade do vento utilizando o modelo WRF na região central de Alagoas. *Ciência e Natura*, 38:447-451.

Moura, J.D.O. 2014. Refinamento das simulações de vento do modelo WRF utilizando Redes Neurais Artificiais. Graduação em Meteorologia, Universidade Federal de Alagoas, Trabalho de Conclusão de Curso, 43p.

Ramos, D.N.S.; Lyra, R.F.F. & Junior, R.S.S. 2013. Previsão do vento utilizando o modelo atmosférico WRF para o estado de Alagoas. *Revista Brasileira de Meteorologia*, 28(2):163-172.

Rodrigues, G.C. 2007. Utilização de redes neurais para previsão de ventos no horizonte de 24 horas. Programa de Pós-Graduação em Ciência em Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Dissertação de Mestrado, 119p.

Santos, I.G.S. 2019. Previsão da velocidade do vento na escala do parque eólico utilizando o modelo WRF e rede neural artificial. Programa de Pós-Graduação em Meteorologia, Universidade Federal de Alagoas, Dissertação de Mestrado, 75p.

Silva, I.N.; Spatti, D.H. & Flauzino, R.A. 2010. *Redes Neurais Artificiais para engenharias e ciências aplicadas*. São Paulo, Artliber, 399p.

Silva, S.S.; Lyra, R.F.F.; Junior, R.S.S.; Silva, S.M.S. & Cruz, N.S.D. 2017. Refinamento das estimativas da velocidade do vento feitas pelo modelo WRF usando redes neurais artificiais e modelo físico-estatístico. *X Workshop Brasileiro de Micrometeorologia*, Santa Maria – RS, 5p.

Silva, S.M.S.; Lyra, R.F.F.; Junior, R.S.S.; Cruz, N.S.D. & Silva, S.S. 2018. Avaliação do desempenho do modelo WRF para prognóstico do vento na região central de Alagoas – Craibas. *Ciência e Natura*, Edição Especial: *X Workshop Brasileiro de Micrometeorologia*, 40:187 – 192.

Zucattelli, P.J.; Nascimento, E.G.S.; Aylas, G.Y.R.; Souza, N.B.P.; Kitagawa, Y.K.L.; Santos, A.A.B. & Moreira, D.M. 2018. Previsão da velocidade do vento a curto prazo usando redes neurais artificiais em Mucuri, Bahia. *X Congresso Nacional de Engenharia Mecânica*, Salvador – Bahia, 10p.