


Artigo

## Comparativo de Prognósticos da Velocidade do Vento Utilizando Modelo WRF e Rede Neural Artificial

Iwldson Guilherme da Silva Santos<sup>1</sup> , Roberto Fernando da Fonseca Lyra<sup>2</sup>,  
Rosiberto Salustiano da Silva Júnior<sup>2</sup>

<sup>1</sup>*Instituto de Ciências Atmosféricas, Universidade Federal de Alagoas,  
Programa de Pós-Graduação em Meteorologia, Maceió, AL, Brasil.*

<sup>2</sup>*Instituto de Ciências Atmosféricas, Universidade Federal de Alagoas, Maceió, AL, Brasil.*

Recebido em: 5 de Julho de 2020 - Aceito em: 22 de Dezembro de 2020

### Resumo

O objetivo deste trabalho é melhorar a previsão da velocidade do vento usando o modelo atmosférico de mesoescala *Weather Research and Forecasting* (WRF) e Rede Neural Artificial (RNA) não linear auto regressiva com entrada externa (NARX), sem entrada externa (NAR). A acurácia dos prognósticos foi aferida com dados observados (OBS) mensurados a cada 10 min, em uma torre anemométrica de 50 m de altura, localizada em Craíbas região Agreste de Alagoas. A estatística univariada indicou que os prognósticos representaram bem a evolução temporal do vento no período estudado (abril de 2015). As velocidades médias, máximas e mínimas de OBS foram de  $5,26 \text{ m.s}^{-1}$ ,  $12,29 \text{ m.s}^{-1}$  e  $0,01 \text{ m.s}^{-1}$ , nesta mesma sequência, os prognósticos variaram entre ( $5,18 \text{ m.s}^{-1}$  a  $5,41 \text{ m.s}^{-1}$ ), ( $11,58 \text{ m.s}^{-1}$  a  $13,92 \text{ m.s}^{-1}$ ) e ( $0,01 \text{ m.s}^{-1}$  a  $0,36 \text{ m.s}^{-1}$ ). Na análise bivariada as métricas estatísticas utilizadas para averiguar a acurácia das previsões resultaram no seguinte: Desvio médio ( $-0,31$  a  $0,04 \text{ m.s}^{-1}$ ); Raiz do desvio quadrático médio ( $1,14$  a  $1,27 \text{ m.s}^{-1}$ ); Desvio percentual absoluto médio (22 a 23%); E coeficiente de correlação (0,63 a 0,72). Esses resultados, apesar de considerar um período curto de dados, indicam o potencial de aplicação da RNA e WRF na previsão da velocidade do vento.

**Palavras-chave:** variável meteorológica, modelagem numérica, inteligência artificial.

## Wind Speed Forecast Comparison Using WRF Model and Artificial Neural Network

### Abstract

The aim of this work is to improve wind speed forecasting, using the atmospheric mesoscale model *Weather Research and Forecasting* (WRF) and Artificial Neural Network (ANN) nonlinear auto regressive (with external input - NARX and without external input - NAR). The accuracy of the predictions was measured with observed data (OBS) measured every 10 min in an anemometric tower 50 m high, located in Craíbas (dry region of Alagoas State). The univariate statistics indicated that the forecasting represented well the wind temporal evolution in the studied period (April 2015). The average, maximum and minimum OBS speeds were  $5.26 \text{ m.s}^{-1}$ ,  $12.29 \text{ m.s}^{-1}$  and  $0.01 \text{ m.s}^{-1}$ . Predictions ranged from  $5.18 \text{ m.s}^{-1}$  to  $5.41 \text{ m.s}^{-1}$  for the average,  $11.58 \text{ m.s}^{-1}$  to  $13.92 \text{ m.s}^{-1}$  for the maximum and  $0.01 \text{ m.s}^{-1}$  to  $0.36 \text{ m.s}^{-1}$  for the minimum. On the bivariate analysis, the statistical metrics used resulted in the following: Mean Error (ME) from  $-0.31 \text{ m.s}^{-1}$  to  $0.04 \text{ m.s}^{-1}$ ; The root mean square error (RMSE) from  $1.14 \text{ m.s}^{-1}$  to  $1.27 \text{ m.s}^{-1}$ ; Mean Absolute Percentage Error (MAPE) from 22 to 23%; Correlation coefficient from 0.63 to 0.72. These results, despite considering a short period of data, indicate the potential for applying ANN and WRF in forecasting wind speed.

**Keywords:** meteorological variable, numerical modeling, artificial intelligence.

## 1. Introdução

De acordo com a *World Wind Energy Association* (WWEA) a capacidade mundial de energia eólica acumulada em 2019 atingiu 597 GW (Gigawatt), sendo que 50,1 GW foram adicionados em 2018. Todas as turbinas eólicas acrescentadas neste ano podem cobrir quase 6% da demanda global de eletricidade. O líder mundial em produção é a China com capacidade nova instalada de 21 GW e capacidade acumulada de 217 GW. O segundo maior produtor são os Estados Unidos da América (EUA) com capacidade nova instalada de 7,6 GW atingindo 96 GW do total acumulado. Em terceiro lugar está a Alemanha com 3,1 GW de capacidade nova instalada e 59 GW do total acumulado (WWEA, 2019).

O Brasil possui padrão de ventos com alta intensidade, considerado um dos melhores no mundo para a produção de energia eólica e o fator de capacidade médio anual é de 40%, sendo que em meses de safra dos ventos, que vai de junho a novembro, registra-se fatores que passam dos 70% enquanto que a média mundial é de apenas 25%. A Associação Brasileira de Energia Eólica (ABEEólica) informa que, ao final de 2019, o Brasil atingiu 15,3 GW de capacidade instalada acumulada em mais de 600 parques eólicos e 7500 aerogeradores em operação distribuídos em 12 estados, sendo 8 da região Nordeste (Abeeólica, 2019).

O Nordeste Brasileiro (NEB) possui a maior capacidade eólica instalada acumulada, maior quantidade de parques eólicos instalados, consequentemente lidera a geração e o consumo de energia eólica. Alagoas é o único Estado desta região que ainda não possui parque eólico, mas não por falta de vento. Com base no Atlas Eólico de Alagoas (AEA), o Estado tem potencial para produção de energia eólica (ELETROBRAS, 2008). Vários estudos recentes indicam que o Agreste alagoano é uma ótima opção para a construção de parques eólicos (Silva, 2011; Costa e Lyra, 2012; Ramos *et al.*, 2013; Lyra *et al.*, 2016; Cruz *et al.*, 2017; Jatobá *et al.*, 2017; Silva, 2018).

A previsão do vento é dividida em quatro categorias segundo Fazelpour *et al.* (2016). A de curtíssimo prazo compreende um período de tempo de alguns segundos a 30 min. A de curto prazo vai de 30 min a 48 h. Já a de médio prazo vai de 48 h a uma semana. Finalmente, a previsão de longo prazo vai de 1 semana a 1 ano ou mais.

O prognóstico da velocidade do vento envolve diversos tipos de técnicas. Segundo Nazir *et al.* (2020), podemos dividir em 3 grupos: a) método de persistência; b) previsão numérica com destaque para modelos meteorológicos de mesoescala, o método de dinâmica computacional de fluidos (*Computational Fluid Dynamics* - CFD) e as Redes Neurais Artificiais (RNA); c) Métodos Híbridos. Maldonado-Correa *et al.* (2020), fizeram um estudo de revisão dos métodos e constataram que RNAs são utilizadas com maior frequência para a previsão do vento/

energia eólica. Entre os mais recentes podemos citar: Fazelpour *et al.*, 2016; Tesfay *et al.*, 2016; Huang *et al.*, 2018; Zucatelli *et al.*, 2019; Nazir *et al.*, 2020; Sewdien *et al.*, 2020; Zhao *et al.*, 2020. Outros compararam outras ferramentas com RNA como Ferreira *et al.* (2019) e Acikgoz (2019).

Os prognósticos propostos aqui irão melhorar a qualidade das previsões do vento para energia eólica em Alagoas e NEB. Isto irá trazer mais confiabilidade nos produtos gerados e trará mais uma ferramenta para previsões com baixo custo computacional. O objetivo deste estudo é avaliar os prognósticos de curto, médio e longo prazo da velocidade do vento através do uso de Rede Neural Artificial (RNA), modelo atmosférico de mesoescala *Weather Research and Forecasting* (WRF) e previsão híbrida que combina estes dois métodos.

## 2. Materiais e Métodos

### 2.1. Área de estudo e dados observados

O local de estudo é coberto por vegetação de transição entre Caatinga e florestas tropicais úmidas. O clima da região central de Alagoas é seco e quente com precipitação média anual de 600 mm a 900 mm (Barros, 2012). Foram utilizados dados medidos em uma torre anemométrica instalada em uma área plana do Município de Craibas na região semiárida (Agreste) do Estado (09°53'03" S; 36°49'44" O; 244 m). As medidas foram realizadas durante a fase observacional do Projeto Previsão do Vento em Parques Eólicos no Nordeste do Brasil (PVPN).

As medições da velocidade, direção e rajadas de vento foram feitas a 50 m de altura, com frequência a cada 15 s. As médias foram armazenadas a cada 10 min em um *datalogger* CR1000 (*Campbell Scientific Inc.* - EUA) alimentado por um sistema de eletricidade fotovoltaica (modelo KS-20 da Kyocera) e calibrados de acordo com as diretrizes de órgãos internacionais (Silva-Junior *et al.*, 2016).

Neste estudo considerou-se apenas os dados observados (OBS) de velocidade do vento ( $m.s^{-1}$ ), mensurados a cada 10 min, com isto o número de previsões de curto, médio e longo prazo são de 144, 720 e 1440 valores, respectivamente. O período estudado foi todo o mês de abril de 2015 com 30 dias de análise totalizando 4320 medições de velocidade do vento.

### 2.2. Prognóstico utilizando rede neural artificial

A previsão da velocidade do vento é feita unicamente através do uso de Rede Neural Artificial não linear auto regressiva (RNA-NAR). O funcionamento inicial desta RNA é do tipo *Feedforward* onde sua informação na camada de entrada segue sempre na direção da camada de saída. Esta RNA se caracteriza pela variável  $Z$  que é o

atraso temporal. O atraso temporal serve como uma memória que proporciona valores de entrada atuais e valores anteriores a eles (Haykin, 2008; Silva *et al.*, 2010).

O prognóstico é feito apenas com OBS funcionando como sinal de entrada e alvo. As análises foram feitas no MATLAB® (versão R2013a) para iniciar o processo de treinamento, teste e validação da RNA. Esta arquitetura de RNA é configurada para fornecer previsão de um ou mais dias à frente, previsão para o dia seguinte no caso de prognóstico de curto prazo, previsão para cinco dias à frente para prognóstico de médio prazo e previsão para dez dias à frente no caso de prognóstico de longo prazo. A quantidade de dias anteriores as previsões utilizadas no treinamento da RNA foi um parâmetro bastante analisado. O número de dias variou de 1 a 10, 15, 30, 45, 60 e 90 dias antes da previsão. O triplo de dias utilizados para treinamento obteve os melhores resultados, ou seja, são utilizados três dias de treinamento para prever o quarto dia (total de 432 dados para prever 144 dados), quinze dias de treinamento para prever os próximos cinco dias (total de 2160 dados para prever 720 dados) e trinta dias de treinamento para prever os dez dias consecutivos (total de 4320 dados para prever 1440 dados) de acordo com o estudo de Santos (2019).

O algoritmo da RNA-NAR e os parâmetros utilizados neste estudo teve como referência principal o trabalho de Moura (2014). A Tabela 1 mostra a configuração final na fase de treinamento da RNA-NAR. Na fase de previsão

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

Parâmetros	Dados/valores
Sinais de entrada/alvo	OBS
Sinais na camada de entrada (curto, médio e longo prazo)	432, 2160 e 4320
Número de previsões (curto, médio e longo prazo)	144, 720 e 1440
Algoritmo de treinamento	Levenberg-Marquardt (LM)
Algoritmo de desempenho	Erro médio quadrado
Épocas	1000
Verificação	10
Gradiente	0,00001
Treinamento	70%
Teste	15%
Validação	15%
Camada escondida	1
Atraso de entrada	1:2
Neurônios na camada escondida	26
Função de ativação	Tangente hiperbólica
Camada de saída	1
Função de ativação	Linear
Neurônios na camada de saída	1

os dados OBS funcionam como sinal de entrada e destino  $y(t)$  e é composta por uma camada escondida (*Hidden*) com 26 neurônios e função de ativação Tangente Hiperbólica (*Tansing*), camada de saída (*Output*) com 1 neurônio e função de ativação Linear (*Purelin*), *delay*, pesos, bias e um sinal de saída  $y(t + 1)$  que representa a previsão da velocidade do vento.

### 2.3. Prognóstico utilizando o modelo WRF

O *Weather Research and Forecasting* (WRF) é um modelo atmosférico de mesoescala não hidrostático para Previsão Numérica de Tempo (PNT) e clima. É um modelo aberto e flexível, com código fonte disponibilizado livremente para uso operacional e de pesquisa, sendo a versão 3.6 usada neste estudo. Por possuir um código estável, limpo e aprimorado o WRF pode ser executado desde máquinas comuns, como um computador de mesa ou portátil, até em supercomputadores de grandes centros de pesquisa. Sua formulação física é baseada na conservação de massa, que expressa às variações de energia, momento e umidade do ar (Skamarock *et al.*, 2008). WRF é utilizado para modelagem em mesoescala que é amplamente usado para previsão do tempo e clima em todo o mundo e complementa as deficiências dos modelos de microescala na detecção de fenômenos sinóticos e anomalias climáticas.

Este modelo permite que seja feito aninhamento por meio de domínios, a fim de reduzir custos computacionais, focando um maior refinamento da grade, com maior resolução na região de maior interesse e os demais domínios servem para incorporar condições de contorno. Neste estudo foram configurados 3 domínios. O domínio 1 (domínio-mãe) apresenta resolução espacial de 80 km e abrange parte da América do Sul e Oceano Atlântico. O domínio 2 tem resolução de 20 km e abrange o Nordeste Brasileiro (NEB) e parte do Oceano Atlântico. O domínio 3 possui resolução de 5 km e compreende o Estado de Alagoas (Amorim, 2015).

A validação do modelo WRF se deu a partir do ponto de grade central no domínio 3 cujas coordenadas coincidem com as duas torres do projeto PVPN. A série foi extraída por meio de rotinas computacionais geradas em *Shell Script*, *GrADS* e *Fortran 90*.

A configuração e parametrização do modelo WRF para simular o vento foi baseado em estudos para regiões tropicais de acordo com o trabalho de Ramos *et al.* (2013).

Como condição de contorno, foram empregados dados de reanálises *National Center For Environmental Prediction* (NCEP) *Final Analysis* (FNL) na entrada das simulações do WRF com resolução espacial de  $1,0^\circ \times 1,0^\circ$  em um intervalo temporal de 6 h para cada ponto de grade. A composição física da superfície terrestre foi configurada através da topografia *United States Geological Survey* e vegetação *Moderate Resolution Imaging Spectroradio-*

meter (MODIS), ambos com resolução de 30 segundos de arco (925 m).

A Tabela 2 a seguir, lista as parametrizações físicas utilizadas junto com esquema e referência. Radiação de Onda Curta (ROC); Radiação de Onda Longa (ROL); Land Surface Model (LSM); Asymmetric Convective Model (ACM2); Teoria da Similaridade de Monin-Obukhov (TSMO); Rapid Radiative Transfer Model (RRTM).

O prognóstico WRF é feito em hora Coordinated Universal Time (UTC) e os dados OBS em hora local, então foi feita a conversão dos dados observados para hora UTC.

Por fim, as rodadas do modelo foram individuais para cada dia no período estudado (abril de 2015), as simulações para a velocidade do vento são do domínio 3, com nova configuração com saídas a cada 10 min, nível de 50 m de altura e a série temporal está compreendida dentro do mesmo período dos dados observados. Esta configuração aumenta a qualidade das simulações.

## 2.4. Prognóstico híbrido

A previsão híbrida da velocidade do vento é feita através do uso de Rede Neural Artificial não linear auto regressiva com entrada externa (RNA-NARX). O funcionamento da RNA-NARX é idêntico ao da RNA-NAR, mas a configuração desta RNA muda com a introdução dos dados do modelo WRF como sinal de entrada  $x(t)$  e os dados OBS funcionam apenas como dados de alvo  $y(t)$ . A Tabela 1, mostrada anteriormente, também pode ser utilizada para identificar os parâmetros da configuração final da fase de treinamento e previsão da RNA-NARX.

Um parâmetro importante presente no algoritmo deste tipo de RNA é a função de ativação Tangente Hiperbólica (Eq. (1)). É uma função suave, continuamente diferenciável e não linear com formato de S. Esta função tem uma característica em que  $x$  pode assumir qualquer valor, seja ele infinitamente grande positivo ou negativo, mas  $f(x)$  sempre estará dentro do intervalo aberto entre -1 e +1. A função de ativação serve de entrada para a camada seguinte, ela reduz o efeito de valores extremos de entrada, proporcionando um melhor funcionamento da

RNA. A Fig. 1 mostra o gráfico da função de ativação Tangente Hiperbólica no plano cartesiano  $x$  e  $f(x)$ .

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1)$$

## 2.5. Análise estatística

O levantamento estatístico para verificação da eficácia dos prognósticos tem uma importância relevante neste estudo, pois facilita a identificação de períodos em que os prognósticos do vento são mais ou menos eficiente.

Inicialmente é feita uma estatística univariada para descrever a análise separada dos dados (médias, mínimos e máximos), depois é feita uma estatística bivariada para descrever um relacionamento entre OBS e os prognósticos. As métricas estatísticas utilizadas foram desvio médio (DM - Eq. (2)), distribuição de frequência percentual a partir dos desvios, raiz do desvio quadrático médio (RDQM - Eq. (3)), desvio percentual absoluto médio (DPAM - Eq. (4)) e coeficiente de correlação de Pearson ( $r$  - Eq. (5)).

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

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

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

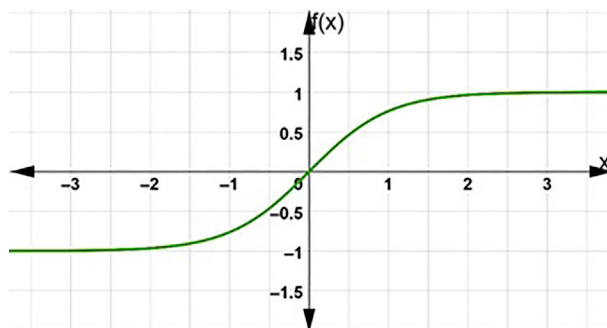
$$r = \frac{\sum_{i=1}^N (RNA_i - \overline{RNA}) \cdot (OBS_i - \overline{OBS})}{\sqrt{\sum_{i=1}^N (RNA_i - \overline{RNA})^2} \cdot \sqrt{\sum_{i=1}^N (OBS_i - \overline{OBS})^2}} \quad (5)$$

O número total de valores ( $N$ ) é de 4320, o índice ( $i$ ) varia de 1 a  $N$ ,  $RNA_i$  e  $OBS_i$  são os valores previstos e observa-

**Tabela 2** - Parametrizações físicas utilizadas na execução do modelo WRF.

Parametrização	Esquema	Referência
Microfísica	Purdue Lin	Lin <i>et al.</i> , 1983
Superfície do Solo	Noah LSM	Chen e Dudhia, 2001
Camada Limite Atmosférica	ACM2	Pleim, 2007
Cumulus	Grell-Devenyi	Grell e Devenyi, 2002
Camada Limite Superficial	TSMO	Monin e Obukhov, 1954
ROC e ROL	RRTM	Mlawer <i>et al.</i> , 1997
Turbulência Atmosférica	Mellor-Yamada	Mellor e Yamada, 1974

Fonte: Ramos *et al.*, 2013.



**Figura 1** - Função de ativação tangente hiperbólica.



dos com seus respectivos índices,  $\overline{RNA}$  e  $\overline{OBS}$  são os valores previstos e observados médios, respectivamente.

A distribuição de frequência percentual dos desvios é importante porque permite identificar melhor a classe da acurácia dos prognósticos em relação aos dados reais. A estatística foi feita utilizando os valores arredondados dos desvios de forma que cada classe representa uma janela de  $1,0 \text{ m.s}^{-1}$  com variação de  $0,5 \text{ m.s}^{-1}$ . Por exemplo, a classe 0 vai de  $-0,5 \text{ m.s}^{-1}$  a  $+0,5 \text{ m.s}^{-1}$ .

### 3. Resultados e Discussão

Nesta seção serão apresentados e discutidos os resultados para a previsão da velocidade do vento no período estudado através da RNA-NAR, modelo WRF e prognóstico híbrido feito pela RNA-NARX. As séries de dados correspondentes aos resultados destas previsões serão chamadas de NAR-CP, NAR-MP, NAR-LP, NARX-CP, NARX-MP, NARX-LP (prognósticos feitos pelas RNAs de curto, médio e longo prazo) e os prognósticos WRF.

A Fig. 2 mostra a evolução temporal da velocidade do vento dos prognósticos e observados no período estudado (abril de 2015). Em todos os gráficos é evidente a proximidade dos prognósticos para com OBS. As previsões reproduziram bem o ciclo diário do vento na maioria dos casos. No entanto, existem alguns períodos do dia em que se observa clara discordância, sendo diferentes em cada prognóstico. Por exemplo, a Fig. 2A apresentou apenas 6 dias de discordância entre OBS e NAR-CP, Fig. 2B (8 dias e NAR-MP), Fig. 2C (10 dias e NAR-LP), Fig. 2D (13 dias e NARX-CP), Fig. 2E (13 dias e NARX-MP), Fig. 2F (14 dias e NARX-LP) e Fig. 2G (16 dias e WRF).

Geralmente, quando a série OBS apresenta um padrão diário diferente dos dias anteriores, os prognósticos não conseguem reproduzir bem estas mudanças de comportamento do vento. O prognóstico da RNA carrega características da velocidade do vento dos dias usados para treinamento, ou seja, se os ventos que irão ser previstos forem muito distintos dos ventos anteriores usados para treinamento da RNA, isto indica que a acurácia da previsão não será precisa.

Como exemplo, vejamos a atipicidade dos dados OBS no dia 12 em que o vento atinge uma velocidade mínima acima da média próximo de  $4 \text{ m.s}^{-1}$ , mas os prognósticos NAR-CP (Fig. 2A) e NARX-CP (Fig. 2E) seguem o padrão dos dias anteriores atingindo uma velocidade próximo de  $1 \text{ m.s}^{-1}$ , assim como o prognóstico WRF (Fig. 2D). Outro exemplo é quando a série OBS atinge uma velocidade mínima próximo de zero, mas no decorrer do dia, aumenta e em seguida diminui novamente, mas não consegue ultrapassar a velocidade de  $10 \text{ m.s}^{-1}$ , como na maioria dos outros dias. Isto se verificou no dia 19 em que os prognósticos NAR-CP e NARX-

CP (Fig. 2 (A e E)) reproduziram estas características no dia seguinte, os NAR-MP e NARX-MP (Fig. 2 (B e F)) reproduziram no dia 24 (5 dias depois) e os NAR-LP e NARX-LP (Fig. 2 (C e G)) reproduziram no dia 29 (10 dias depois). Reafirmando o fato, já comentado anteriormente, em que a previsão da RNA carrega características dos dias usados para treinamento (Moura, 2014; Santos, 2019).

Estudos semelhantes indicaram que o modelo WRF tem limitações na previsão do vento para o mês de abril período de transição de seco para chuvoso, limitações em prever valores extremos (máximos e mínimos) (Ramos *et al.*, 2013; Ihadua, 2014; Lyra *et al.*, 2016). Isto também pode ser verificado neste prognóstico WRF (Fig. 2D). Em alguns dias específicos nota-se uma nítida diferença entre os dados OBS e WRF, principalmente nos períodos de transição de dia/noite ou noite/dia, como pode ser visualizado nos dias 05, 06, 07, 10, 12 e 23. Neste prognóstico foi onde se obteve mais casos de subestimação de valores.

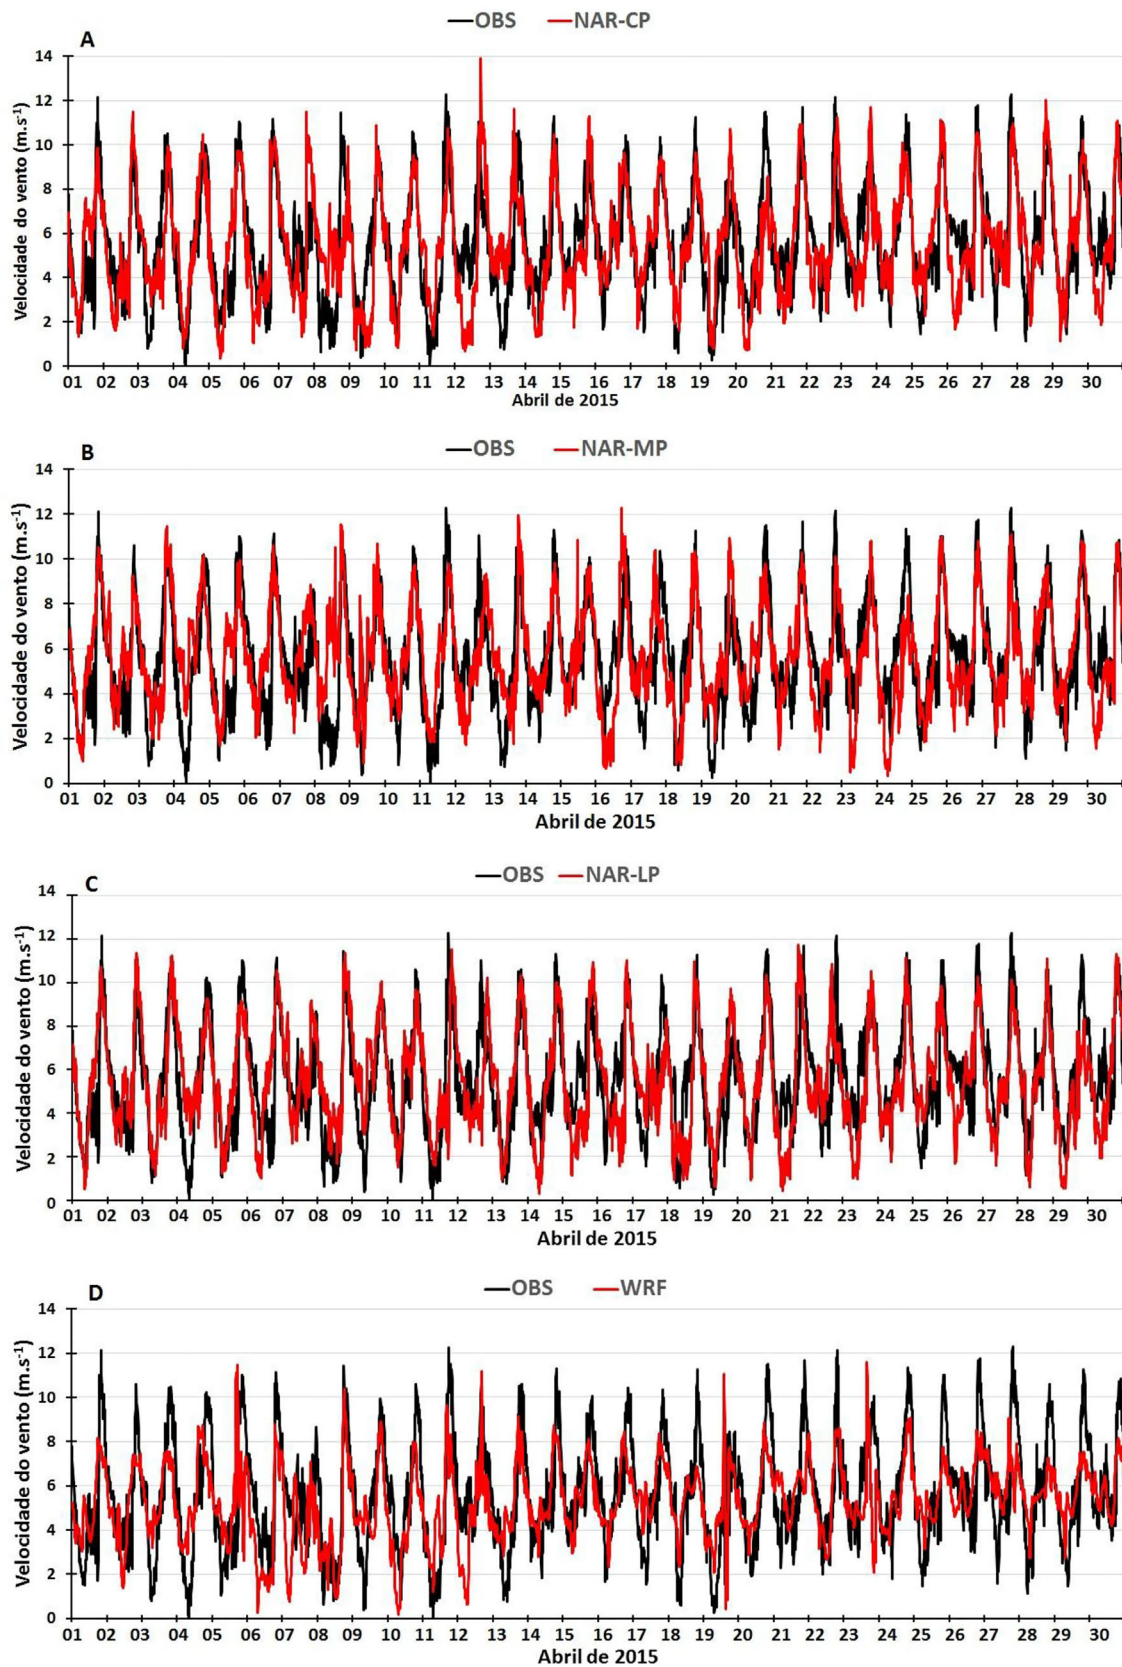
No caso de atipicidade da série OBS como, por exemplo, no dia 07, NAR-CP (Fig. 2A) não conseguiu reproduzir esta mudança de comportamento do vento, mas o prognóstico WRF (Fig. 2D) que subestimou os dados OBS neste dia auxiliou o NARX-CP (Fig. 2E) diminuindo os extremos máximos e mínimos melhorando o prognóstico neste dia. Algumas oscilações bruscas do prognóstico WRF (Fig. 2D) não se adaptou aos dados observados, como nos dias 05, 19 e 23.

A Tabela 3 mostra a estatística univariada (média, máximo e mínimo) e bivariada (DM, RDQM, DPAM e r) dos resultados. Nela podemos observar que todos os valores médios foram próximos variando de  $5,18 \text{ m.s}^{-1}$  (WRF) a  $5,41 \text{ m.s}^{-1}$  (NAR-MP). O prognóstico que mais se aproximou da média observada foi NARX-LP com  $5,25 \text{ m.s}^{-1}$ .

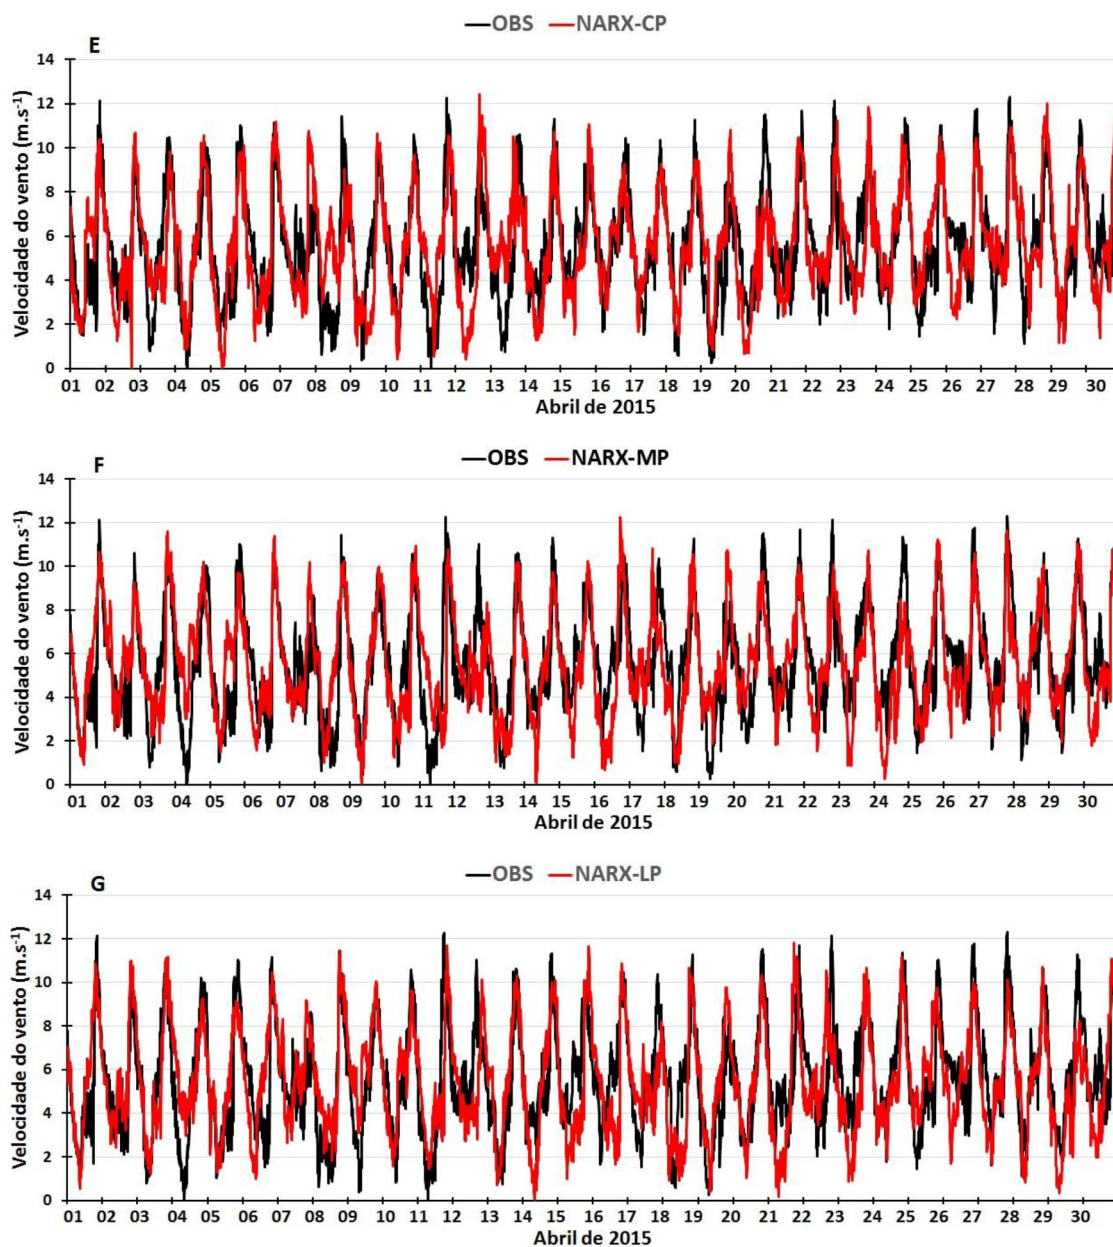
As velocidades máximas variaram de  $11,58 \text{ m.s}^{-1}$  (WRF) a  $13,92 \text{ m.s}^{-1}$  (NAR-CP). A série que mais se aproximou da OBS foi NAR-MP com  $12,30 \text{ m.s}^{-1}$ . Observa-se na Tabela 3 que à medida que aumentou-se o prazo de previsão diminuiu o valor da velocidade máxima dos prognósticos RNA.

As velocidades mínimas variaram de  $0,01 \text{ m.s}^{-1}$  (OBS, NARX-CP e NARX-LP) a  $0,36 \text{ m.s}^{-1}$  (NAR-CP). As velocidades mínimas das séries NARXs foram sempre menores que as séries NARs. Nos prognósticos RNAs, a velocidade mínima ocorreu no período da manhã e a máxima no fim da tarde ou começo da noite, em alguns casos o prognóstico WRF obteve velocidade máxima no período da tarde.

Os desvios médios (DM) mensais foram próximos de zero caracterizando um ótimo resultado. Eles variaram entre  $-0,31 \text{ m.s}^{-1}$  (WRF) a  $0,04 \text{ m.s}^{-1}$  (NAR-MP), sendo este último o único positivo. Portanto, a maioria dos prognósticos subestimou a velocidade do vento. Também neste caso, verifica-se na Tabela 3, à medida que aumenta o



**Figura 2** - Evolução temporal da velocidade do vento das séries NAR-CP (A), NAR-MP (B), NAR-LP (C), WRF (D), NARX-CP (E), NARX-MP (F), NARX-LP (G) e OBS.



**Figura 2 (cont.)** - Evolução temporal da velocidade do vento das séries NAR-CP (A), NAR-MP (B), NAR-LP (C), WRF (D), NARX-CP (E), NARX-MP (F), NARX-LP (G) e OBS.

**Tabela 3** - Estatística univariada e bivariada entre os dados observados e os prognósticos.

Série	Média	Máximo	Mínimo	DM	RDQM	DPAM	r
OBS	5,26 m.s <sup>-1</sup>	12,29 m.s <sup>-1</sup>	0,01 m.s <sup>-1</sup>	-	-	-	-
NAR-CP	5,24 m.s <sup>-1</sup>	13,92 m.s <sup>-1</sup>	0,36 m.s <sup>-1</sup>	-0,01 m.s <sup>-1</sup>	1,14 m.s <sup>-1</sup>	22 %	0,71
NAR-MP	5,41 m.s <sup>-1</sup>	12,30 m.s <sup>-1</sup>	0,34 m.s <sup>-1</sup>	0,04 m.s <sup>-1</sup>	1,20 m.s <sup>-1</sup>	22 %	0,68
NAR-LP	5,29 m.s <sup>-1</sup>	11,74 m.s <sup>-1</sup>	0,31 m.s <sup>-1</sup>	-0,05 m.s <sup>-1</sup>	1,24 m.s <sup>-1</sup>	23 %	0,69
WRF	5,18 m.s <sup>-1</sup>	11,58 m.s <sup>-1</sup>	0,16 m.s <sup>-1</sup>	-0,31 m.s <sup>-1</sup>	1,27 m.s <sup>-1</sup>	22 %	0,63
NARX-CP	5,30 m.s <sup>-1</sup>	12,41 m.s <sup>-1</sup>	0,01 m.s <sup>-1</sup>	-0,01 m.s <sup>-1</sup>	1,17 m.s <sup>-1</sup>	22 %	0,72
NARX-MP	5,28 m.s <sup>-1</sup>	12,25 m.s <sup>-1</sup>	0,06 m.s <sup>-1</sup>	-0,08 m.s <sup>-1</sup>	1,19 m.s <sup>-1</sup>	22 %	0,70
NARX-LP	5,25 m.s <sup>-1</sup>	11,83 m.s <sup>-1</sup>	0,01 m.s <sup>-1</sup>	-0,09 m.s <sup>-1</sup>	1,23 m.s <sup>-1</sup>	23 %	0,69



prazo de previsão, o DM também aumenta, principalmente nos prognósticos NARXs. É importante destacar que todos os desvios dos prognósticos RNAs foram inferiores à margem do erro dos anemômetros ( $0,2 \text{ m.s}^{-1}$ ).

A RDQM de todos os resultados esteve entre  $1,14 \text{ m.s}^{-1}$  (NAR-CP) a  $1,27 \text{ m.s}^{-1}$  (WRF). O DPAM foi praticamente igual para todos os prognósticos, apenas NAR-LP e NARX-LP obtiveram 23%, enquanto que o restante apresentou DPAM de 22% dos dados observados. A partir da análise estatística, o melhor prognóstico foi o NAR-CP, pois obteve o menor DM, RDQM e DPAM.

Apesar da diferença média muito pequena entre os prognósticos e OBS, o coeficiente de correlação de Pearson ( $r$ ) permaneceu entre 0,63 a 0,72. Isto ocorre pelo caráter intermitente do vento o que dificulta a sua previsibilidade. O prognóstico WRF obteve a menor correlação (0,63), enquanto que NARX-CP obteve a melhor correlação (0,72). Na Tabela 3, nesta métrica estatística também é possível identificar que ao aumentar o período de previsão o coeficiente de correlação entre os prognósticos e OBS diminui.

Comparando os resultados deste estudo com estudos similares verificamos que os valores da Tabela 3 estão em concordância. No caso dos estudos com RNA, os coeficientes de correlação são da mesma ordem daqueles encontrados por Acikgoz *et al.* (2019) [0,87 a 0,95], Zucatelli *et al.* (2019) [0,91] e Ferreira *et al.* (2019) [0,46 a 0,96].

Um estudo similar ao presente foi aquele realizado por Ferreira *et al.* (2019). Com o objetivo de prever a velocidade média horária do vento em torres anemométricas de 50 m, uma em Camocim-CE e outra em Belo Jardim-PE. Utilizaram os modelos *Holt-Winters* (HW), Rede Neural Artificial (RNA) e um modelo híbrido (MH). Nos prognósticos feitos para 30 dias os resultados obtidos para “ $r$ ” foram: a) Triunfo (HW 0,73), (RNA 0,46), (MH 0,07); b) Camocim (HW 0,96), (RNA 0,96), (MH 0,96). Com relação à RDQM/RMSE, os resultados foram: a) Triunfo

(HW 1,14), (RNA 1,73), (HM 0,74); b) Camocim (HW 1,06), (RNA 1,07), (MH 1,00). Portanto, quando comparados estes resultados com os da Tabela 3 verificamos que obtivemos resultados próximos. É importante salientar que, o trabalho de Ferreira *et al.* (2019) é o que melhor permite comparação uma vez que foram utilizados dados observados semelhantes (velocidade do vento a 50 m) e na mesma região (Nordeste do Brasil). Além do mais, Triunfo, assim como Craibas, encontram-se na região semiárida do Nordeste.

Na Fig. 3 é mostrada a distribuição de frequência relativa dos desvios dos prognósticos em relação aos dados OBS. Em todos os casos a distribuição é unimodal com maior frequência percentual dos desvios na classe 0 (entre 22% a 24%). Na maioria dos casos a frequência percentual negativa (entre 37% a 45%) é maior que a positiva (entre 33% a 39%) informando tendência de subestimativa. A maior diferença de frequência percentual foi do prognóstico WRF com 45% negativa e 33% positiva. O prognóstico NARX-CP obteve 38% para negativa e positiva. O único caso em que a frequência percentual positiva 39% foi maior que a negativa 37% foi o prognóstico NAR-MP. Em todos os prognósticos mais da metade da frequência dos desvios estão compreendidos entre as classes -1 a +1 (entre 58% a 61%) indicando uma boa simulação.

A Tabela 4 apresenta uma análise estatística de estudos que utilizaram o modelo WRF e/ou RNA para prognóstico do vento na região central de Alagoas (GP - Girau do Ponciano e CR - Craibas). As unidades de medidas são dadas em  $\text{m.s}^{-1}$  e apenas o coeficiente de correlação de Pearson ( $r$ ) é adimensional.

A maioria dos trabalhos analisados na Tabela 4 disponibilizaram apenas as médias mensais ou diárias, por isso que estes estudos apresentam uma diferença pequena entre os valores máximos e mínimos da velocidade do vento. Jatobá *et al.* (2017) apresentou resultados com apenas três dias de estudos com médias a cada 10 min, con-

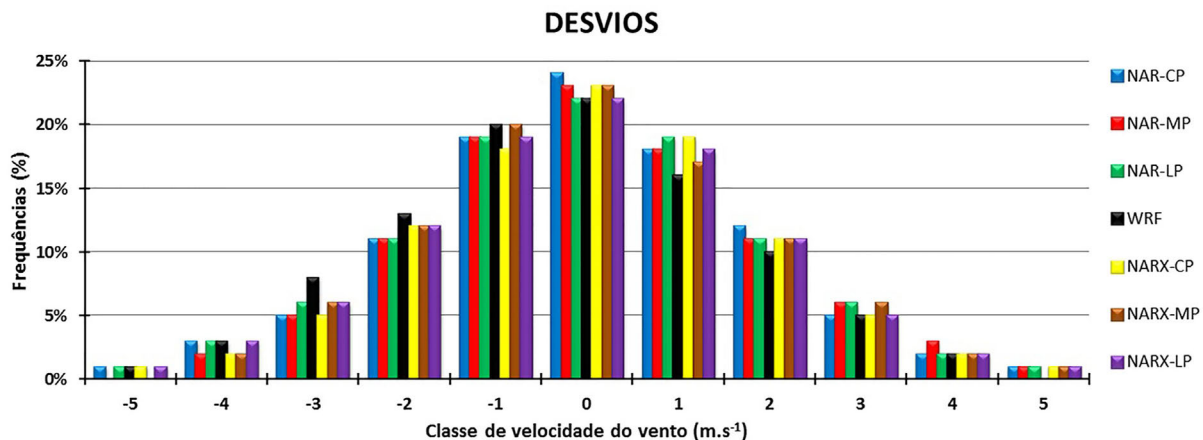


Figura 3 - Distribuição de frequência relativa (%) dos desvios ( $\text{m.s}^{-1}$ ) dos prognósticos com relação aos dados observados.



**Tabela 4** - Levantamento estatístico de estudos que utilizaram o modelo WRF e/ou RNA para prognóstico da velocidade do vento na região central de Alagoas.

	Período	OBS Médio	WRF Médio	RNA Médio	OBS Máx e Mín	WRF Máx e Mín	RNA Máx e Mín	DM	RDQM	r
Ramos <i>et al.</i> (2013)-GP	01/08/07 31/07/08	-	-	-	-	-	-	-1,16	2,98	-
Moura (2014)-GP	01/01/09 31/12/09	7,25	4,24	7,30	15,34	9,17	11,00	-3,01 e 0,05	-	0,60 e 0,71
Ihadua (2014)-GP	01/12/07 30/11/08	7,25	7,27	-	9,56 e 5,76	10,34 e 5,34	-	0,02	-	-
Amorim (2015)-GP	01/01/08 31/12/08	-	-	-	-	-	-	-1,18	2,31	0,62
Lyra <i>et al.</i> (2016)-CR	22/03/14 31/03/14	5,72	6,32	-	-	-	-	0,60	-	0,86
Jatobá <i>et al.</i> (2017)-CR	22/03/15 24/03/15	6,44	7,19	-	11,84 e 1,40	12,21 e 2,48	-	0,75	-	0,77
Silva <i>et al.</i> (2017)-GP	01/01/09 31/12/09	6,31	-	5,99	12,65 e 2,16	-	8,18 e 3,62	-0,32	1,41	0,86
Lyra <i>et al.</i> (2017)-CR	01/01/15 31/01/15	7,08	6,70	-	16,19 e 1,47	13,28 e 0,93	-	-0,38	1,31	0,64
Silva <i>et al.</i> (2018)-CR	01/01/14 31/12/14	5,27	5,03	-	6,72 e 4,60	7,30 e 5,03	-	-0,24	-	-
Santos (2019)-CR	04/03/15 04/07/15	5,32	4,98	5,52	7,21 e 3,03	6,76 e 2,81	7,21 e 3,07	-0,01 e -0,35	1,18 e 1,24	0,61 e 0,70

sequentemente apresentou a variação diária do vento com velocidade mínima de  $1,40 \text{ m.s}^{-1}$  para OBS e Lyra *et al.* (2017) com o mês de janeiro em análise apresentou a maior velocidade máxima dos dados observados de  $16,19 \text{ m.s}^{-1}$  e a menor velocidade mínima de  $0,93 \text{ m.s}^{-1}$  para WRF dentre todos os trabalhos analisados.

No estudo do Ramos *et al.* (2013), o modelo WRF apresentou limitações na previsão do vento para o mês de abril período de transição de seco para chuvoso, o DM foi de  $-1,16 \text{ m.s}^{-1}$  e RDQM de  $2,98 \text{ m.s}^{-1}$ , sendo classificado como um resultado satisfatório.

Moura (2014) utilizou RNA para melhorar os dados WRF em comparação com os dados OBS em Girau do Ponciano, Agreste de Alagoas. As velocidades médias para o período estudado (2009) foram de  $7,25 \text{ m.s}^{-1}$  (OBS),  $4,24 \text{ m.s}^{-1}$  (WRF) e  $7,30 \text{ m.s}^{-1}$  (RNA). O DM diminuiu de  $-3,01 \text{ m.s}^{-1}$  para  $0,05 \text{ m.s}^{-1}$  e o coeficiente de correlação passou de 0,60 para 0,71.

O estudo feito por Ihadua (2014) foi o que obteve a velocidade do vento simulada mais próxima da velocidade real  $7,27 \text{ m.s}^{-1}$  e  $7,25 \text{ m.s}^{-1}$ , consequentemente obteve o menor DM anual de apenas  $0,02 \text{ m.s}^{-1}$ .

Com o objetivo de validar o prognóstico da velocidade do vento gerado pelo modelo WRF em quatro estações anemométricas no Estado de Alagoas Amorim (2015) constatou que, em apenas uma delas (Girau do Ponciano) verificou-se um desempenho satisfatório.

Estudos com período curto de análise apresentaram as melhores correlações como é o caso do Lyra *et al.*

(2016), Jatobá *et al.* (2017) e Silva *et al.* (2017). A maioria dos trabalhos apresentou tendência de subestimação dos prognósticos.

Santos (2019) fez prognósticos da velocidade do vento utilizando RNA com antecedência de 24 h, os dados WRF e OBS funcionaram como dados de entrada e alvo, obteve as menores RDQM com  $1,24 \text{ m.s}^{-1}$  entre WRF e OBS e  $1,18 \text{ m.s}^{-1}$  entre RNA e OBS.

Em geral, os resultados de todos os trabalhos citados neste item, quando comparados à literatura, foram considerados de satisfatórios a bons. Entretanto, as particularidades de cada estudo devem ser consideradas uma vez que há fatores que influenciam os resultados, como o tamanho das séries anemométricas, sua resolução temporal, método de modelagem e avaliação das métricas estatísticas empregadas.

#### 4. Considerações Finais

Este estudo teve como objetivo avaliar os prognósticos da velocidade do vento feitos por Redes Neurais Artificiais e modelo atmosférico de mesoescala WRF. Todos os resultados obtidos mostraram que os prognósticos RNA-NAR, WRF e RNA-NARX conseguiram reproduzir bem a evolução temporal da velocidade do vento.

As velocidades médias variaram de  $5,18 \text{ m.s}^{-1}$  a  $5,41 \text{ m.s}^{-1}$ , as máximas de  $11,58 \text{ m.s}^{-1}$  a  $13,92 \text{ m.s}^{-1}$  e as mínimas de  $0,01 \text{ m.s}^{-1}$  a  $0,36 \text{ m.s}^{-1}$ . As métricas estatísticas utilizadas para averiguar a acurácia das previsões resultaram no seguinte: Desvio médio ( $-0,31 \text{ m.s}^{-1}$  a

0,04 m.s<sup>-1</sup>); Raiz do desvio quadrático médio (1,14 m.s<sup>-1</sup> a 1,27 m.s<sup>-1</sup>); Desvio percentual absoluto médio (22% a 23%); e coeficiente de correlação (0,63 a 0,72). Em todos os prognósticos a distribuição de frequência percentual foi unimodal sendo que a maior frequência percentual dos desvios está na classe 0 (22% a 24%). Na maioria dos prognósticos as distribuições negativas (37% a 45%) são maiores que as positivas (33% a 39%) indicando tendência de subestimação de valores. Para todos os modelos de estimativas analisados, a maior frequência ocorreu com desvios entre as classes -1 a +1 m.s<sup>-1</sup> (58% a 61%).

A análise estatística comprovou que quanto menor for o período de previsão os prognósticos ficam mais próximos dos dados OBS. Deste modo, os melhores prognósticos foram os de curto prazo NAR-CP e NARX-CP, respectivamente, pois obtiveram os melhores DM, RDQM, DPAM e r.

A maior limitação dos prognósticos é reproduzir dias atípicos. Apesar disso, os resultados mostraram que a utilização de RNAs e modelo WRF, separados ou juntos são opções viáveis para prognóstico da velocidade do vento.

## Agradecimentos

Os autores agradecem ao Programa de Pós-Graduação em Meteorologia (PPGMET), ao Instituto de Ciência Atmosférica (ICAT), a Universidade Federal de Alagoas (UFAL) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro concedido ao primeiro autor durante o curso de mestrado realizado entre os anos 2017-2019.

## Referências

- ABEEOLICA. **Associação Brasileira de Energia Eólica**. Disponível em <http://abeeolica.org.br/agencia-abeeolica/>. Acesso em 23 dez. 2019.
- ACIKGOZ, H.; CEYHUN, Y.; MUSTAFA, S. An extreme learning machine based very short-term wind power forecasting method for complex terrain. **Energy Sources**, v. 42, n. 22, p. 2715-2730, 2020.
- AMORIM, M.C.A.L. **Análise e Refinamento Estatístico Dos Prognósticos Do Vento Com O Modelo WRF no Estado de Alagoas**. Dissertação de Mestrado em Meteorologia, Universidade Federal de Alagoas. Maceió, Alagoas, 78 p., 2015.
- BARROS, A.H.C. **Boletim De Pesquisa E Desenvolvimento: Climatologia do Estado de Alagoas**. 2 ed. Recife: Embrapa, 33 p., 2012.
- CHEN, F.; DUDHIA, J. Coupling an advanced land surface / hydrology model with the Penn State / NCAR MM5 modeling system. Part 1: Model description and implementation. **Monthly Weather Review**, v. 129, p. 569-585, 2001.
- COSTA, G.B.; LYRA, R.F.F. Análise dos padrões de vento no estado de Alagoas. **Revista Brasileira de Meteorologia**, v. 27, n. 1, p. 31-38, 2012.
- CRUZ, N.S.D.; LYRA, R.F.F.; CORREIA-FILHO, W.L.F. Caracterização do vento na região de Craíbas - AL para fins eólicos. **Revista Brasileira de Energias Renováveis**, v. 6, n. 4, p. 811-823, 2017.
- ELETROBRAS. **Atlas Eólico de Alagoas**. Disponível em [http://www.cresesb.cepel.br/publicacoes/download/atlas\\_eolico/atlas\\_eolico\\_AL.pdf](http://www.cresesb.cepel.br/publicacoes/download/atlas_eolico/atlas_eolico_AL.pdf). Acesso em 25 dez. 2019.
- FAZELPOUR, F.; TARASHKAR, N.; ROSEN, M.A. Short-term wind speed forecasting using artificial neural networks for Tehran, Iran. **International Journal of Energy and Environmental Engineering**, v.7, p. 377-390, 2016.
- FERREIRA, M.; SANTOS, A.; LUCIO, P. Short-term forecast of wind speed through mathematical models. **Energy Reports**, v. 5, p. 1172-1184, 2019.
- GONÇALVES, A.R. **Refinamento Estatístico das Previsões de Vento do Modelo ETA Aplicado ao Setor Eólico-Elétrico do Nordeste Brasileiro**. Dissertação de Mestrado em Meteorologia, Instituto Nacional de Pesquisas Espaciais. São José dos Campos, São Paulo, 180 p., 2011.
- GRELL, G.A.; DEVENYI, D. A generalized approach to parameterizing convection combining ensemble and data assimilation techniques. **Geophysical Research Letters**, v. 29, n. 14, p. 1-4, 2002.
- HAYKIN, Simon. **Redes Neurais Princípios e Prática**. 2ª ed. Porto Alegre: Bookman, 900 p., 2008.
- HUANG, C.J.; KUO, P.H. A Short-Term Wind Speed Forecasting Model by Using Artificial Neural Networks with Stochastic Optimization for Renewable Energy Systems. **Journals Energies**, v. 11, n. 10, p. 1-20, 2018.
- IHADUA, I.M.T.J. **Desempenho Do Modelo WRF Para Prognóstico Da Velocidade Do Vento Em Girau Do Ponciano - AL**. Monografia, Curso de Graduação em Meteorologia. Universidade Federal de Alagoas, Maceió, Alagoas, 2014.
- JATOBA, B.R.G.; SILVA-JUNIOR, R.S.; LYRA, R.F.F.; ROCHA-JUNIOR, R.L.; FERNANDO, L.Y.C. Avaliação do potencial eólico para a cidade de Craíbas - AL utilizando o modelo meteorológico WRF em alta resolução. **Revista Brasileira de Energias Renováveis**, v. 6, n. 4, p. 787-810, 2017.
- LIN, Y.L.; FARLEY, R.D.; ORVILLE, H.D. Bulk parametrization of the snow field in a cloud model. **Journal of Applied Meteorology and Climatology**, v. 22, p. 1065-1092, 1983.
- LYRA, R.F.F.; SILVA-JUNIOR, R.S.; MOURA, M.A.L.; AMORIM, M.C.A.L. Prognóstico da velocidade do vento utilizando o modelo WRF na região central de Alagoas. **Ciência e Natura. Edição Especial - IX Workshop Brasileiro de Micrometeorologia**, v. 38, p. 447-451, 2016.
- LYRA, R.F.F.; SILVA, S.M.S.; SILVA-JUNIOR, R.S.; CRUZ, N.S.D.; SILVA, S.S. Avaliação do desempenho do modelo WRF para prognóstico do vento utilizando um passo de tempo de 10 minutos. **X Workshop Brasileiro de Micrometeorologia**, Santa Maria, p.1-7, 2017.
- MALDONADO-CORREA, J.; SOLANO, J.C.; ROJAS-MONCAYO, M. Wind power forecasting: A systematic literature review. **Wind Engineering**, p. 1-14, 2019.
- MELLOR, G.L.; YAMADA, T. A Hierarchy of Turbulence Closure Models for Planetary Boundary Layers. **Journal of the Atmospheric Sciences**, v. 31, n. 7, p. 1791-1806, 1974.

- MLAWER, E.J.; TAUBMAN, S.J.; BROWN, P.D.; IACONO, M.J.; CLOUGH, S.A. Radiative transfer for inhomogeneous atmosphere: RRTM, a validated correlated-k for the longwave. **Journal of Geophysical Research**, v. 102, n. 14, p.16663-16682, 1997.
- MONIN, A.S.; OBUKHOV, A.M. Basics laws of turbulent mixing in the surface layer of the atmosphere. **Contrib. Geophys. Inst. Acad. Sci.**, v. 151, p. 163-187, 1954.
- MOURA, J.D.O. **Refinamento Das Simulações De Vento Do Modelo WRF Utilizando Redes Neurais Artificiais**. Monografia, Curso de Graduação em Meteorologia. Universidade Federal de Alagoas, Maceió, Alagoas. 2014.
- NAZIR, M.S.; ALTURISE, F.; ALSHMURANY, S.; NAZIR, H.M.J.; BILAL, M.; ABDALLA, A.N.; SANJEEVIKUMAR, P.; ZIAD, M.A. Wind Generation Forecasting Methods and Proliferation of Artificial Neural Network: A Review of Five Years Research Trend. **Sustainability**, v. 12, n. 3778, p. 1-27, 2020.
- PLEIM, J.E. A combined local and non-local closure model for the Atmospheric boundary layer. Part. 1: Model description and testing. **Journal of Applied Meteorology and Climatology**, v. 46, p. 1383-1398, 2007.
- RAMOS, D.N.S.; LYRA, R.F.F.; SILVA-JUNIOR, R.S. Previsão do vento utilizando o modelo atmosférico WRF para o Estado de Alagoas. **Revista Brasileira de Meteorologia**, v. 28, n. 2, p. 163-172, 2013.
- SANTOS, I.G.S. **Previsão da Velocidade do Vento na Escala do Parque Eólico Utilizando o Modelo WRF e Rede Neural Artificial**. Dissertação de Mestrado em Meteorologia, Universidade Federal de Alagoas, Maceió, Alagoas, 76 p, 2019.
- SANTOS, I.G.S.; LYRA, R.F.F.; FREITAS, I.G.F.; NOVA, T.S.V. Prognóstico da velocidade do vento utilizando rede neural artificial. In: **Meteorologia e Recursos Naturais: Estudos Aplicados**, SILVA, M.T.; SANTOS, C.A.C. (orgs.), Campina Grande: EDUEFCG, 623 p, 2020. Disponível em [http://www.dca.ufcg.edu.br/\\_docs/Ebook\\_WMRN\\_2020\\_VFinal.pdf](http://www.dca.ufcg.edu.br/_docs/Ebook_WMRN_2020_VFinal.pdf). Acesso em 20 nov. 2020.
- SEWDIEN, V.N.; PREECE, R.; TORRES, J.L.R.; RAKHSHANI, E.; MEIJDEN, M.V.D. Assessment of critical parameters for artificial neural networks based short-term wind generation forecasting. **Renewable Energy**, v. 161, p. 878-892, 2020.
- SILVA-JUNIOR, R.S.; LYRA, R.F.F.; RAMOS, D.N.S.; MOURA, M.A.L.; GOMES, H.B.; HOLANDA, S.C. Prognóstico do vento para o Estado de Alagoas utilizando o modelo WRF em alta resolução: avaliação da melhoria da topografia, uso do solo e velocidade de fricção. **Ciência e Natura. Edição Especial - IX Workshop Brasileiro de Micrometeorologia**, v. 38, p. 137-144, 2016.
- SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes Neurais Artificiais para Engenharias e Ciências Aplicadas**. São Paulo: Artliber, 399 p., 2010.
- SILVA, A.R. **Caracterização do vento e potencial eólico no Estado de Alagoas**. Dissertação de Mestrado em Meteorologia, Universidade Federal de Alagoas, Maceió, 100 p., 2011.
- SILVA, S.S.; LYRA, R.F.F.; SILVA-JUNIOR, R.S.; SILVA, S.M.S.; CRUZ, N.S.D. Refinamento das estimativas da velocidade do vento feitas pelo modelo WRF usando redes neurais artificiais (RNA) e modelo físico-estatístico. **X Workshop Brasileiro de Micrometeorologia**, Santa Maria, p. 1-5, 2017.
- SILVA, S.M.S. **Estudo Dos Parâmetros Aerodinâmicos Para Melhoria Da Previsão Do Vento No Estado De Alagoas**. Dissertação de Mestrado em Meteorologia, Universidade Federal de Alagoas, Maceió, 66 p., 2018.
- SKAMAROCK, W.C.; KLEMP, J.B.; DUDHIA, J.; GILL, D.O.; BARKER, D.M.; DUDA, M.G.; HUANG, X.Y.; WANG, W.; POWERS, J.G. **A Description Of The Advanced Research WRF Version 3**. Boulder: National Center for Atmospheric Research, p. 1-125, 2008.
- TESFAY, A.; ZHANG, J.H.; SHIFERAW, D. Wind Power Forecasting Using Artificial Neural Networks for Resource Scheduling in Microgrids. **International Journal of Science and Engineering Applications**, v. 5, n. 3, p. 144-151, 2016.
- WWEA. **World Wind Energy Association**. Disponível em <https://wwindea.org/blog/2019/02/25/wind-power-capacity-worldwide-reaches-600-gw-539-gw-added-in-2018/>. Acesso em 23 dez. 2019.
- ZHAO, X.; WEI, H.; LI, C.; ZHANG, K. A hybrid nonlinear forecasting strategy for short-term wind speed. **Energies** 2020, v. 13, n. 1596, p. 1-15, 2020.
- ZUCATELLI, P.J.; NASCIMENTO E.G.S.; AYLAS, G.Y.R.; SANTOS, A.A.B.; ARCE, A.M.G.; MOREIRA, D.M. Short-term wind speed forecasting in Uruguay using computational intelligence. **Heliyon**, v.5, n. 5, p. 1-11, 2019.