



UNIVERSIDADE FEDERAL DE ALAGOAS  
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS  
PÓS-GRADUAÇÃO EM METEOROLOGIA

IWLDSOON GUILHERME DA SILVA SANTOS

**PREVISÃO DA VELOCIDADE DO VENTO NA ESCALA DO PARQUE EÓLICO  
UTILIZANDO O MODELO WRF E REDE NEURAL ARTIFICIAL**

**MACEIÓ - AL  
Março ó 2019**

IWLDSOON GUILHERME DA SILVA SANTOS

**PREVISÃO DA VELOCIDADE DO VENTO NA ESCALA DO PARQUE EÓLICO  
UTILIZANDO O MODELO WRF E REDE NEURAL ARTIFICIAL**

Dissertação submetida ao colegiado do Curso de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas - UFAL, como parte dos requisitos para obtenção do título de Mestre em Meteorologia.

Orientador: Prof. Dr. Roberto Fernando da Fonseca Lyra.

**MACEIÓ - AL  
Março - 2019**

**Catálogo na fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**

Bibliotecário: Marcelino de Carvalho

S237p Santos, Iwldson Guilherme da Silva.  
Previsão da velocidade do vento na escala do parque eólico utilizando o modelo WRF e rede neural artificial / Iwldson Guilherme da Silva Santos. – 2019.  
76 f. : il. color.

Orientador: Roberto Fernando da Fonseca Lyra.  
Dissertação (mestrado em Meteorologia) – Universidade Federal de Alagoas.  
Instituto de Ciências Atmosféricas. Maceió, 2019.

Bibliografia: f. 64-74.  
Anexos: f. 75-76.

1. Ventos. 2. Energia eólica. 3. Weather Research and Forecasting (Modelo atmosférico). 4. Redes neurais (Computação). I. Título.

CDU: 551.502



UNIVERSIDADE FEDERAL DE ALAGOAS  
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS  
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA

## CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-161.

“PREVISÃO DA VELOCIDADE DO VENTO NA ESCALA DO PARQUE  
EÓLICO UTILIZANDO O MODELO WRF E REDE NEURAL  
ARTIFICIAL .”

*Iwldson Guilherme da Silva Santos*

Dissertação submetida ao colegiado do Curso de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas - UFAL, como parte dos requisitos necessários à obtenção do grau de Mestre em Meteorologia.

Aprovado pela Banca Examinadora composta por:

Prof. Dr. Roberto Fernando da Fonseca Lyra  
(Orientador)

Prof. Dr. Rosiberto Salustiano da Silva Junior  
(Membro Interno)

Prof. Dr. Isnaldo Isaac Barbosa  
(Membro Externo)

Maio/2019

## DEDICATÓRIA

À minha família, DEDICO.

## AGRADECIMENTOS

Agradeço...

Primeiramente a **Deus** por ter me dado forças, coragem e disposição para conseguir chegar até o fim desta etapa acadêmica.

Em especial a minha mãe **Maria do O da Silva** pelo apoio, incentivo e segurança durante toda a minha vida.

Ao meu pai **Cícero Guilherme dos Santos** pela educação dada, as minhas irmãs **Isabel Cristina** e **Inaura Patrícia** que sempre acreditaram no meu potencial e sempre me estimularam a estudar mais.

Aos meus filhos **Italo Guilherme** e **Arthur Guilherme** dois motivos e razões que me fazem continuar a estudar e produzir conhecimento.

Ao Prof. **Roberto Lyra** pela paciência e amizade, por ter acreditado no meu potencial, pela orientação tornando possível a elaboração deste trabalho.

Ao Prof. **Rosiberto Salustiano** pelo acompanhamento e dicas na construção deste trabalho e pela disponibilização dos dados do modelo WRF.

Ao Prof. **Isnaldo Isaac** que me ajuda e incentiva desde graduação na matemática e aceitação para ser membro externo na minha banca de mestrado.

A **CAPES** pela ajuda financeira na concessão da bolsa de mestrado.

A todos da Meteorologia começando pelos amigos do mestrado e colegas da graduação, passando pela área burocrática, técnica e Limpeza, por fim a todos os professores do Instituto de Ciências Atmosféricas.

Família, amigos e a todos que me incentivaram, apoiaram e vibraram com minhas conquistas e que de alguma forma contribuíram de maneira direta ou indireta na realização deste trabalho deixo escrito os meus sinceros agradecimentos.

**Muito Obrigado!**

## **PENSAMENTO**

Diante do desafio de migrar da Matemática e adentrar no mundo da Meteorologia em busca de evolução pessoal, melhorar o currículo acadêmico e profissional, ampliar os conhecimentos, aumentar o leque de possibilidades para trabalhos futuros, etc. Concluo que fiz a escolha certa!

## RESUMO

SANTOS, Iwldson Guilherme da Silva. **Previsão da velocidade do vento na escala do parque eólico usando o Modelo WRF e Rede Neural Artificial**. Orientador: Prof. Dr. Roberto Fernando da Fonseca Lyra. Maceió AL, 2019, 76p. Dissertação (Mestrado em Meteorologia).

O objetivo deste trabalho é melhorar a previsão da velocidade do vento com antecedência de 24 horas, utilizando o modelo atmosférico WRF (*Weather Research and Forecasting*) com saídas a cada 10 minutos. Em adição, estas saídas são refinadas através de uma Rede Neural Artificial (RNA) não linear auto-regressiva com entradas externas (NARX) visando melhorar os prognósticos. Trata-se de um estudo com muitos testes e simulações computacionais. Os dados OBS são de uma torre anemométrica de 100 metros de altura do Projeto PVPN em 3 níveis (30, 50 e 100 m), mas foram utilizados somente os dados do nível 2 (50 metros) localizada no Município de Craíbas na região Agreste de Alagoas. A configuração do modelo para gerar os prognósticos WRF foi baseada em estudos recentes para regiões tropicais. As séries WRF e OBS são convertidas para o *software* computacional MATLAB para treinar, testar e validar a RNA-NARX. Na sequência o algoritmo extrapola uma série de dados que denominamos de RNA é a previsão da velocidade do vento a partir do *output* de treinamento. Os resultados mostraram que os prognósticos WRF feitos em intervalos de 10 minutos foram bem melhores do que o obtido em diversos estudos com médias horárias. O uso de RNA-NARX utilizando estes prognósticos, para fazer a previsão da velocidade do vento para o dia seguinte se mostrou uma opção viável. A velocidade média OBS foi de 5,30 m/s enquanto que as médias WRF e RNA foram de 5,20 m/s e 5,32 m/s respectivamente. Na comparação dos prognósticos RNA e WRF verificou-se o seguinte: Desvio médio quase nulo (-0,01 m/s versus -0,35); REQM inferior (1,18 m/s versus 1,24 m/s), coeficiente de correlação superior (0,70 versus 0,61). Ficou evidente que o período escolhido para o treinamento (3 dias) implica em erros grandes quando existe muita variabilidade na série OBS e/ou WRF.

**PALAVRAS - CHAVE:** Vento; Energia Eólica; Modelo WRF; Rede Neural Artificial (RNA).

## ABSTRACT

SANTOS, Iwldson Guilherme da Silva. **Wind speed forecast in the wind park scale using the WRF model and artificial neural network**. Advisor: Prof. Dr. Roberto Fernando da Fonseca Lyra. Maceió AL, 2019, 76p. Dissertation (Master's degree in Meteorology).

The objective of this work is to improve the prediction of the wind speed with 24 hours in advance, using forecast of the atmospheric model WRF (Weather Research and Forecasting) every 10 minutes. In addition, these outputs are refined through an Artificial Neural Network (ANN) nonlinear autoregressive with external inputs (NARX) to improve the WRF prognosis. This is a study with many tests and computational simulations. The OBS data were measured in an anemometric tower with measurements of wind speed and direction in 50, 70 and 100 meters. The tower was located at *Craibas* (Alagoas State, Brazil). The configuration of the WRF model to generate the simulated data was based on recent studies for tropical regions. The ANN training was done with the WRF and OBS initial series. Then, the algorithm makes the forecast of the wind velocity from the training output. The results showed that the WRF prognoses made at 10-minute intervals were much better than those obtained in several 60-minutes studies. The use of ANN-NARX using these prognoses to forecast the next day's wind speed proved to be a viable option. The mean velocity OBS was 5,30 m/s while the mean WRF e ANN were 5,20 m/s and 5,32 m/s respectively. In the comparison between ANN and WRF the following were observed: Mean deviation almost null (-0,01 m/s versus -0,35 m/s); Lower REQM (1,18 m/s versus 1,24 m/s); higher correlation coefficient (0,70 versus 0,61). It was evident that the chosen period for training (3 days) implies large errors when there is lot variability in the OBS and/or WRF series.

**KEY - WORDS:** Wind; wind energy; WRF model; artificial neural network (ANN).

## LISTA DE FIGURAS

|  |    |
|--|----|
| <b>Figura 1</b> - Top 10 de nova capacidade instalada de janeiro a dezembro de 2017 (esquerda).<br>Top 10 de capacidade acumulada em dezembro de 2017 (direita).....                 | 22 |
| <b>Figura 2</b> - Mapa do Brasil com destaque para os Estados produtores de energia eólica com o total de potência instalada MW e o número de parques eólicos em abril 2019.....     | 24 |
| <b>Figura 3</b> - Esquema geral de funcionamento de um aerogerador moderno.....  | 25 |
| <b>Figura 4</b> - Ilustração de um neurônio biológico.....   | 30 |
| <b>Figura 5</b> - Modelo matemático de um neurônio artificial.....   | 31 |
| <b>Figura 6</b> - Posição geográfica do Agreste alagoano com destaque para Craíbas.....  | 37 |
| <b>Figura 7</b> - Torre Anemométrica do Projeto PVPN em Craíbas.....   | 38 |
| <b>Figura 8</b> - Representação dos três domínios configurados no WRF.....   | 39 |
| <b>Figura 9</b> - Estrutura de neural do tipo recorrente.....  | 40 |
| <b>Figura 10</b> - Esquema da RNA - NARX utilizada no <i>toolbox</i> do MATLAB.....  | 42 |
| <b>Figura 11</b> - Evolução temporal da velocidade do vento a partir das médias diárias OBS (contínua), WRF (pontilhada) e RNA (tracejada) no período de 04/03/2015 a 04/07/2015.... | 47 |
| <b>Figura 12</b> - Desvios Médios entre os prognósticos WRF (vermelho) e RNA (azul) com relação aos dados OBS.....   | 48 |
| <b>Figura 13</b> - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 24/06/2015 a 27/06/2015.....          | 50 |
| <b>Figura 14</b> - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 27/06/2015 a 30/06/2015.....          | 51 |
| <b>Figura 15</b> - Frequências dos desvios RNA (preta) e WRF (cinza) em Craíbas, no período de 04/03/2015 a 04/07/2015.....  | 52 |
| <b>Figura 16</b> - Erro quadrático dos prognósticos WRF (pontilhada) e RNA (tracejada), em Craíbas, no período de 04/03/2015 a 04/07/2015.....                                       | 53 |
| <b>Figura 17</b> - Raiz do erro quadrático dos prognósticos WRF (pontilhada) e RNA (tracejada), em Craíbas, no período de 04/03/2015 a 04/07/2015.....                               | 54 |
| <b>Figura 18</b> - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 04/04/2015 a 07/04/2015.....          | 55 |

|   |    |
|---|----|
| <b>Figura 19</b> - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 09/04/2015 a 12/04/2015..... | 56 |
| <b>Figura 20</b> - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 16/04/2015 a 19/04/2015..... | 57 |
| <b>Figura 21</b> - Coeficiente de correlação dos prognósticos WRF (pontilhada) e RNA (tracejada), em Craíbas, no período de 04/03/2015 a 04/07/2015.....                    | 58 |
| <b>Figura 22</b> - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 28/06/2015 a 01/07/2015..... | 59 |

## LISTA DE TABELAS

|   |    |
|---|----|
| <b>Tabela 1</b> - Estados que produzem energia eólica, com o total de potência instalada em MW e o número de parques eólicos no Brasil em abril 2019.....   | 23 |
| <b>Tabela 2</b> - Processo de escolha dos parâmetros quantidade de neurônio na camada escondida e o número de dias anteriores a previsão.....   | 44 |
| <b>Tabela 3</b> - Parâmetros utilizados na avaliação de desempenho da RNA-NARX.....   | 44 |
| <b>Tabela 4</b> - Análise do CV de OBS e WRF entre os dias 24 a 27/06/2015.....   | 49 |
| <b>Tabela 5</b> - Resumo das médias das séries OBS, WRF e RNA e métricas estatísticas.....  | 60 |
| <b>Tabela 6</b> - Comparação dos resultados obtidos neste trabalho (Silva Santos, 2019) com os resultados obtidos de trabalhos que utilizaram o modelo WRF e/ou RNA na região central de Alagoas..... | 61 |

## LISTA DE SIGLAS, ABREVIATURAS E SÍMBOLOS

**UFAL** - Universidade Federal de Alagoas.

**ICAT** - Instituto de Ciências Atmosféricas.

**PPGM** - Programa de Pós-Graduação em Meteorologia.

**EE** - Energia Eólica.

**GW** - Giga Watt.

**MW** - Mega Watt.

**Mtep** - Mega tonelada equivalente de petróleo.

**TWh** - Tera Watt hora.

**GWEC** - Global World Energy Council.

**ABEEólica** - Associação Brasileira de Energia Eólica.

**AEA** - Atlas Eólico de Alagoas.

**RNA** - Rede Neural Artificial e/ou Dados RNA.

**NARX** - Não linear auto-regressiva com entradas Externas.

**WRF** - Weather Research and Forecasting e/ou Dados WRF.

**OBS** - Dados Observados.

**MATLAB** ó MATrix LABoratory.

**PVPN** - Previsão do vento em parques eólicos no Nordeste Brasileiro.

**r** - Coeficiente de Correlação.

**R<sup>2</sup>** - Coeficiente de Determinação.

**DESV**- Desvio Médio.

**EQM** - Erro Quadrático Médio.

**REQM** - Raiz do Erro Quadrático Médio.

**EPM**- Erro Percentual Médio.

**EAM** - Erro Absoluto Médio.

**RLM** - Regressão Linear Múltiplas.

**CFE** - Comissão Federal de Eletricidade.

**CCEE** - Centro de Controle de Energia Elétrica.

**Eta** - Modelo de previsão do tempo.

**NCAR** - National Center for Atmospheric Research.

**NOAA** ó National Oceanic and Atmospheric Administration.

**FSL** - Forecast Systems Laboratory.

**AFWA** - Air Force Weather Agency.

**NRL** - Naval Research Laboratory.

**FAA** - Federal Aviation Administration.

**BEN** - Balanço Energético Nacional.

**NWP** - Numerical Weather Prediction.

**MMM** - Mesoscale & Microscale Meteorology.

**NCEP** - National Centers for Environmental Prediction.

**BRAMS** - Brazilian developments on the Regional Atmospheric Modelling System.

**NEB** - Nordeste Brasileiro.

**UTC** - Coordinated Universal Time.

**MLP** - Multilayer Perceptron.

**FTDNN** - Focused Time Delay Neural Network.

**CEAR** - Centro de Energias Alternativas e Renováveis.

**LM** ó Levenberg - Marquardt.

**BPTT** - Backpropagation Through Time.

**CFD** ó Computational Fluid Dynamics.

**$u$  e  $v$**  - componentes horizontais da velocidade do vento.

- Coordenada *sigma*.
- Coordenada vertical *ETA*.

**$p_h$**  - Componente hidrostático de pressão.

**$p_{hs}$**  - Pressão no nível da superfície terrestre.

**$p_{ht}$**  - Pressão do topo do nível de referência.

**Z** - Variável de atraso temporal também conhecido como *delay*.

**CFSV2** - Climate Forecast System Version 2.

## SUMÁRIO

|   |             |
|---|-------------|
| <b>RESUMO</b> -----                                   | <b>VIII</b> |
| <b>ABSTRACT</b> -----                                 | <b>IX</b>   |
| <b>LISTA DE FIGURAS</b> -----                         | <b>X</b>    |
| <b>LISTA DE TABELAS</b> -----                         | <b>XII</b>  |
| <b>LISTA DE SIGLAS, ABREVIATURAS E SÍMBOLOS</b> ----- | <b>XIII</b> |
| <b>1 - INTRODUÇÃO</b> -----                           | <b>16</b>   |
| <b>2 - REVISÃO BIBLIOGRÁFICA</b> -----                | <b>18</b>   |
| 2.1 - Previsão do Vento-----                          | 18          |
| 2.2 - Energia Eólica-----                             | 21          |
| 2.3 - Modelo WRF-----                                 | 26          |
| 2.4 - Rede Neural Artificial-----                     | 29          |
| <b>3 - MATERIAIS E MÉTODOS</b> -----                  | <b>37</b>   |
| 3.1 - Área de Estudo-----                             | 37          |
| 3.2 - Dados Utilizados-----                           | 38          |
| 3.2.1 - Dados Observados-----                         | 38          |
| 3.2.2 - Dados WRF-----                                | 39          |
| 3.3 - RNA-NARX-----                                   | 40          |
| 3.4 - Resumo das etapas metodológicas empregadas----- | 41          |
| <b>4 - RESULTADOS E DISCUSSÃO</b> -----               | <b>46</b>   |
| 4.1 ó Velocidade média diária-----                    | 46          |
| 4.2 ó Desvios Médios-----                             | 47          |
| 4.3 ó Raiz do Erro Quadrático-----                    | 53          |
| 4.5 ó Coeficiente de Correlação-----                  | 58          |
| 4.6 ó Discussão dos resultados-----                   | 60          |
| <b>5 ó CONCLUSÃO</b> -----                            | <b>63</b>   |
| 5.1 ó Sugestões para trabalhos futuros-----           | 63          |
| <b>6 - REFERÊNCIAS BIBLIOGRÁFICAS</b> -----           | <b>64</b>   |
| <b>7 ó ANEXOS</b> -----                               | <b>75</b>   |

## 1 - INTRODUÇÃO

Os recursos energéticos necessitam de pesquisas que produzam conhecimentos que busquem suprir a alta demanda industrial e de consumo populacional, visando à conservação ambiental daquilo que se explora. Esta prática conduz a um melhor aproveitamento e uso mais sustentável dos recursos naturais (MARIANO, 2017). O desenvolvimento sustentável, mira utilizar os meios necessários para suprir as necessidades da humanidade, sem privar as gerações que virão se beneficiar dos recursos da natureza (LOPEZ, 2012). Nesse contexto, o vento é uma fonte de energia limpa, pois não libera substâncias poluentes para o meio ambiente, e através de uma determinada velocidade do vento pode-se produzir energia renovável que é abundante e inesgotável.

De acordo com o Balanço Energético Nacional 2018 (BEN, 2018), ano base 2017, o total de energia disponibilizada no país atingiu 292,1 Mtep (Mega tonelada equivalente de petróleo), registrando um acréscimo de 1,3% em relação a 2016. Parte deste aumento foi influenciada pela geração de energia eólica que atingiu 42,4 TWh (Tera Watt hora), representando um crescimento de 26,5%. A potência instalada eólica atingiu 12.283 MW (Mega Watt) expansão de 21,3% neste período. Devido às condições hidrológicas desfavoráveis, houve redução de 3,4% da energia hidráulica disponibilizada em relação a 2016. Apesar da menor oferta hídrica, a participação de energias renováveis na matriz elétrica atingiu 80,4% no ano base, fato explicado pelo avanço da geração eólica. Ou seja, a produção de energia originada dos ventos está se destacando cada vez mais na matriz energética brasileira compensando a vulnerabilidade às condições climáticas que as hidrelétricas têm.

A região Nordeste lidera a produção e consumo de energia eólica no Brasil, mas apesar disto Alagoas é o único Estado desta região que ainda não possui parque eólico. Com base no Atlas Eólico de Alagoas (AEA, 2008), o Estado tem potencial de produzir pelo menos 2/3 da energia elétrica que consome.

Diante do exposto, o desenvolvimento e o melhoramento de modelos de previsão de ventos com 24 horas de antecedência na escala de cada parque eólico é de extrema importância no que diz respeito à prospecção, produção e distribuição de energia elétrica de fonte eólica.

O objetivo deste trabalho é melhorar a previsão da velocidade do vento com antecedência de 24 horas, utilizando o modelo atmosférico WRF (*Weather Research and Forecasting*) com saídas a cada 10 minutos. Em adição, estas saídas são refinadas através de

uma Rede Neural Artificial (RNA) não linear auto-regressiva com entradas externas (NARX) visando melhorar os prognósticos.

## 2 - REVISÃO BIBLIOGRÁFICA

### 2.1 - Previsão do Vento

O vento, dentre muitas definições existentes, pode ser definido como massa de ar em movimento devido ao aquecimento e arrefecimento da superfície terrestre e diferença de pressão, desloca-se da alta para baixa pressão provocando o movimento horizontal do ar (LYRA *et al*, 2016). Para equilibrar essas diferenças de pressão o ar desloca-se de uma alta pressão em direção a uma baixa pressão, dando origem ao vento (BORBA, 2005).

A radiação solar provoca um aquecimento diferencial de porções de ar, criando os gradientes de pressão, geradores dos ventos que ocorrem tanto em escala local quanto global. Quando as massas de ar se deslocam próximas de uma superfície, elas têm a sua velocidade diminuída devido ao atrito com a superfície rugosa e uma camada limite na superfície é criada (AYOADE, 1998).

Segundo MOLION & BERNARDO (2002) o vento é resultante de variações de gradiente horizontais de pressão atmosférica produzido em várias escalas espaciais, é uma das variáveis meteorológicas mais relevantes, pois é responsável pelo transporte horizontal (advecção) de calor latente e de calor sensível.

Os métodos de previsão da velocidade do vento podem ser agrupados em duas categorias: modelos baseados na análise de séries históricas do vento e aqueles que usam modelos numéricos de previsão climatológica (*Numerical Weather Prediction* ó NWP). A classificação dos métodos de previsão de vento considerando a escala de tempo não é completamente clara (SOMAN *et al*, 2010), a previsão do vento pode ser separada nas seguintes categorias:

- Previsões de curtíssimo prazo são as compreendidas no espaço de tempo de poucos minutos à frente;
- Previsões de curto prazo são as que têm um horizonte de tempo de até 72 horas ou 3 dias à frente;
- Previsões de médio prazo são as compreendidas no espaço de tempo de no máximo 10 dias à frente;
- Previsões de longo prazo são feitas no espaço de tempo acima de 10 dias à frente.

A previsão do vento tem implicações na capacidade de despacho de energia elétrica pelas linhas de transmissão, pois é um dos principais parâmetros meteorológicos que controlam a capacidade de dispersão do calor gerado devido ao aquecimento destas linhas pelo Efeito Joule. Previsões de vento melhores podem trazer outros benefícios à sociedade, principalmente para aeroportos, atividades esportivas e no lazer em geral. Além disso, dada a perspectiva de que a capacidade eólica - elétrica no Brasil instalado chegue a 3% do total por volta de 2014, órgãos ligados ao governo já se pronunciaram quanto à necessidade de uma ferramenta nacional confiável de previsão de potência eólica disponível em curto prazo (LOPES, 2010).

Aumentar a eficiência das previsões de vento auxilia no planejamento e produção da usina eólica, minimizando perdas. Com isso, é fundamental que grupos nacionais de pesquisa busquem desenvolver técnicas próprias para estudos eólicos. Além de enriquecer o corpo científico brasileiro, é imprescindível para formação de mão de obra qualificada, desenvolvimento tecnológico, entre outros benefícios. Os principais estudos atualmente buscam o aperfeiçoamento da previsão do vento em curto prazo, seja utilizando modelos atmosféricos (SILVA JÚNIOR *et al.*, 2010; OLIVEIRA, 2011; SILVA, 2011; RAMOS, 2012; IHADUA, 2014; MARIANO, 2017), ou outras ferramentas, como rede neural artificial (GONÇALVES, 2011; KANI *et al.*, 2011; MOURA, 2014; MARTINIANO, 2016; COSTA, 2016).

SILVA (2011) investigou as características do vento, visando principalmente o aproveitamento do recurso eólico, em 4 locais do Estado de Alagoas onde estão localizadas as torres anemométricas duas no litoral (Maragogi e Roteiro) e duas no interior sendo uma no Agreste (Girau do Ponciano) e uma no Sertão (Água Branca) no ano de 2008. O autor determinou a velocidade e a direção preferencial dos ventos, e posteriormente a quantidade esperada de energia e o fator de capacidade. Foi realizado através de distribuição de Weibull, o tratamento estatístico da velocidade do vento com auxílio do programa WAsP (*Wind Atlas Analysis and Application Program*) para uma altura de 50 m e área de 10x10 km. Os resultados mostraram que a direção do vento tem pouca variabilidade para as regiões estudadas e foram predominantemente de Sudeste e Leste-Nordeste. Dentre os sítios analisados o que mais se destacou foi o de Girau de Ponciano com estimativa de energia anual gerada de 7,97 GWh, fator de capacidade acima de 55% e potência local estimada pelo aerogerador foi superior a 500 W/m<sup>2</sup>.

JIANG *et al.* (2013) em seu trabalho utilizaram um novo método de séries temporais

para previsão da velocidade do vento de curto prazo. O modelo de previsão integra os conceitos de quebras estruturais e inferências Bayesianas, o que permite que a informação antecipada da velocidade do vento seja incorporada ao modelo que de certa forma aumenta o desempenho da previsão. Resultados computacionais confirmaram as vantagens deste modelo, superando todos os outros modelos usados pelo autor, com exceção da previsão feita pela RNA que em alguns casos proporcionou previsões bastante confiáveis.

DA CRUZ, LYRA & FILHO (2017) analisaram o comportamento do vento na zona rural do município de Craíbas região central de Alagoas e investigaram a variabilidade do local em termos de aproveitamento eólico. Foram usados dados do Projeto PVPN correspondentes ao período de abril de 2014 a março de 2015 para análise descritiva da velocidade do vento à 100 m. Os resultados mostraram que a velocidade média mensal variou entre 5,4 m/s e 7,7 m/s, com máximo em outubro de 2014. A direção do vento não demonstra variações bruscas ao longo do ano, com direção predominante de SE. A pequena variabilidade na direção do vento e a intensidade constante da velocidade do vento indicam Craíbas como uma ótima opção para a instalação de aerogeradores.

MICALICHEN (2018) investigou boas técnicas de extrapolação da velocidade vertical do vento para alturas superiores a 10 m. Com séries de dados de reanálise do modelo *Climate Forecast System Version 2* (CFSV2) vindas dos *National Centers for Environmental Prediction/National Center for Atmospheric Research* (NCEP/NCAR) e com dados medidos em uma torre localizada em Minas Gerais. Foram estimados valores do comprimento de rugosidade para o uso da previsão da velocidade do vento e o que produziu melhores resultados para o local da torre citada foi  $Z_0$  de 0,15 m. Para estimar a velocidade do vento foram analisados três modelos, um deles é o perfil logaritmo e os outros dois utilizam funções de correção de estabilidade atmosférica e depois as estimativas geradas por cada um desses modelos são comparadas com os dados observados pela torre meteorológica. Os resultados dos índices estatísticos mostram que a estimativa da velocidade do vento para a altura de 50 m com o uso do perfil logaritmo gerou uma REQM de 3,22 m/s para todo o conjunto de dados e um coeficiente de correlação de 0,30. A melhor estimativa com função de estabilidade gerou uma REQM de 2,18 m/s para todo o conjunto de dados e um coeficiente de correlação de 0,64.

SILVA (2018) desenvolveu uma metodologia para melhorar a estimativa da velocidade do vento a partir de dados de torres anemométricas, via implementação de uma ferramenta para determinação dos parâmetros aerodinâmicos ( $d$ ,  $Z_0$ ) e do expoente da equação

mais usada na engenharia eólica: lei da potência ( ). Foram utilizados dados de velocidade do vento medidos em 5 torres anemométricas localizadas nas 3 mesorregiões do Estado de Alagoas. Foi implementado um algoritmo para filtrar os dados de vento e melhorar a sua estimativa com a altura em parque eólico. Este algoritmo acabou se mostrando uma ferramenta importante para o estudo do escoamento uma vez que o filtro revela os casos de comportamento atípico do vento. Os resultados mostraram que a velocidade e a direção do vento possuem padrão anual e que a velocidade no interior é maior do que no litoral. Os ventos são mais fortes na estação seca e mais fracos na estação chuvosa, com direção predominante de SE.

## 2.2 - Energia Eólica


Energia Eólica é a transformação da energia cinética dos ventos em energia útil, tal 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, é renovável e limpa, não produz gases de efeito de estufa durante a produção, requer menos terreno e o impacto ambiental é geralmente menos problemático do que de outras fontes de energia como a hidrelétrica (FTHENAKIS, VASILIS e HYUNG CHUL, 2009).

LIMA, SANTOS & MOIZINHO (2018) em um trabalho sobre energia eólica no Brasil abordando oportunidades e limitações para o desenvolvimento sustentável. As autoras buscaram analisar o contexto atual da produção de energia eólica no Brasil, ressaltando elementos da sustentabilidade presentes nessa fonte energética. Foi realizada uma revisão da literatura sobre a temática de estudo, especialmente no que diz respeito a importância da expansão da energia eólica no Brasil. Os resultados mostraram que a energia eólica está em pleno desenvolvimento no território brasileiro, em decorrência da implantação das políticas públicas e incentivos, o que pode ser constatado pelas melhorias constantes na cadeia produtiva desse setor.

O *Global Wind Energy Council* (GWEC) informa que China, EUA e Alemanha, nesta ordem, são os três países que mais investem em energia eólica no mundo. Como pode ser visto nos gráficos (Figura 1) sobre a produção global de energia eólica dos países que mais produziram capacidade instalada seja ela nova ou acumulada em 2017. Observa-se também

que o Brasil produziu 2 GW (4% do total global) ficando na 6º posição em nova capacidade instalada. O país ultrapassou o Canadá passando de 9º para o 8º atingindo 12,8 GW (2% do total global) em capacidade instalada acumulada.

**Figura 1 - Top 10 de nova capacidade instalada de janeiro a dezembro de 2017 (esquerda). Top 10 de capacidade acumulada em dezembro de 2017 (direita).**



Fonte: GWEC, 2018.

De acordo com os dados da Associação Brasileira de Energia Eólica (ABEEólica) o Brasil hoje tem 15,1 GW (Giga Watt) de capacidade instalada de energia eólica, em 601 parques eólicos e mais de 7.000 aerogeradores em 12 estados. Os números são referentes ao mês de abril. A Tabela 1 abaixo mostra a distribuição desse montante por região no Brasil em 2019.

**Tabela 1 - Estados que produzem energia eólica, com o total de potência instalada em MW e o número de parques eólicos no Brasil em abril 2019.**


| Estado (Sigla) | Potência (MW) | Nº de parques eólicos |
|----------------|---------------|-----------------------|
| RN             | 4.066,15      | 151                   |
| BA             | 3.934,99      | 153                   |
| CE             | 2.045,46      | 79                    |
| RS             | 1.831,87      | 80                    |
| PI             | 1.638,10      | 60                    |
| PE             | 781,99        | 34                    |
| MA             | 328,80        | 12                    |
| SC             | 238,50        | 14                    |
| PB             | 157,20        | 15                    |
| SE             | 34,50         | 1                     |
| RJ             | 28,05         | 1                     |
| PR             | 2,50          | 1                     |

**Fonte: ABEEólica, 2019.**

O Nordeste é referência na produção de energia eólica no Brasil. No dia 13 de setembro de 2018, cerca de 74% da energia consumida nesta região veio dos ventos, com geração média diária de 7.839 MW. Este é o dado mais recente de recorde histórico de abastecimento energético atendido pela fonte eólica (ABEEólica, 2018).

De acordo com a Figura 2, o Nordeste aparece à frente na capacidade de produção de energia eólica no Brasil dos 12 estados produtores de energia eólica 8 são do Nordeste. O Rio Grande do Norte, com 151 parques, é o estado que mais produz, são 4 GW de capacidade instalada. Em seguida, está a Bahia, com 153 parques, sendo o Estado com o maior número de parques eólicos e 3,9 GW de potência instalada. Em terceiro lugar, está o Ceará que conta com 79 parques e um total de 2 GW de capacidade instalada. Em quarto lugar, aparece o Rio Grande do Sul com 80 parques e 1,8 GW. E em quinto lugar está o Piauí com 60 parques e um total de 1,6 GW de capacidade instalada (ABEEólica, 2019).

**Figura 2 - Mapa do Brasil com destaque para os Estados produtores de energia eólica com o total de potência instalada MW e o número de parques eólicos em abril 2019.**



**Fonte: Adaptada do LIMA, SANTOS e MOIZINHO, 2018.**


As fontes de energia renováveis não competem entre si, algumas delas se complementam. É o caso da energia eólica. Esta fonte renovável é extremamente estratégica para o Brasil, especialmente durante as secas, de maio a novembro, quando o volume dos reservatórios fica comprometido pela falta de chuvas. É justamente nesse período, de junho a novembro, denominados de "Safrã dos Ventos", que as ventanias ficam mais fortes, favorecendo o aumento da geração de energia eólica (LETRAS AMBIENTAIS, 2018).

MARIANO (2017) utilizou o modelo BRAMS nas três mesorregiões da Paraíba no período de 1 a 31 de outubro de 2010 para instalação de parque eólico no nordeste setentrional oriental do Brasil. Os dados de entrada são do NCEP. Reanálise do ERA-Interim, com resolução espacial de 0,75° x 0,75° foram utilizadas como uma segunda fonte de dados para o mesmo propósito. Nesta comparação, foram feitas correlações e aplicados testes de significância estatística, assim como, avaliação dos parâmetros de forma e escala da distribuição de Weibull. Foram avaliadas as variações sazonais e interanuais da velocidade do vento em quatro cidades com parques eólicos instalados. Os resultados apontam coeficientes de correlações acima de 0,70 com significância estatística de 99%. Na distribuição de

Weibull, os parâmetros de forma e de escala mostraram-se próximos aos obtidos dos dados observados. Na variação sazonal, o mês de setembro apresentou velocidades do vento mais intensas e menos intensas em março, com valores intermediários verificados em junho e dezembro. Com os resultados obtidos o uso da simulação de Densidade de Potência Eólico (DPE), utilizando o modelo BRAMS pode ser aplicado em qualquer região da América do Sul.

De acordo com o princípio de conservação de energia, considerando algumas perdas entre os processos, basicamente um aerogerador converte energia a partir de dois processos. Inicialmente a energia cinética do vento é transformada em energia mecânica e posteriormente em energia elétrica que será distribuída para rede elétrica, como pode ser visto na Figura 3. O vento atinge as pás do rotor que se movimentam. Esse movimento é transferido para um sistema de engrenagens que multiplicam a frequência do rotor. Essa velocidade é transmitida para o gerador elétrico responsável por produzir a eletricidade por meio do fenômeno de indução eletromagnética (PICCOLO, BUHLER & RAMPINELLI, 2014).

**Figura 3 - Esquema geral de funcionamento de um aerogerador moderno.**



Fonte: PICCOLO, BUHLER e RAMPINELLI, 2014.

### 2.3 - 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 trabalho. 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. WRF é utilizado para modelagem em meso escala 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 (OLIVEIRA, 2006).

O modelo foi desenvolvido através da parceria entre diversos institutos dos Estados Unidos da América: *National Center for Atmospheric Research* (NCAR); *Mesoscale & Microscale Meteorology* (MMM); *National Oceanic and Atmospheric Administration* (NOAA); *National Centers for Environmental Prediction* (NCEP); *Naval Research Laboratory* (NRL); *Federal Aviation Administration* (FAA) e Universidade de Oklahoma (SKAMAROCK, KLEMP, *et al.*, 2008). Os mesmos autores descrevem detalhadamente toda a sua estrutura física e computacional, além de outras informações específicas.

Sua assimilação de dados é baseada em uma grande gama de tipos de diferentes dados observados sejam por satélites e bóias marinhas, a sondagens atmosféricas e radares. Os domínios espaciais de execução podem ir desde alguns metros (microescala) até milhares de metros (escala planetária). Diversos tipos de resultados podem ser obtidos através de suas simulações, como análise de dispersão de poluentes, previsão de eventos extremos, parâmetros de interação oceano-atmosfera, sistemas sinóticos, etc.

O grupo de pesquisa em Micrometeorologia da UFAL vem desenvolvendo desde 2010 o projeto PVPN (Previsão do vento em parques eólicos no nordeste brasileiro). Nele foram testados os modelos WRF e BRAMS (*Brazilian developments on the Regional Atmospheric Modelling System*), tendo as saídas do WRF superiores em termos de acerto. O modelo WRF consegue gerar bons resultados em suas simulações, dependendo do esquema de parametrização utilizado, porém podem ser melhorados através de refinamentos, pois a comparação entre dados WRF e observados pode sofrer perda de precisão devido a diversos fatores, como por exemplo: distância do ponto de grade da estação meteorológica, diferença

entre hora local e hora UTC (*Coordinated Universal Time*), efeito de rugosidade, topografia ou mesmo diferença de altura na medição.

RAMOS (2012) descreveu uma metodologia para elaboração do mapeamento do potencial eólico em Alagoas, baseando-se no uso de medições anemométricas do período de agosto de 2007 a julho de 2008, além da modelagem atmosférica de mesoescala (WRF), simulações espaciais em microescala (WAsP) e sistemas de informações geográficas (SIG). As estações anemométricas foram distribuídas geograficamente nas 3 mesorregiões do Estado: Sertão (Água Branca), Agreste (Girau do Ponciano e Palmeira dos Índios) e Litoral (Feliz Deserto, Maragogi e Roteiro). Os resultados mostraram que houve maior eficiência do WRF nas simulações da velocidade do vento para o sertão e agreste alagoano, com erro inferior a 1 m/s. A direção do vento do WRF foi calculada com acurácia adequada em todos os sítios, sendo dominante de leste a nordeste no agreste. O mapa eólico anual do WRF para Alagoas apontou áreas com propício potencial energético, cuja magnitude do vento varia entre 7 a 9 m/s em 50 m de altura.

COUTO (2013) utilizou o modelo WRF para analisar a velocidade e a direção do vento em dois diferentes esquemas físicos de Camada Limite. O autor observou que as simulações representaram de forma satisfatória as duas variáveis durante o período de estudo do dia 15 até o dia 22 de abril de 2011. Os dados simulados foram comparados com dados observados de uma torre anemométrica de 10 metros de altura e média a cada 10 minutos. Esses dois esquemas do WRF obtiveram boa concordância entre os modelos e os dados observados, como podem ser vistos através das métricas estatísticas a seguir:  $r$  igual a 0,73 e 0,76, DESV de 1 e 0,54, EAM igual a 1,22 e 0,93, REQM de 1,44 e 1,13 para a velocidade do vento. E para a direção do vento os resultados foram:  $r$  de 0,54 e 0,57, DESV de -17 e -16, EAM de 26 e 26, REQM de 38 e 37.

OLIVEIRA (2013) realizou simulações numéricas com os modelos BRAMS e WRF a fim de analisar o potencial eólico do estado da Paraíba destacando as regiões onde o comportamento dos ventos é mais favorável à geração de energia elétrica. Os resultados das simulações realizadas para um período de três anos sugerem que o vento, nas quatro estações, tende a ser mais intenso no interior do Estado que nas demais regiões, sendo a primavera a estação que apresenta ventos de maior intensidade. As torres anemométricas estão localizadas nas mesorregiões do Agreste, Borborema e Sertão. Os resultados encontrados indicam que as áreas analisadas apresentam densidade de potência média diária acima de 100 W/m<sup>2</sup> a 10 m, crescente com a altura. Além disso, revelam que para o agreste o WRF acompanha as

variações de velocidade média de forma mais concisa a 70 m e 100 m de altura, ao passo que para a Borborema os ciclos reproduzidos pelo BRAMS mostraram-se mais próximos dos ciclos observados. De modo geral, os dados observados e simulados por ambos os modelos apresentaram uma forte correlação com significância estatística de 99% de acordo com o teste estatístico aplicado.

IHADUA (2014) em seu trabalho de conclusão de curso avaliou os prognósticos de vento gerado pelo modelo WRF na região de Girau do Ponciano, Agreste de Alagoas. Os prognósticos WRF são confrontados com os dados de medições anemométricas, entre dezembro de 2007 a novembro de 2008, as métricas estatísticas foram analisadas através de cálculo de BIAS, desvio padrão e coeficiente de variação. Os resultados mostraram que o modelo WRF tem certa dificuldade de simular com precisão os dias atípicos, teve revés em apresentar os mínimos picos de vento na estação seca e em simular os períodos de máxima velocidade do vento na estação chuvosa, mas acompanhou o padrão do vento dos dados observados.

LYRA *et al* (2016) utilizou o modelo WRF na região central de Alagoas no intervalo de 10 dias (22 a 31 de março de 2015) com dados a cada 10 minutos. O trabalho foi elaborado com o objetivo de desenvolver uma metodologia para a previsão de curto e médio prazo da energia do vento em parques eólicos, adequada a região Nordeste brasileira. Foram feitas medidas anemométricas e micro meteorológicas incluindo os fluxos turbulentos. Foram comparadas as estimativas feitas pelo WRF para a velocidade do vento, velocidade de fricção e os fluxos de calor sensível e de calor latente. Os resultados mostraram que o modelo representou bem os ciclos diários das quatro variáveis com coeficientes de correlação entre 0,79 e 0,94. As estimativas da velocidade do vento foram muito boas com diferença de apenas 10,55%.

JATOBÁ *et al* (2017) utilizou o modelo WRF em alta resolução no município de Craíbas agreste de Alagoas para melhor detalhamento na avaliação dos ventos sendo feita a atualização da topografia e uso do solo. Foram utilizadas as variáveis: velocidade e direção do vento, temperatura, umidade relativa. Métodos estatísticos: Média, desvio padrão e correlação de Pearson. A simulação da geração de energia por um aerogerador fictício resultou na quantidade de casas abastecidas pela soma do potencial dos ventos atendeu o número de 543 a 952.

PINTO (2017) avaliou o modelo WRF para aplicação em previsão de recursos eólicos

no NEB. A autora apresentou uma série de testes de sensibilidade realizados com o WRF configurado com diferentes parametrizações físicas (camada limite, convecção, microfísica e radiação). O modelo foi configurado com 3 domínios (grades) de resolução 5 x 5 km sobre o NEB. O período de estudo foi de 2008 a 2013 e a localização das grades foram a partir de dados observados em 121 estações meteorológicas automáticas operadas pelo INMET. Os resultados mostraram que independente das parametrizações adotadas, há uma forte tendência a superestimação da intensidade dos ventos pelo modelo WRF. Algumas parametrizações mostraram-se mais adequadas para um domínio do que para outro, em função do NEB ser influenciado por diferentes sistemas meteorológicos. Foram realizadas comparações entre previsões do modelo WRF com dados medidos nas torres anemométricas. Os valores dos índices estatísticos (REQM e Viés) das previsões da velocidade do vento para os níveis das torres continuam elevados. O estudo mostrou a dificuldade dos modelos numéricos de meso escala para prever a velocidade do vento, mas apesar disso quando configurado corretamente pode contribuir de forma importante na obtenção de informações confiáveis do vento e consequentemente serem uma informação disponibilizada com confiabilidade para o setor de energia eólica.

#### 2.4 - Rede Neural Artificial


Rede Neural Artificial (RNA) são modelos computacionais desenvolvidos para reproduzirem as atividades de um sistema nervoso humano. Com capacidade de aquisição e manutenção do conhecimento podem ser definidos como um conjunto de unidades de processamento, caracterizada por neurônios artificiais, são interligados por um grande número de interconexões, sendo representados por vetores de pesos sinápticos. Sua arquitetura, de forma mais simples, é dotada de uma camada de entrada, camadas escondidas (intermediárias, ocultas ou invisíveis) e uma camada de saída (SILVA *et. al.*, 2010).

As RNAs podem ser definidas como técnicas computacionais constituídas por neurônios matemáticos, em que cada neurônio artificial tem uma estrutura que se assemelha a de um neurônio biológico. Para propósitos de comparação, uma rede neural artificial pode chegar a ter centenas ou milhares de unidades de processamento enquanto que o cérebro de um mamífero, por exemplo, pode ter bilhões de neurônios (BRAGA, 2012).

Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões. O cérebro humano, representado pela rede neural (nervosa), é constituído por estruturas, neurônios, que interagem entre si, armazenando e tomando decisões adequadas a partir das informações recebidas (SHEPHERD, 2003).

Um neurônio biológico Figura 4 é composto por um corpo celular (ou soma), um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos (zonas receptivas) formam uma malha de finíssimos filamentos ao redor do corpo celular. Ao passo que o axônio (linhas de transmissão) consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse, que tem como papel fundamental a memorização da informação (MATSUNAGA, 2012).

**Figura 4 - Ilustração de um neurônio biológico.**




**Fonte: REMES, 2013.**

O modelo de neurônio artificial simples e que engloba as principais características de um neurônio biológico, tal como, paralelismo e alta conectividade, foi proposto por McCulloch & Pitts (1943). Desta forma, o modelo matemático de um neurônio artificial simples é formado por um conjunto de entradas, uma unidade de processamento e uma ou mais unidades de saídas, correspondendo aos dendritos, corpo celular e axônios do neurônio biológico. Portanto, o modelo matemático de um neurônio artificial é mostrado na Figura 5.

As informações da Figura 5 são definidas da seguinte forma: O conjunto de dados  $\{x_1, x_2, \dots, x_n\}$  advindas do meio externo são os sinais de entrada; Os valores  $\{w_1, w_2, \dots, w_n\}$  são os pesos sinápticos; O símbolo somatório  $\{\Sigma\}$  é o combinador linear; Limiar de ativação  $\{\theta\}$  também conhecido como bias; O resultado produzido entre o combinador linear e o limiar de ativação é chamado de potencial de ativação  $\{u\}$ ; A função de ativação  $\{g(\cdot)\}$  usada para limitar a saída do neurônio; E o sinal de saída  $\{y\}$  que consiste do valor final produzido pelo neurônio (SILVA, SPATTI & FLAUZINO, 2010).

**Figura 5 - Modelo matemático de um neurônio artificial.**



Fonte: SILVA, SPATTI & FLAUZINO, 2010.

MABEL & FERNANDEZ (2008) usaram dados de sete parques eólicos em Muppandal e Tamil Nadu na Índia, coletados por três anos, de abril de 2002 a março de 2005, para estimativa do rendimento destes parques eólicos. Usaram RNA e os parâmetros de entrada foi velocidade média do vento, umidade relativa do ar e horas de geração, e uma variável de saída que é a energia produzida pelos parques eólicos. O algoritmo de treinamento é baseado na técnica de retro propagação e a configuração da rede neural mais apropriada após a tentativa e erro é de 3-5-1 (3 neurônios na camada de entrada, 5 neurônios na camada oculta e 1 neurônio na camada de saída). A precisão do modelo foi avaliada aferindo os resultados dos prognósticos WRF com os dados observados mensurados nos parques eólicos. O erro quadrático médio para os valores estimados em relação aos dados medidos é de  $7,6 \times 10^{-3}$ , cerca de 1,6% de concordância entre os dados. Os resultados demonstram que este

trabalho é uma ferramenta eficiente de estimativa de rendimento energético para parques eólicos. De acordo com os resultados a produção de energia prevista para os parques eólicos usando o modelo de rede neural artificial mostra uma boa concordância com os dados reais.

RODRIGUES (2008) fez previsão de ventos locais em ambiente urbano conjugando CFD (*Computational Fluid Dynamics*) e RNA para fonte de energia alternativa e consumo doméstico. O autor quis demonstrar a eficácia da utilização de RNA na previsão de ventos em cima dos topos de 5 edifícios. Foi demonstrado que os resultados da simulação CFD eram próximos aos resultados experimentais do túnel de vento, particularmente para cotas superiores às alturas dos edifícios. A rede neural foi projetada, cujos *inputs* de treinamento eram as alturas dos 4 edifícios a montante e o *output* a velocidade no topo do quinto edifício. Foram comparados os resultados de valores que não tinham sido usados no treino da rede (desconhecidos) e a rede demonstrou prever velocidades de vento com erros na ordem de 5%.

CADENAS & RIVERA (2009) usaram RNA para prever a velocidade do vento de curto prazo na região de La Venta, Oaxaca, México. Os dados foram coletados pela Comissão Federal de Eletricidade (CFE) durante 7 anos através de uma rede de estações. Os autores utilizaram diversas configurações de RNA para serem comparadas através de medidas de erro, garantindo o desempenho e a precisão dos modelos escolhidos. O modelo mais simples de duas camadas, com dois neurônios de entrada e um de saída, foi o melhor para previsão da velocidade do vento de curto prazo, as métricas estatísticas de treinamento foram EQM e EAM de 0,0016 m/s e 0,0399 m/s, respectivamente. O modelo desenvolvido para a previsão da velocidade do vento de curto prazo mostrou uma precisão muito boa para ser usada pelo Centro de Controle de Energia Elétrica (CCEE) em Oaxaca para o fornecimento de energia.

FREIRE *et al* (2009) em um estudo comparativo entre diferentes arquiteturas de redes neurais artificiais para predição de séries temporais caóticas. As RNAs foram treinadas com algoritmos de aprendizagem Levenberg - Marquardt (LM) ou *Backpropagation Through Time* (BPTT) e fazem a mesma tarefa. Os resultados mostraram que o modelo de rede recorrente apresentou um desempenho melhor quando comparado com modelo de rede MLP.

GONÇALVES (2011) desenvolveu um modelo de refinamento estatístico para previsão de vento em curto prazo para a região Nordeste, com dados de 8 estações anemométricas sendo 5 de Alagoas, com uso de Regressões Lineares Múltiplas (RLM) e RNA alimentadas por saídas do modelo de previsão do tempo Eta. A previsão de vento próximo a superfície é discutida sob aspectos observacionais e de modelagem, onde é feita

uma ampla avaliação dos possíveis preditores do modelo Eta. Uma metodologia de refinamento estatístico das previsões numéricas de vento é proposta e seu desempenho é comparado às saídas originais do modelo Eta e RLM para previsões de vento a 50 m e de potência eólica a 80m. O refinamento por RNA foi ligeiramente superior ao uso de RLM e ambos foram superiores em relação às saídas do Eta. As correlações obtidas para o vento variam de 0,75 a 0,90 e o REQM entre 0,93 m/s e 1,39 m/s. Para a potência eólica o REQM varia entre 10,3% e 17,2% da potência disponível, enquanto o ganho de potência garantida para uma probabilidade de 90% chega a 35% da potência disponível em relação às previsões do Eta não refinadas.

BEZERRA *et al* (2011) em seu trabalho fez uma previsão de curto prazo da velocidade do vento através da comparação de resultados entre redes neurais artificiais NARX e FTDNN, da sigla em inglês *Focused Time Delay Neural Network* que é uma rede *Feedforward Multilayer Perceptron*, e de modelos estocásticos (AR, ARMA e ARIMA) tendo como referência os resultados obtidos através do modelo de persistência. Os autores concluíram que utilizando somente os dados da velocidade do vento os modelos de previsão feitos com RNA apresentaram resultados próximos da realidade e que para todos os horizontes de tempo o modelo NARX obteve melhor resultado que o FTDNN.

ZHAO *et al* (2012) avaliou o desempenho e aprimorou a precisão de um sistema de previsão de energia eólica para o dia seguinte na China. O sistema consiste em RNA e um modelo de previsão numérica do tempo que é estabelecido pelo acoplamento do Sistema Global Forecasting (GFS) com o modelo WRF para prever parâmetros meteorológicos. Os resultados numéricos comprovam a eficácia deste sistema de previsão em termos da correção da velocidade do vento bruta e precisão da previsão da energia eólica. O erro quadrático médio da raiz normalizada (NRMSE) teve um valor médio mensal de 16,47%, que é uma margem de erro aceitável para permitir o uso dos valores previstos nas operações do mercado elétrico.

COSTA (2013) utilizou modelos de previsão de séries temporais para prever a produção de energia elétrica a partir da energia eólica em Cabo Verde, particularmente na ilha de Santiago. O autor utilizou os modelos Holt ó Winters, ARIMA e RNA com função Base Radial (RNA ó RBF) e *Perceptron* de múltiplas camadas (RNA - MLP). Neste trabalho propõe-se a realização de uma análise comparativa desses modelos não ó lineares para a previsão para encontrar qual modelo que melhor se adapta à série temporal. Os resultados

mostraram que os modelos de RNA foi o que apresentou o melhor EM de -0,175 e -0,151 e EPAM de 29,528 e 35,902 para RNA ó MLP e RNA ó RBF, respectivamente.

ROSSI (2014) desenvolveu uma metodologia híbrida utilizando RNA (*Perceptron* de multicamadas) e modelo estatístico ARIMA com abordagem de Box e Jenkins, com o objetivo de prever séries temporais de velocidade dos ventos. Os modelos estatísticos ARIMA realizam a previsão das séries de dados, que ainda conservam os padrões lineares, juntamente com a rede MLP e o algoritmo de aprendizagem retro propagação que, através do erro de previsão obtido, desenvolvem um Modelo Híbrido aditivo para previsão de séries temporal. Os testes de validação foram realizados com dois bancos de dados. Teste 1 com dados agrometeorológicos na região de Ilha Solteira ó SP. Teste 2 dados do projeto SONDA em alturas de 25 e 50 metros. Os resultados mostraram que o modelo estatístico ARIMA e RNA isolados não obtiveram resultados satisfatórios, mas quando houve uma junção entre os modelos para desenvolver um modelo híbrido obtiveram bons resultados através do EPAM = 3,75% para o teste 1 e 22,48% para o teste 2.

KOO *et al* (2015) usaram RNA para investigar a precisão da previsão da velocidade do vento através de dados de estações de referência em locais designados da Coréia do Sul. Os autores dividiram os locais de referência e de destino em três categorias geográficas: planícies, costa e montanhas. A precisão das previsões da velocidade do vento é calculada por meio de coeficiente de correlação entre os dados reais e previstos pela RNA. Investigou-se também o efeito das características geológicas de cada categoria e a distância entre os locais de referência e de alvo para a previsão da RNA. O melhor coeficiente de correlação foi de 0,74 está na planície 1 conhecida como Seobu distante 12,32 km da estação e possui velocidade média do vento de 1,7m/s.

COSTA (2016) em seu trabalho utilizou redes neurais artificiais do tipo *Multilayer Perceptron* usando o algoritmo *Backpropagation* para desenvolver modelos de predição da velocidade do vento. Foram criados onze modelos de predição, cujos dados utilizados para treinamento, validação e testes envolveram combinações entre horário de medição, temperatura, umidade e pressão atmosférica coletados da estação meteorológica do Centro de Energias Alternativas e Renováveis (CEAR) do campus de João Pessoa da UFPB entre o período de 2009 a 2013. O melhor modelo de rede neural artificial teve como dados de entrada a combinação de temperatura, umidade e pressão, cuja configuração da rede foi de 3 neurônios na camada de entrada, 35 neurônios na primeira e segunda camadas ocultas e 1 neurônio na camada de saída. Obtendo um MSE (da sigla em inglês Mean Square Error) de

0,05. O valor do MAPE (Mean Absolute Percentage Error) de 6,68 e o Coeficiente de Correlação de 0,79.

CAMELO *et al* (2017) utilizou RNA e o modelo ARIMAX (Auto Regressivo integrado de Médias Móveis com entradas de Variáveis Exógenas) para prever a velocidade do vento (médias mensais e horárias) através de modelagem híbrida no nordeste brasileiro. O autor relacionou pressão, temperatura, precipitação e velocidade do vento como variáveis meteorológicas obtendo os resultados EPM de 5,0% e coeficiente de eficiência Nash - Sutcliffe de 0,96. Confirmando a existência de precisão para as velocidades dos ventos previstas acompanhando o perfil de suas observações, em especial é possível identificar semelhanças em ambas às séries temporais (em termos de valores máximos e mínimos), mostrando assim, a capacidade do modelo em representar características de sazonalidade.

FERREIRA (2017) fez predição da velocidade do vento de curto prazo via modelos matemáticos. O objetivo principal do seu trabalho foi realizar previsões de médias horárias da velocidade do vento oriundas de torres anemométricas (altura de 50 metros), situadas em Belo Jardim/PE e Camocim/CE. Para isso, foram utilizados modelos de séries temporais, tais como: Holt - Winters (HW), RNA e Híbrido. Os dados observacionais foram também avaliados pela reanálise MERRA-2 (estado-da-arte) na altura de referência das torres. Os resultados mostram que para as duas localidades o modelo híbrido, em geral, apresentou um melhor desempenho com relação aos demais, inclusive na avaliação com o MERRA-2. Em termos de resíduos estatísticos, foram encontrados valores de REQM e EAM de 0,91 e 0,62 m/s, respectivamente.

SILVA *et al* (2017) refinou as estimativas da velocidade do vento feitas pelo modelo WRF usando RNA e modelo físico ó estatístico (MODEST). Foram feitos dois ensaios com o MODEST. No primeiro foram usados como dado de entrada as saídas WRF e os dados observados da torre anemométrica de Girau do Ponciano ó AL no período de janeiro a dezembro de 2009. No segundo, os dados de saída originais do WRF foram refinados via RNA. Os resultados mostraram que, o MODEST não funcionou bem quando usou as saídas originais do WRF como dado de entrada, mas se mostrou bastante eficiente quando as saídas WRF foram previamente refinadas via RNA, melhorando assim o prognóstico da velocidade do vento. O coeficiente de correlação aumentou de 0,36 para 0,89 e a REQM diminuiu de 5,89 para 1,29.

ZUCATELLI *et al* (2018) em seu trabalho de previsão da velocidade do vento a curto prazo usando RNA. Os autores treinaram, validaram e testaram 7 arquiteturas de RNA (Múltiplas Camadas *Perceptron* com algoritmo de treinamento *Feedforward Backpropagation*), a fim de definir qual seria a mais eficiente em realizar a previsão da velocidade do vento em 1 hora utilizando dados observacionais de uma torre anemométrica de 151 metros situada na cidade de Mucuri, Bahia, nordeste do Brasil, num período de 30 de novembro de 2015 a 31 de dezembro de 2015. A melhor configuração da RNA foi a que teve 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). As métricas estatísticas foram EAM (0,78), EQM (0,99), Erro mínimo (0,004), Erro máximo (3,06),  $r$  (0,94) e  $R^2$  (0,99). Este trabalho contribuiu para a tomada de decisão do Operador Nacional do Sistema Elétrico (ONS) em um parque eólico a fim de evitar prejuízos financeiros e técnicos, além de coadjuvar na análise da viabilidade técnica e econômica de implantação destes empreendimentos no Brasil.

### 3 - MATERIAIS E MÉTODOS

#### 3.1 - Área de Estudo

Com uma área territorial de 27.848,14km<sup>2</sup> (Quilômetro quadrado), situado entre os paralelos 08°48'47" S e 10°30'09" S e os meridianos 35°09'09" W e 38°14'27" W. O Estado de Alagoas delimita-se ao norte com Pernambuco, ao sul com Sergipe, sudoeste com a Bahia e sendo banhado pelo Oceano Atlântico ao leste. O Agreste está no centro do Estado, com uma área de 5.739km<sup>2</sup>, do lado esquerdo encontra-se o Sertão e do lado direito está a Zona da Mata, coberto por vegetação de transição entre a Caatinga e florestas tropicais (IBGE, 2008).

O local principal para os ensaios é aquele onde foi instalada a torre anemométrica do projeto PVPN, no Município de Craíbas, com as coordenadas geográficas a seguir:

- Latitude 09°53'03" S
- Longitude 36°49'44" O
- Altitude 244 metros

Craíbas limita-se ao norte com o município de Igaci (1), ao leste com Arapiraca (2), ao sudeste com Lagoa da Canoa (3), ao sul com Girau do Ponciano (4), ao sudoeste com Jaramataia (5) e oeste com Major Izidoro (6), conforme mostra a Figura 6.

**Figura 6 - Posição geográfica do Agreste alagoano com destaque para Craíbas.**



Fonte: Adaptada do IBGE, 2008.

## 3.2 - Dados Utilizados

### 3.2.1 - Dados Observados

Para a realização deste trabalho foram utilizados dados observados (OBS) do Projeto PVPN. Uma descrição detalhada das medições do Projeto PVPN foi feita por DA CRUZ, 2017.

Atualmente estão sendo usados os dados da rede anemométrica instalada na época da realização do Atlas Eólico de Alagoas. Uma descrição detalhada destas medições foi feita por RAMOS, 2012.

A Figura 7 mostra onde está localizada fisicamente a torre anemométrica de 100 metros de altura com medições de velocidade e direção do vento em 3 níveis: 30, 50 e 100 metros. As medições da velocidade do vento utilizadas foram feitas com frequência a cada 15 segundos e armazenada sem médias a cada 10 minutos registradas em um *datalogger* CR1000 (*Campbell Scientific Inc.* - USA) (SILVA, 2018).

Neste trabalho foram usados unicamente os dados de velocidade do vento na escala do parque eólico com medição no nível 2 a 50 metros de altura, de 10 em 10 minutos e o período estudado encontra-se entre 04/03/2015 à 04/07/2015.

**Figura 7 - Torre Anemométrica do Projeto PVPN em Craíbas.**



**Fonte: Autor, 2019.**

### 3.2.2 - Dados WRF


Foram utilizados dados de simulações numéricas a partir do modelo de meso escala WRF, com saídas de séries temporais compreendidas dentro do mesmo período dos dados observados. As simulações do modelo foram realizadas e cedidas pelo Laboratório de Modelagem Atmosférica do Instituto de Ciências Atmosféricas (ICAT) ó UFAL.

Como as saídas WRF são feitas em hora UTC e os dados OBS em hora local foi feita a conversão dos dados OBS para hora UTC. A configuração do modelo atmosférico para gerar os prognósticos WRF foi baseada em estudos recentes para regiões tropicais. A configuração e parametrização do modelo são descritas por RAMOS (2012).

O modelo foi configurado com 3 domínios, apresentados na Figura 8. 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 NEB (Nordeste Brasileiro) e parte do Oceano Atlântico. O domínio 3 possui resolução de 5 km e compreende o Estado de Alagoas. Este tipo de configuração aumenta a qualidade das simulações (AMORIM, 2011).

Neste trabalho as simulações do modelo WRF para a velocidade do vento são do domínio 3, nova configuração com saídas a cada 10 minutos e foram feitas no período entre 04/03/2015 à 04/07/2015.

**Figura 8 - Representação dos três domínios configurados no WRF.**



Fonte: Ramos, 2012.


### 3.3 - RNA-NARX

Rede neural artificial não linear auto-regressiva com entrada externa (NARX) é uma rede Recorrente ou Realimentada, também conhecida como redes de Hopfield, caracteriza-se pelo fato de que as saídas 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. Esta rede também é caracterizada pela variável  $Z$  que é o atraso temporal, também é conhecido como *delay*. O atraso da rede serve como uma memória que proporciona valores de entrada atuais e valores anteriores a eles (HAYKIN, 2008).

A configuração de uma rede recorrente está na Figura 9, onde pode observar os seus sinais de entrada  $\{x_1(k), x_2(k), \dots, x_n(k)\}$ , camada intermediária, realimentação do sinal de saída  $y(k-1)$  e atraso temporal ( $Z^{-1}$ ) características de uma rede recorrente e outro sinal de saída  $y(k)$ .

Dentre as várias configurações de RNA a escolhida para este trabalho foi a NARX, 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 (SILVA, SPATTI & FLAUZINO, 2010).

**Figura 9 - Estrutura de neural do tipo recorrente.**



Fonte: MANTOVANI, 2011.

### 3.4 - Resumo das etapas metodológicas empregadas

As séries de dados WRF e observados (OBS) são extraídas e convertidas para o *Workspace* do *software* computacional MATLAB para iniciar o processo de treinamento, validação, teste e avaliação de desempenho da RNA. A série WRF funciona como dados de entrada *input* e a série OBS como alvo *target*.

A elaboração do algoritmo da RNA primeiramente teve como referência principal o trabalho do MOURA (2014). Posteriormente, este código computacional sofreu algumas alterações, de acordo com os exemplos do *Help* do MATLAB, para melhor ajustar-se aos objetivos do presente trabalho. Foi utilizada a versão R2013a do MATLAB.


Os valores escolhidos de cada parâmetro foi resultado de inúmeros testes realizados até encontrar a melhor combinação. A quantidade de neurônios na camada escondida foi um parâmetro bastante analisado. Variando de zero a trinta, cinquenta e cem neurônios. Os testes indicaram que, acima de 50 neurônios os resultados tendem a piorar. A quantidade de vinte e seis neurônios na camada escondida obteve os melhores resultados.

A quantidade de dias anteriores a previsão utilizados no treinamento da RNA também foi outro parâmetro bastante analisado. O tamanho da série variou de 1 a 10, 15, 30, 45, 60 e 90 dias antes do dia previsto. O tamanho da série de três dias, total de 432 dados, obteve os melhores resultados.

Uma vez que o *output* de treinamento está disponível a partir de dados iniciais o algoritmo extrapola uma série que chamaremos de RNA, esta série de dados é a previsão da velocidade do vento para o dia posterior aos três dias usados para treinamento. Gerando uma série com 144 valores (totalizando um dia com um valor a cada 10 minutos).

O esquema utilizado pelo toolbox do MATLAB para a rede neural artificial NARX pode ser visualizado na Figura 10. Nela observam-se os sinais de entrada  $x(t)$ , sinais de saídas  $y(t)$  sendo realimentadas típicas das redes recorrentes, com duas camadas uma escondida (*Hidden*) e uma de saída (*Output*), atraso de entrada e atraso de retorno sendo de 0:1, pesos, bias, função de ativação na camada escondida é a Tangente Hiperbólica (*tansing*) com 26 neurônios, a função de ativação da camada de saída é a Linear (*purelin*) com um neurônio e outro sinal de saída  $y(t+1)$  que representa a previsão da velocidade do vento.

Figura 10 - Esquema da rede neural artificial NARX utilizada no toolbox do MATLAB.



Fonte: Autor, 2019.

Da mesma forma que OBS é comparada com WRF, a série prevista denominada de RNA também é aferida com a série de dados observados em todo o período de estudo através de métricas estatísticas, tais como coeficiente de correlação, desvio médio, erro quadrático médio e raiz do erro quadrático médio calculados pelas equações a seguir:

a) Coeficiente de Correlação

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

b) Desvio Médio

$$DESV = \frac{1}{N} \sum_{i=1}^N (x_i - y_i) \quad (2)$$

**c) Erro Quadrático Médio**

$$EQM = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (3)$$

**d) Raiz do Erro Quadrático Médio**

$$REQM = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (4)$$

Para diferenciar dias típicos de dias atípicos foi utilizada a métrica estatística Coeficiente de Variação (Equação 5) que é uma medida de dispersão empregada para estimar a precisão de experimentos e representa o quociente do desvio-padrão expresso como porcentagem da média (GOMES, 1990).

$$CV = \frac{DP}{\bar{x}} \cdot 100 \quad (5)$$

Para classificar dias atípicos nas séries OBS e WRF foram usados CV médio. Assim, dias em que o CV foi superior ao CV médio foram classificados como atípicos. No período estudado o CV médio OBS foi de 35,29% e WRF de 35,35%. Para simplificar, arredondamos o valor de referência para 36,0%.

De acordo com os parâmetros quantidade de neurônios na camada escondida e quantidade de dias anteriores a previsão.

Foram realizados vários testes e simulações variando o tamanho da amostra (número de dias) e o número de neurônios. Todos os testes foram feitos para simular o vento no dia 10/03/2015. Para encontrar a melhor combinação foram utilizados 3 métricas: coeficiente de correlação ( $r$ ), DESV e REQM. Na Tabela 2 são mostrados os resultados obtidos com destaque para os melhores valores obtidos. Separando as seis melhores quantidades de neurônios na camada escondida e variando de um a cinco dias anteriores a previsão. A melhor combinação destes parâmetros é a com 26 neurônios na camada escondida coincidindo com

três dias anteriores a previsão obtendo menor REQM entre os dados observados e os prognósticos previstos.

**Tabela 2 - Processo de escolha dos parâmetros quantidade de neurônio na camada escondida e o número de dias anteriores a previsão.**

| Neurônios | Dias | $r_{(OBS \times RNA)}$ | Desvio(RNA-OBS) | REQM (RNA-OBS) |
|-----------|------|------------------------|-----------------|----------------|
| 12        | 1    | 0,81                   | 1,04            | 1,38           |
| 15        | 1    | 0,76                   | 0,43            | 0,96           |
| 17        | 1    | 0,77                   | 0,47            | 1,26           |
| 19        | 1    | 0,79                   | 1,01            | 1,34           |
| 20        | 1    | 0,82                   | 0,82            | 1,17           |
| 26        | 1    | 0,82                   | 1,18            | 1,40           |
| 12        | 2    | 0,83                   | 1,00            | 1,16           |
| 15        | 2    | 0,80                   | 1,08            | 1,49           |
| 17        | 2    | 0,81                   | 0,96            | 1,41           |
| 19        | 2    | 0,84                   | 1,03            | 1,68           |
| 20        | 2    | 0,80                   | 0,87            | 1,20           |
| 26        | 2    | 0,80                   | 0,61            | 0,88           |
| 12        | 3    | 0,81                   | 0,94            | 1,32           |
| 15        | 3    | 0,81                   | 1,02            | 1,44           |
| 17        | 3    | 0,81                   | 1,07            | 1,35           |
| 19        | 3    | 0,82                   | 1,04            | 1,55           |
| 20        | 3    | 0,82                   | 0,96            | 1,45           |
| 26        | 3    | 0,83                   | 0,53            | 0,83           |
| 12        | 4    | 0,82                   | 1,07            | 1,42           |
| 15        | 4    | 0,82                   | 0,75            | 1,12           |
| 17        | 4    | 0,81                   | 0,94            | 1,30           |
| 19        | 4    | 0,81                   | 0,98            | 1,38           |
| 20        | 4    | 0,81                   | 0,85            | 1,25           |
| 26        | 4    | 0,82                   | 0,98            | 1,27           |
| 12        | 5    | 0,83                   | 1,03            | 1,26           |
| 15        | 5    | 0,82                   | 1,05            | 1,41           |
| 17        | 5    | 0,81                   | 0,91            | 1,32           |
| 19        | 5    | 0,80                   | 1,03            | 1,30           |
| 20        | 5    | 0,80                   | 1,14            | 1,25           |
| 26        | 5    | 0,81                   | 1,10            | 1,32           |

Fonte: Autor, 2019.

Para finalizar, foi definida a configuração final da RNA cujos parâmetros são apresentados na Tabela 3 a seguir.

**Tabela 3 - Parâmetros utilizados na avaliação de desempenho da RNA-NARX.**

| PARÂMETROS                                     | DADOS/VALORES |
|--|---------------|
| SÉRIE DE ENTRADA ( <i>input series</i> )       | SÉRIE WRF     |
| SÉRIE DE ALVO ( <i>target series</i> )         | SÉRIE OBS     |
| NÚMERO DE PREVISÕES ( <i>forecast number</i> ) | 144           |
| ATRASSO DE ENTRADA ( <i>input delays</i> )     | 0:1           |

|   |  |
|---|--|
| ATRASSO DO RETORNO ( <i>feedback delays</i> )     | 0:1                                    |
| NÚMERO DE CAMADAS ( <i>layer number</i> )         | 2                                      |
| NEURÔNIOS NA CAMADA ESCONDIDA                     | 26                                     |
| REDE ( <i>net</i> )                               | NARX                                   |
| FUNÇÃO ( <i>function</i> )                        | PREPARETS                              |
| CAMADA ESCONDIDA ( <i>hidden layer</i> )          | 1                                      |
| FUNÇÃO DE ATIVAÇÃO ( <i>activation function</i> ) | TANGENTE HIPERBÓLICA ( <i>Tansig</i> ) |
| CAMADA DE SAÍDA ( <i>output layer</i> )           | 1                                      |
| FUNÇÃO DE ATIVAÇÃO ( <i>activation function</i> ) | LINEAR ( <i>Purelin</i> )              |
| NEURÔNIOS NA CAMADA DE SAÍDA                      | 1                                      |
| TREINAMENTO ( <i>training</i> )                   | 70%                                    |
| VALIDAÇÃO ( <i>validation</i> )                   | 15%                                    |
| TESTE ( <i>testing</i> )                          | 15%                                    |
| ÉPOCAS ( <i>net.trainParam.epochs</i> )           | 1000                                   |
| VERIFICAÇÕES ( <i>net.trainParam.max_fail</i> )   | 10                                     |
| GRADIENTE ( <i>net.trainParam.mu</i> )            | 0,001                                  |
| TREINAMENTO ( <i>training</i> )                   | LEVENBERG-MARQUARDT                    |
| DESEMPENHO ( <i>performance</i> )                 | ERRO QUADRÁTICO MÉDIO                  |
| FUNÇÃO ( <i>function nets</i> )                   | REMOVE DELAY                           |

Fonte: Autor, 2019.

## 4 - RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados e discutidos os resultados para a previsão da velocidade do vento no período estudado através do modelo WRF e refinados pela RNA-NARX que foi treinada, validada e testada. A série de dados refinada na verdade é uma previsão feita a partir dos dados observados e WRF dos 3 dias anteriores. Doravante a série de dados correspondente aos resultados desta previsão será chamada de RNA de acordo com o que foi explanado no capítulo anterior.

Os resultados serão apresentados e discutidos através dos gráficos que mostram a evolução da velocidade do vento através das três séries de dados OBS, WRF e RNA no período estudado. Serão também utilizadas métricas estatísticas para quantificar o desempenho dos referidos prognósticos.

### 4.1 Velocidade média diária


A Figura 11 mostra a evolução temporal da velocidade do vento dos dados observados (contínua), WRF (pontilhada) e RNA (tracejada) no período estudado. Para visualizar de maneira mais clara, sem uma enorme quantidade de valores horários, este gráfico foi gerado a partir das médias diárias. A primeira coisa que fica bem evidente é a proximidade das 3 séries, ou seja, a série WRF ficou muito próxima da série OBS a ponto de não ser possível diferenciar com facilidade. Por conta disso, fica ainda mais difícil notar a pequena melhora obtida pela previsão RNA. Deste modo, os valores médios da velocidade média diária do vento no período estudado foram de OBS com 5,30 m/s, WRF com 5,20 m/s e RNA com 5,32 m/s.

O máximo valor OBS foi de 7,2 m/s no dia 13/05/2015 e o mínimo de 3,0 m/s no dia 08/04/2015. O valor máximo da série RNA também foi de 7,2 m/s, no dia 19/03/2015 e o mínimo foi de 3,1 m/s no dia 24/05/2015. No caso dos dados WRF o valor máximo foi de 6,7 m/s no dia 18/03/2015 e o mínimo de 2,8 m/s no dia 06/04/2015.

Moura (2014) relatou que as saídas WRF no período chuvoso aumentaram relativamente em relação aos dados observados e este aumento foi repassado para o refinamento da RNA. O prognóstico WRF teve dificuldades em gerar os períodos de máxima velocidade do vento, períodos de mudanças bruscas no comportamento do vento, períodos de chuva e de transição noite/dia e vice e versa. Estas adversidades também foram mencionadas nos trabalhos do Ramos (2013) e Ihadua (2014).

Comparando as séries WRF e RNA, observa-se que, aquela que se manteve mais próxima da série OBS foi a RNA. Pois o prognóstico WRF não conseguiu reproduzir os períodos de máxima velocidade do vento como o prognóstico RNA. E em alguns casos é possível identificar os momentos em que WRF subestima os dados OBS.

**Figura 11 - Evolução temporal da velocidade do vento a partir das médias diárias OBS (contínua), WRF (pontilhada) e RNA (tracejada) no período de 04/03/2015 a 04/07/2015.**



Fonte: Autor, 2019.

#### 4.2 ó Desvios Médios

A Figura 12 mostra os desvios médios diários dos prognósticos WRF (pontilhada) e RNA (tracejada) em relação aos dados observados. Os desvios RNA oscilaram mais entre positivo e negativo permanecendo na maior parte do tempo dentro do intervalo de -1 a 1, com desvio médio quase nulo de -0,01 m/s. O maior desvio positivo foi de 2,2 m/s no dia 27/06/2015. O maior desvio negativo foi de -2,5 m/s no dia 30/06/2015.

Em relação ao prognóstico WRF o maior desvio positivo foi de 1,09 m/s no dia 13/06/2015. O maior desvio negativo foi de -2,14 m/s no dia 26/05/2015. Os desvios WRF, na maioria dos casos, são negativos. Desta forma, as simulações WRF subestimaram os dados observados. O valor médio do desvio WRF foi de -0,35 m/s.


De acordo com o gráfico da Figura 12 o melhor período de previsão encontra-se entre os dias 21/04/2015 até 20/05/2015, pois neste período o desvio da RNA manteve-se dentro do intervalo -1 a 1. Outros períodos em que se obteve uma boa previsão estão localizados entre os dias 20/03/2015 a 07/04/2015 (com exceção do dia 31/03/2015) e 05/06/2015 a 26/06/2015 (com exceção do dia 14/06/2015).

Não é considerada uma boa previsão os casos em que os desvios ultrapassam o intervalo -1 a 1. Deste modo, destacamos os períodos 15/03/2015 a 19/03/2015, 08/04/2015 a 20/04/2015 e 21/05/2015 a 04/06/2015 em todos esses casos o desvio da RNA oscilou muito tanto quanto positivo como negativo.

O pior período de previsão encontra-se entre os dias 27/06/2015 até 01/07/2015 em que o desvio RNA oscilou bruscamente ultrapassando o intervalo -2 a 2, maior desvio dentre todos. Este período compreende ao Inverno.

O melhor período de simulação dos prognósticos WRF foi entre 04/03/2015 a 05/04/2015, pois permaneceu dentro do intervalo de desvio de velocidade -1 a 1. E argumentando sobre alguns períodos em que os dados WRF subestimaram OBS, como por exemplo, 06/04/2015 a 12/04/2015, 10/05/2015 a 27/05/2015 e 18/06/2015 a 03/07/2015.

**Figura 12 - Desvios Médios entre os prognósticos WRF (pontilhada) e RNA (tracejada) com relação aos dados OBS.**



Fonte: Autor, 2019.

O fato de ter usado médias diárias leva a crer que houve maior variabilidade nos desvios RNA inclusive com extremos mais acentuados. No entanto a estatística de médias a 10 minutos mostrou que as distribuições dos desvios são praticamente iguais na Figura 15.

Na busca de tentar entender o motivo dos desvios acima da média geral fazemos uso da Tabela 4 que mostra os CVs das séries OBS e WRF de alguns dias. A tabela 4 será usada toda vez que for analisada a evolução temporal horária da velocidade do vento. Tendo em vista que o prognóstico RNA é feito a partir das séries OBS e WRF dos 3 dias anteriores, atipicidades nestas séries (uma ou ambas), implicará em perda da qualidade do prognóstico.

**Tabela 4 - Análise do CV das séries OBS e WRF de alguns dias.**

| Data       | CV (%) |       |
|------------|--------|-------|
|            | OBS    | WRF   |
| 04/04/2015 | 58,79  | 37,35 |
| 05/04/2015 | 70,77  | 39,79 |
| 06/04/2015 | 53,98  | 87,50 |
| 07/04/2015 | 22,90  | 41,55 |
| 09/04/2015 | 43,60  | 32,21 |
| 10/04/2015 | 41,80  | 54,67 |
| 11/04/2015 | 97,35  | 44,24 |
| 12/04/2015 | 29,14  | 47,20 |
| 16/06/2015 | 36,31  | 28,61 |
| 17/06/2015 | 41,23  | 19,60 |
| 18/06/2015 | 42,07  | 19,05 |

|            |       |       |
|------------|-------|-------|
| 19/06/2015 | 56,20 | 42,11 |
| 24/06/2015 | 43,08 | 50,86 |
| 25/06/2015 | 38,37 | 46,20 |
| 26/06/2015 | 23,48 | 23,82 |
| 27/06/2015 | 53,74 | 44,23 |
| 28/06/2015 | 48,68 | 41,03 |
| 29/06/2015 | 40,78 | 45,82 |
| 30/06/2015 | 27,69 | 29,86 |
| 01/07/2015 | 29,97 | 32,85 |


**Fonte: Autor, 2019.**

A Figura 13 mostra a evolução temporal horária da velocidade do vento nos dias 24/06/2015 a 27/06/2015. Nela verificamos que em muitas ocasiões as séries OBS e WRF evoluem de forma oposta, ou seja, enquanto uma aumenta a outra diminui.

Utilizando o critério de atipicidade adotado ( $CV > 36\%$ ) quando olhamos para os CVs (Tabela 4), verificamos que os dias 24, 25 e 27/06/2015 foram atípicos.

A série OBS indica que os dias 25 e 26/06/2015 foram dias em que a velocidade do vento foi acima da média, 5,6 m/s e 6,8 m/s respectivamente, principalmente nas primeiras horas do dia. Enquanto que no dia 27/06/2015 a velocidade do vento diminuiu drasticamente chegando a manter-se abaixo de 2 m/s no período da manhã e sua velocidade média neste dia foi de 4,6 m/s abaixo da média. Assim, o prognóstico RNA subestimou OBS nos dias 25 e 26/06/2015, com velocidade média de 4,3 m/s e 5,5 m/s respectivamente, e transportou características dos dois dias observados para o dia seguinte 27/06/2015, com velocidade média de 7,1 m/s superestimando os dados observados com um desvio positivo de mais de 2 m/s.

**Figura 13 - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 24/06/2015 a 27/06/2015.**




Fonte: Autor, 2019.

A Figura 14 mostra a evolução temporal horária da velocidade do vento nos dias 27/06/2015 a 30/06/2015. Utilizando o critério de atipicidade adotado ( $CV > 36\%$ ) na Tabela 4 vemos que os CVs das séries OBS e WRF dos três dias (27, 28 e 29/06/2015) usados para treinamento da RNA foram atípicos.

Fica evidente que o dia 29/06/2015 foi um dia atípico, pois a série OBS mostra um pico de mais de 10 m/s as 09:00. Após o pico de alta a velocidade diminui para próximo de 2 m/s as 12:00. Finalmente, a velocidade média OBS foi de 4,3 m/s. O prognóstico RNA no dia 30/06/2015 foi influenciado pela atipicidade do dia 29/06/2015 atingindo a velocidade máxima de 10 m/s no período da manhã (perto de 9:00) e um pico de baixa as 12:00 e isto fez com que o prognóstico RNA subestimasse os dados OBS. O prognóstico WRF, com menos oscilações que as demais séries, no dia 29/06/2015 apresentou um extremo máximo próximo das 12:00, e no dia 30/06/2015 WRF também apresentou um pico de baixa as 12:00 subestimando OBS. Como pode ser observado na Figura 14 a seguir.

**Figura 14 - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 27/06/2015 a 30/06/2015.**




Fonte: Autor, 2019.

O gráfico de colunas na Figura 15 mostra a frequência percentual dos desvios RNA e WRF. A estatística foi feita utilizando os valores inteiros dos desvios. Portanto cada classe representa uma janela de 1,0 m/s.

A comparação entre as duas distribuições é importante porque permite identificar melhor a acurácia das séries WRF e RNA.

As duas distribuições foram uni modais com padrões bem parecidos. A distribuição RNA é simétrica e a WRF é assimétrica à esquerda. As frequências divergem um pouco, enquanto que a maior frequência do desvio WRF é na classe -1 (21,76%). O máximo RNA está na classe 0 (22,43%). Para ambas as séries mais da metade da frequência dos desvios estão compreendidos na coluna de -1 a 1. No caso da RNA foram 60,48% e para o WRF 58,16%.

**Figura 15 - Frequências dos desvios RNA (preta) e WRF (cinza) em Craíbas, no período de 04/03/2015 a 04/07/2015.**



Fonte: Autor, 2019.

#### 4.3 ó Raiz do Erro Quadrático

A Figura 16 mostra os Erros Quadráticos dos prognósticos RNA (tracejada) e WRF (pontilhada) com relação aos dados observados no período estudado. A decisão de usar esta métrica se deu em virtude dela ser mais sensível aos grandes desvios e os valores serem sempre positivo, por elevar os desvios individuais ao quadrado conforme Wilks (2006).

De maneira geral, o erro quadrático dos prognósticos WRF não teve picos máximos tão expressivos como os prognósticos RNA, mas apesar disto, na maioria dos casos, são superiores tanto que o EQM foi de 1,4 m/s para o RNA e 1,5 m/s para o WRF.


O menor e maior valor do EQ da série RNA foi de 0,4 m/s no dia 27/04/2015 e de 7,1 m/s no dia 30/06/2015. Já o EQ da série WRF foi também de 0,4 m/s no dia 12/05/2015 e 5,0 m/s no dia 21/06/2015.

Quando o erro quadrático atinge valores maiores ou iguais a 4 m/s indica que os desvios ultrapassaram o intervalo de -2 a 2 indicando uma prognóstico insatisfatório. No caso dos dados WRF podemos observar alguns casos isolados em que o erro quadrático foi acima de 4 m/s, por exemplo, 21/03/2015, 07/04/2015, 15/05/2015, 26/05/2015 e 21/06/2015.

Através do gráfico da Figura 16 podemos observar dois pequenos períodos que mostra onde a previsão não foi precisa, no período 26/06/2015 a 01/07/2015 em que o EQ da RNA chegou a 7,1 m/s no dia 30/06/2015. Neste período a previsão não foi precisa, pois o prognóstico RNA atingiu o seu maior desvio negativo conforme mostrado no item 4.2. Assim

quando elevado ao quadrado atingi o valor máximo. Outros extremos que chama atenção são visto entre os dias 08/04/2015 até 20/04/2015, pois oscilou repetidamente elevando o erro quadrático dos prognósticos RNA a picos de 5 m/s, 6,0 m/s e 4m/s, respectivamente.

**Figura 16 - Erro quadrático dos prognósticos WRF (pontilhada) e RNA (tracejada), em Craíbas, no período de 04/03/2015 a 04/07/2015.**



Fonte: Autor, 2019.


A Figura 17 mostra a raiz do erro quadrático dos prognósticos WRF (pontilhada) e RNA (tracejada) dentro dos cinco meses de previsão. Willmott (1982) em seu trabalho informa que a raiz do erro quadrático é geralmente usada para expressar a precisão dos resultados numéricos, pois apresenta valores do erro nas mesmas dimensões da variável analisada. Portanto, quanto menor é a raiz do erro quadrático melhor a previsão.

No contexto geral, o melhor período de previsão encontra-se entre os dias 21/04/2015 até 20/05/2015 (com exceção do dia 08/05/2015), pois neste período houve muitos casos em que a REQ do RNA esteve abaixo de 1 m/s, indicando um prognóstico satisfatório. Em poucos casos a REQ do RNA obteve valores iguais ou maiores que dois, entre os dias 08/04/2015 a 20/04/2015 e 27/06/2015 a 01/07/2015. Na maioria dos casos manteve-se com valores próximos de 1 fazendo com que a REQM do RNA seja de 1,18 m/s, enquanto que a REQM do WRF foi de 1,24 m/s. Isto comprova que os prognósticos RNA aproximaram-se mais dos dados observados do que os prognósticos WRF.

O mínimo encontra-se no dia 27/04/2015 com valor de 0,6 m/s e o máximo está no dia 30/06/2015 com valor de 2,7 m/s, ambos referentes à série RNA. Enquanto que o mínimo da

série WRF foi de 0,7 m/s no dia 12/05/2015 e o máximo foi no dia 21/06/2015 com valor de 2,2 m/s.

**Figura 17 - Raiz do erro quadrático dos prognósticos WRF (pontilhada) e RNA (tracejada), em Craíbas, no período de 04/03/2015 a 04/07/2015.**



Fonte: Autor, 2019.


Deste modo, têm-se dois períodos que mostram onde a previsão não foi boa, no período 26/06/2015 a 01/07/2015 comentado no item 4.2. E no período entre os dias 08/04/2015 até 20/04/2015, pois a raiz do erro quadrático do prognóstico RNA oscilou repetidamente ultrapassando o intervalo de 2 m/s. Assim, vamos analisar o motivo da REQ da RNA oscilar desta maneira acima da média.

A Figura 18 mostra a evolução temporal horária da velocidade do vento nos dias 04/04/2015 a 07/04/2015. De acordo com a Tabela 4 todos os dias usados para treinamento da RNA são considerados atípicos, o dia 07/04/2015 da série OBS obteve um CV de 22,90% abaixo da média, com pouca dispersão de valores o que fez com que sua velocidade fosse de 5,20 m/s, próxima a média (5,30 m/s).

Na Figura 18 podemos verificar o quanto o dia 07/04/2015 da série OBS foi diferente dos dias anteriores com pouca dispersão de dados durante o dia todo, atingindo velocidade mínima as 17:30 e máxima as 23:00. Por outro lado, o prognóstico WRF foi marcado por algumas oscilações, principalmente nos dias 05 e 07/04/2015, fugindo do padrão que as demais séries seguem. O prognóstico RNA conseguiu reproduzir bem o padrão de evolução temporal do vento nos três primeiros dias desta análise, mas a previsão para o último dia não

foi precisa, principalmente no quarto período do dia em que RNA atingiu mais de 10 m/s enquanto que OBS foi de aproximadamente 8 m/s.

**Figura 18 - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 04/04/2015 a 07/04/2015.**




Fonte: Autor, 2019.

A Figura 19 mostra a evolução temporal horária da velocidade do vento entre os dias 09/04/2015 a 12/04/2015. Novamente, de acordo com a Tabela 4 podemos observar que todos os dias usados para treinamento da RNA são considerados atípicos, apenas o dia 12/04/2015 da série OBS obteve um CV de 29,14% abaixo da média, ficando assim com pouca variabilidade de dados.

Os três primeiros dias da Figura 19, os prognósticos WRF e RNA mantiveram-se próximos dos dados OBS. Mas, no dia 12/04/2015 podemos observar que a intensidade da velocidade do vento dos dados observados não diminuíram nas primeiras 12:00 do dia se mantendo acima de 4 m/s e atingindo velocidade máxima de 11 m/s no período da tarde as 16:00 tendo poucas dispersões durante o dia todo. Neste dia as velocidades dos prognósticos diminuíram como nos dois dias anteriores, sendo que WRF representou melhor o perfil do vento, em comparação com OBS, melhor que RNA que transferiu características dos dias 10 e 11/04/2015 para o dia seguinte. Portanto, os prognósticos WRF e RNA subestimaram OBS no dia 12/04/2015.

**Figura 19 - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 09/04/2015 a 12/04/2015.**




Fonte: Autor, 2019.

A Figura 20 mostra a evolução temporal horária da velocidade do vento entre os dias 16/04/2015 a 19/04/2015. Podemos observar na Tabela 4 que todos os dias da série OBS são considerados atípicos, enquanto que a série WRF apenas o dia 19/04/2015 é atípico.

No dia 19/04/2015 a série OBS apresentou uma diminuição de velocidade anormal no terceiro quarto do dia e a noite foi aumentando sua velocidade gradativamente, mas não o suficiente para atingir a velocidade de 10 m/s. Com isso, OBS obteve velocidade média de 3,8 m/s abaixo da média geral. Por outro lado, neste mesmo dia o prognóstico WRF em menos de duas horas apresentou uma oscilação inesperada no período da tarde onde atingiu um valor máximo e mínimo respectivamente e sua velocidade média neste dia foi de 4,5 m/s também abaixo da média. O prognóstico da RNA para o dia 19/04/2015 não apresentou nenhuma atipicidade seguiu as características dos dias OBS anteriores principalmente as características do dia 18/04/2015, com velocidade média de 5,7 m/s superestimando os dados observados.

**Figura 20 - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 16/04/2015 a 19/04/2015.**



Fonte: Autor, 2019.

#### 4.5 ó Coeficiente de Correlação

A Figura 21 mostra o coeficiente de correlação de Pearson dos prognósticos WRF (pontilhada) e RNA (tracejada) relacionado com os dados observados.

O coeficiente de correlação de Pearson mede o grau de correlação entre os dados OBS e os prognósticos RNA e WRF assumindo valores no intervalo de -1 a 1.


De uma maneira geral as correlações RNA foram melhores. O coeficiente de correlação médio entre as variáveis observadas e os prognósticos RNA foi de 0,70 indicando uma correlação forte. Já entre as variáveis OBS e os prognósticos WRF a correlação foi de 0,61 que indica uma correlação moderada de acordo com Dancey & Reidy (2006).

Como pode ser observado na Figura 21 o  $r_{RNA}$  atingiu valores mais próximos de 1 do que  $r_{WRF}$ . No período final do estudo foi onde o  $r_{RNA}$  atingiu seu pior resultado. Em muitos casos o  $r_{WRF}$  diminuiu drasticamente e em alguns momentos o  $r_{RNA}$  acompanhou esta diminuição, como por exemplo no dia 09/03/2015 e 01/07/2015. Na maioria dos casos observa-se o  $r_{RNA}$  entre 0,6 e 0,8 principalmente entre os dias 11/03/2015 e 20/05/2015 com algumas exceções.

O maior coeficiente de correlação (0,92) está no dia 10/04/2015 indicando uma correlação muito forte entre as variáveis OBS e RNA e no dia 01/07/2015 obteve o menor  $r_{RNA}$  de 0,13 informando que não existe correlação entre estas duas variáveis.

É importante destacar que o número de casos com correlação abaixo de 0,5 é bem maior na série WRF. Assim, os menores coeficientes de correlação pertencem a  $r_{WRF}$  e em dois casos específicos, nos dias 26/05/2015 e 01/07/2015, obtiveram valores menores que zero apontando uma correlação negativa. O maior coeficiente de correlação do prognóstico WRF (0,88) que ocorreu no dia 24/04/2015.

**Figura 21 - Coeficiente de correlação dos prognósticos WRF (pontilhada) e RNA (tracejada), em Craíbas, no período de 04/03/2015 a 04/07/2015.**



Fonte: Autor, 2019.


Vamos analisar o período final de estudo em que  $r_{RNA}$  obteve um coeficiente de correlação muito abaixo da média. No dia 01/07/2015 saber o porquê do  $r_{RNA}$  atingir o menor coeficiente de correlação de 0,13.

A Figura 22 mostra a evolução temporal horária da velocidade do vento entre os dias 28/06/2015 a 01/07/2015. Fazendo uso da Tabela 4 vemos que apenas os dois primeiros dias das séries OBS e WRF foram atípicos, mas na figura a seguir veremos que os dias 29/06/2015, 30/06/2015 e 01/07/2015 são dias muito diferentes entre si, consequentemente a previsão da RNA para o ultimo dia da análise não será precisa.

No item 4.2 discutimos que os dias 28 e 29/06/2015 são dias atípicos, com isto os prognósticos WRF e RNA não geraram bons resultados. OBS no dia 01/07/2015 apesar de atingir uma velocidade próxima da média de 5,1 m/s apresentou muitas oscilações bruscas no período da tarde e as 15:00 atingiu a velocidade máxima de apenas 9 m/s. O prognóstico RNA carregou características dos dados observados do dia 30/06/2015 para o dia seguinte atingindo uma velocidade acima da média de 6,6 m/s. Em certos momentos fica evidente que à medida

que OBS diminui RNA aumenta, ou seja, oscilações divergentes e isso claramente faz com que o  $r_{RNA}$  diminua ao ponto de ser o menor coeficiente de correlação.

**Figura 22 - Evolução temporal horária da velocidade do vento dos dados OBS (contínua), WRF (pontilhada) e RNA (tracejada) entre os dias 28/06/2015 a 01/07/2015.**



Fonte: Autor, 2019.

#### 4.6 ó Discussão dos resultados

A Tabela 5 resume os valores médios OBS, WRF e RNA assim como as demais métricas estatísticas utilizadas. Nesta tabela pode ser visto a melhora produzida pela RNA. Os resultados RNA foram sempre melhores que os resultados do WRF.

Dos três dias usados para treinar a rede neural o terceiro é o que exerce mais peso na previsão, por isso que quando OBS é atípico o RNA carrega essas atipicidades para o dia seguinte.

Vale salientar que o valor do desvio médio entre os prognósticos RNA e OBS, foi inferior a margem de erro dos anemômetros (0,2 m/s).

**Tabela 5 - Resumo das médias das séries OBS, WRF e RNA e métricas estatísticas.**

| Série de dados e      |          |
|-----------------------|----------|
| Métricas Estatísticas | Valores  |
| OBS                   | 5,30 m/s |
| WRF                   | 5,20 m/s |

|                               |           |
|-------------------------------|-----------|
| <b>RNA</b>                    | 5,32 m/s  |
| <b>Desvio (WRF)</b>           | -0,35 m/s |
| <b>Desvio (RNA)</b>           | -0,01 m/s |
| <b>EQM (WRF)</b>              | 1,5 m/s   |
| <b>EQM (RNA)</b>              | 1,4 m/s   |
| <b>REQM (WRF)</b>             | 1,24 m/s  |
| <b>REQM (RNA)</b>             | 1,18 m/s  |
| <b><math>r_{(WRF)}</math></b> | 0,61      |
| <b><math>r_{(RNA)}</math></b> | 0,70      |

**Fonte: Autor, 2019.**

A Tabela 6 mostra a comparação dos resultados obtidos neste trabalho com os resultados obtidos de alguns trabalhos que utilizaram o modelo WRF e/ou RNA para aferir com os dados observados na região central de Alagoas. Gonçalves (2011) utilizou dados anemométricos de Girau do Ponciano para serem aferidos com dados refinados por RNA através de desvios, REQM e  $r$ . Ramos (2012) utilizou o modelo WRF para desenvolver um mapeamento eólico nas três mesorregiões de Alagoas no período de agosto/2007 a julho/2008, mas serão apenas comparados os resultados de Girau do Ponciano através do desvio médio e raiz do erro quadrático médio. A razão disto é o fato de Girau do Ponciano ficar próximo ao local onde foi instalada a torre PVPN.

Moura (2014) utilizou RNA para fazer refinamento das simulações do modelo WRF da velocidade média do vento no ano de 2009 e seus resultados foram discutidos com relação à velocidade média e correlação entre os dados OBS e os prognósticos WRF e RNA. Ihadua (2014) utilizou o modelo WRF para diagnosticar a velocidade do vento em Girau do Ponciano no período de dezembro de 2007 a novembro de 2008 e seus resultados foram discutidos através do cálculo de desvio médio.

Amorim (2015) analisa estatisticamente o desempenho do modelo WRF para o prognóstico do vento em Girau do Ponciano no ano de 2008 e faz uma análise comparativa com dados observados através do desvio, REQM e  $r$ . Lyra *et al* (2016) realizou o prognóstico do vento usando o modelo WRF na região central de Alagoas no intervalo de 10 dias (22 a 31 de março de 2015) e os resultados comparados foram velocidade média e coeficiente de correlação entre os dados OBS e WRF.

Jatobá (2017) avaliou o potencial eólico de Craíbas utilizando o modelo WRF em alta resolução e dados observados, os resultados foram analisados através de velocidade média do vento e correlação de Pearson. Silva *et al* (2018) avaliou o desempenho do modelo WRF para prognóstico do vento em Craíbas no período de janeiro a dezembro de 2014 e seus resultados

foram mostrados através das métricas estatísticas velocidade média e coeficiente de correlação.

Através da Tabela 6 verifica-se que os valores médios do vento dos prognósticos WRF e RNA mantiveram-se próximos dos dados OBS em quase todos os resultados, com exceção do WRF do Moura (2014). Dentre todos os desvios o menor foi o  $Desv_{(RNA)}$  igual a  $-0,01$  m/s para este trabalho e o pior desvio foi  $Desv_{(WRF)}$  igual a  $-3,01$  m/s. Em geral os valores dos prognósticos e métricas estatísticas foram considerados satisfatórios quando comparados à literatura. Os valores para REQM de trabalhos similares entre  $1,38$  m/s e  $2,08$  m/s e as correlações entre  $0,79$  e  $0,87$  de acordo com Gonçalves (2011). Deste modo,  $r_{(RNA)}$  está abaixo da expectativa e o valor de  $REQM_{(RNA)}$  ficou melhor que os valores da literatura, o que pode ser considerado um bom resultado. Entretanto, as particularidades de cada trabalho 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 (GONÇALVES, 2011).

**Tabela 6 - Comparação dos resultados obtidos neste trabalho (Santos, 2019) com os resultados obtidos de trabalhos que utilizaram o modelo WRF e/ou RNA na região central de Alagoas.**

|                               | Frequência | OBS         | WRF         | RNA         | $Desv_{(WRF)}$ | $Desv_{(RNA)}$ | $REQM_{(WRF)}$ | $REQM_{(RNA)}$ | $r_{(WRF)}$ | $r_{(RNA)}$ |
|-------------------------------|------------|-------------|-------------|-------------|----------------|----------------|----------------|----------------|-------------|-------------|
| <b>Santos (2019)-CR</b>       | 10 min     | 5,30<br>m/s | 5,20<br>m/s | 5,32<br>m/s | -0,35 m/s      | -0,01 m/s      | 1,24 m/s       | 1,18 m/s       | 0,61        | 0,70        |
| <b>Gonçalves (2011)-GP</b>    | 60 min     | -           | -           | -           | -              | 0,15 m/s       | -              | 1,33 m/s       | -           | 0,87        |
| <b>Ramos (2012)-GP</b>        | 10 min     | 7,39<br>m/s | 6,79<br>m/s | -           | -0,60 m/s      | -              | 2,98 m/s       | -              | -           | -           |
| <b>Moura (2014)-GP</b>        | 60 min     | 7,25<br>m/s | 4,24<br>m/s | 7,30<br>m/s | -3,01 m/s      | 0,05 m/s       | -              | -              | 0,60        | 0,71        |
| <b>Ihadua (2014)-GP</b>       | 60 min     | 7,25<br>m/s | 7,27<br>m/s | -           | 0,02 m/s       | -              | -              | -              | -           | -           |
| <b>Amorim (2015)-GP</b>       | 60 min     | -           | -           | -           | 0,55 m/s       | -              | 0,39           | -              | 0,62        | -           |
| <b>Lyra et al (2016)-CR</b>   | 10 min     | 5,72<br>m/s | 6,32<br>m/s | -           | 0,60 m/s       | -              | -              | -              | 0,86        | -           |
| <b>Jatobá et al (2017)-CR</b> | 10 min     | 6,44m/s     | 7,19m/s     | -           | 0,75 m/s       | -              | -              | -              | 0,77        | -           |
| <b>Silva et al (2018)-CR</b>  | 60 min     | 5,91<br>m/s | 6,14<br>m/s | -           | 0,23 m/s       | -              | -              | -              | 0,59        | -           |

Fonte: Autor, 2019.

## 5 6 CONCLUSÃO

Este trabalho teve como objetivo melhorar a previsão da velocidade do vento que foi alcançado. Os resultados obtidos mostram que os prognósticos WRF feitos em intervalos de 10 minutos se mostraram bem melhores do que o obtido em diversos estudos com médias horárias. O uso de RNA-NARX utilizando estes prognósticos, para fazer a previsão da velocidade do vento para o dia seguinte se mostrou uma opção viável.

A velocidade média OBS foi de 5,20 m/s enquanto que as médias WRF e RNA foram de 5,20 m/s e 5,32 m/s respectivamente.

Na comparação dos prognósticos RNA e WRF verificou-se o seguinte: Desvio médio quase nulo (-0,01 m/s versus -0,35 m/s); REQM inferior (1,18 m/s versus 1,24 m/s), coeficiente de correlação superior (0,70 versus 0,61).

Ficou evidente que o período escolhido para o treinamento (3 dias) implica em erros grandes quando existe muita variabilidade na série OBS e/ou WRF.

### 5.1 Sugestões para trabalhos futuros

A partir do que foi desenvolvido neste trabalho pode-se sugerir como propostas de trabalhos futuros o seguinte:

- Desenvolvimentos de outras arquiteturas de RNA para previsão da velocidade do vento, usar diferentes redes neurais para realizarem a mesma tarefa e fazer comparativos entre os resultados.
- Desenvolver uma ferramenta para ponderar atipicidade no período usado para prognóstico.
- Aumentar o período estudado da velocidade do vento para um ano e assim distinguir as quatro estações do ano (Outono, Inverno, Primavera e Verão) identificar períodos como quadra chuvosa, época de seca ou safra dos ventos.

## 6 - REFERÊNCIAS BIBLIOGRÁFICAS

**ABEEólica.** Associação Brasileira de Energia Eólica. Disponível em: <<http://abeeolica.org.br/>>. Acesso em: 20 jan. 2019.

AMARANTE, O. A. C. *et al.* **Atlas Eólico do Rio de Janeiro**, Governo do Estado RJ ó Secretaria de Estado de Energia, da Indústria Naval e do Petróleo, 2002.

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. 2015.

ANDIFES. **Pesquisa da UFAL revela potencial para produção de Energia Eólica em Alagoas.** Disponível em: < <http://www.andifes.org.br/pesquisa-da-ufal-revela-potencial-para-producao-de-energia-eolica-em-alagoas/>>. Acesso em: 18 jan. 2019.

**ATLAS DE ENERGIA ELÉTRICA DO BRASIL** / Agência Nacional de Energia Elétrica. 3º. Ed. ó Brasília: Aneel. 2008.

AYOADE, J. O. **Introdução à climatologia para os trópicos.** 5ª Ed. Rio de Janeiro: BCD União de Editorias S. A. 1998.

**BEN2018 - Balanço Energético Nacional.** Disponível em: <[www.epe.gov.br](http://www.epe.gov.br)>. Acesso em: 18 mar. 2019.

BEZERRA, E. C.; REGO, M. C. O. *et al.* **Comparação entre modelos estatísticos e RNA usando persistência como referência para a previsão da velocidade do vento.** X SBAI ó Simpósio Brasileiro de Automação Inteligente. São João Del-Rei, Minas Gerais. 2011.

**BORBA, J. C. C. Identificação do Potencial Eólico no Estado de Alagoas Utilizando Dados de Reanálise.** Dissertação (Mestrado em Meteorologia) - Universidade Federal de Alagoas, Maceió, 80 p. 2005.

**BRAGA, A. de P.; CARVALHO, A. P. L. F., LUDERMIR, T. B. Redes Neurais Artificiais Teoria e Aplicações.** 2ª edição, Rio de Janeiro: LTC. 2012.

**CAMELO, H. N. et al. Modelagem de média mensal de velocidade do vento para região litorânea no nordeste brasileiro através do método aditivo Holt Winters com vias a previsão de geração eólica.** Artigo científico. Revista Brasileira de Energias Renováveis. 20 p. 2016.

**CAMELO, H. N. et al. Modelagem da velocidade do vento usando metodologias ARIMA, Holt Winters e RNA na previsão de geração eólica no Nordeste Brasileiro.** Artigo Científico. Revista Brasileira de Climatologia. 18 p. 2017.

**CAMELO, H. N. et al. Proposta para previsão de velocidade do vento através de modelagem híbrida elaborada a partir dos modelos ARIMAX e RNA.** Artigo científico. Revista Brasileira de Meteorologia, v. 33, n.1, 115-129. 2018.

**CADENAS, E.; RIVERA, W. Previsão da velocidade do vento de curto prazo na La Venta, Oaxaca, México, usando rede neural artificial.** Energia Renovável 34, 2746278. 2009.

**CARDOSO, B. C. T. Estudo da eficiência da previsão numérica do tempo de curto prazo para o município de Maceió ó AL utilizando o modelo WRF.** Dissertação de Mestrado em Meteorologia. Universidade Federal de Alagoas. 95 p. 2018.

**CARVALHO, ANDRÉ. Redes Neurais Artificiais.** Artigo. Instituto de Ciências Médicas e Computação, Universidade de São Paulo. 2010.

CHAPMAN, S. J. **Programação em MATLAB para engenheiros**. 2ª edição, São Paulo: CENGAGE Learning, 2010.

COSTA, G. B.; LYRA, R. F. F. **Análise dos padrões de vento no Estado de Alagoas**. Revista Brasileira de Meteorologia (Impresso), V27, p.31 ó 38. 2012.

COSTA, L. M. **Previsão da energia eólica ó Santiago ó Cabo Verde**. Dissertação de Mestrado. Universidade do Porto. 81 p. 2013.

COSTA, R. C. **Modelos Preditivos de Velocidade de Vento para Sistemas Eólicos Baseados em Redes Neurais Artificiais**. Trabalho de Conclusão de Curso. Universidade Federal da Paraíba. 2016.

COUTO, V. M. *et al.* **Uso do modelo WRF para circulação superficial em Fortaleza durante o projeto Chuva**. Artigo científico. Revista Ciência e Natura, Santa Maria. 2013.

DA CRUZ, N. S. D. **Comportamento do vento e aproveitamento eólico na região central de Alagoas (Craíbas)**. Dissertação (Mestrado em Meteorologia) - Universidade Federal de Alagoas, Orientador: Roberto Fernando da Fonseca Lyra. 2017.

DA CRUZ, N. S. D.; LYRA, R. F. F.; FILHO, W. L. F. C. **Caracterização do vento na região de Craíbas ó AL para fins eólicos**. Artigo Científico. Revista Brasileira de Energias Renováveis. V.6, n.4, p. 811 ó 823. 2017.

DANCEY, Christine & REIDY, John. **Estatística Sem Matemática para Psicologia: Usando SPSS para Windows**. 3ª edição. Porto Alegre, Artmed. 2006.

**Divisão Territorial do Brasil e Limites Territoriais**. Instituto Brasileiro de Geografia e

Estatística (IBGE). 1 de julho de 2008. Acesso em: 30 mai. 2019.

ELETROBRAS. **Atlas eólico do estado de Alagoas**. v.1, 67p. 2008.

FERRAZ, R. S. F. *et al.* **Previsão multi ó passos da velocidade do vento através de redes neurais artificiais**. Artigo científico. 12º Congresso Latino ó Americano sobre geração e transmissão de eletricidade ó CLAGTEE. 2017.

FERREIRA, M. D. M. **Predição da velocidade do vento a curto prazo via modelos matemáticos**. Trabalho de Conclusão de Curso em Meteorologia. Universidade Federal do Rio Grande do Norte. 65 p. 2017.

FILHO, D. B. F.; JÚNIOR, J. A. S. **Desvendando os mistérios do coeficiente de correlação de Pearson**. Revista Política Hoje, Vol. 18, n.1. 2009.

FREIRE, A. L. *et al.* **Redes Neurais Recorrentes para predição recursiva de séries temporais caóticas: um estudo comparativo**. IX CBRN. Ouro Preto 25 - 28. 2009.

FREIRE, MARCELO. **Utilização de redes neurais na previsão da velocidade do vento**. Trabalho de Conclusão de Curso. Universidade Federal de Pernambuco, 2014.

FTHENAKIS, V.; KIM, H. C. **Uso da terra e geração de eletricidade: uma análise do ciclo de vida**. Revisões de Energia Renovável e Sustentável. 13 (6 ó 7): 1465-1474. 2009.

GWEC ó **Global Wind Energy Council**. Disponível em: <<https://bit.ly/2TcSdCI>>. Acesso em: 28 fev. 2019.

GILAT, A. **MATLAB ó Uma introdução com Aplicações**. Livro. Departamento de Engenharia Mecânica. Estados Unidos da América: John Wiley & Sons. 2006.

GOMES, F. P. **Curso de estatística experimental**. Livro 12<sup>a</sup> ed. São Paulo: Nobel, 467 p. 1990.

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, São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2011.

HAYKIN, Simon. **Redes Neurais Princípios e prática**. Livro 2<sup>a</sup> ed. Porto Alegre: Bookman, 2008.

HIDALGO, Pedro da Silva; **A influência da resolução espacial em modelos de previsão em meso escala na programação de despacho da produção de usinas eólicas**. Dissertação em Engenharia Elétrica. Universidade Federal do Pampa. 2014.

IHADUA, I. M. T. J. **Desempenho do modelo WRF para prognóstico da velocidade do vento em Girau do Ponciano - AL**. Trabalho de Conclusão de Curso. Universidade Federal de Alagoas. Janeiro de 2014.

JATOBÁ, B. R. G. *et al.* **Avaliação do potencial eólico para a cidade de Craíbas -AL utilizando o modelo WRF em alta resolução**. Revista brasileira de energias renováveis. 2017.

JIANG, Y.; SONG, Z.; KUSIAK, A. **Previsão da velocidade do vento de curtíssimo prazo com modelo de quebra estrutural Bayesiana**. Energia Renovável, v. 50, p. 637 - 647. 2013.

JUNIOR, Aparecido Nardo. **Aplicação de RNA utilizando o software matlab**. Trabalho de Conclusão de Curso em Ciência da Computação. Fundação de Ensino Eurípides Soares da Rocha. 77 p. Marília. 2005.

JUNIOR, O. L.; COSTA, E. M. M. **Redes Neurais: Fundamentos e Aplicações com Programas em C**. Rio de Janeiro: Editora Ciência Moderna Ltda. 2007.

KANI, S. A. P. *et al.* **Previsão da velocidade do vento de curtíssimo prazo óUma nova rede neural artificial ó Modelo de cadeia de Markov**. Energia Renovável, p. 738-745. 2011.

KOO, J. *et al.* **Previsão e análise da velocidade do vento baseado na geografia e distância de variáveis usando rede neural artificial: Um estudo de caso na Coréia do Sul**. Energy 93, 1296 ó 1302. 2015.

**Letras Ambientais**. Disponível em: <<https://letrasambientais.com.br>>. Acesso em: 01 mar. 2018.

LIMA, E. C.; SANTOS, I. A.; MOIZINHO, L. C. S. **Energia eólica no Brasil: Oportunidade e limitações para o desenvolvimento sustentável**. Revista Estudo & Debate, Lajeado, v.25, n.1. 2018.

LOPES, J. C. **I Workshop sobre o desenvolvimento de tecnologia nacional para o levantamento de potencial eólico**. INPE, São José dos Campos, Abril. 2010.

LOPEZ, R. A. **Energia Eólica, Energia e Meio Ambiente**. São Paulo: Artiliber. 2012.

LYRA, R. F. F. *et al.* **Prognóstico da velocidade do vento utilizando o modelo WRF na região central de Alagoas**. Ciência e Natura. 2016.

MABEL, M. C.; FERNANDEZ, E. **Análise de geração de energia eólica e previsão usando RNA: Um estudo de caso**. Energia Renovável, v. 33, p. 986-992, 2008.

MACHADO, V. C. *et al.* **Técnicas de Previsão**. Caparica: FCT/UNL, Cap. II. 2009.

MANTOVANI, W. A. **Utilização de redes neurais recorrentes na caracterização de cargas não lineares em sistemas elétricos**. Dissertação de mestrado. Universidade Estadual Paulista. Ilha Solteira. 2011.

MARIANO, E. B. **Simulação do modelo BRAMS para instalação de parque eólico no nordeste setentrional oriental do Brasil**. Tese de Doutorado. Universidade Federal de Campina Grande. 2017.

MARTINIANO, A. *et al.* **Utilizando uma rede neural artificial para aproximação da função de evolução do sistema de Lorentz**. Revista Produção e Desenvolvimento, v.2, n.1, p. 26 - 38. 2016.

**MATLAB ó Rede Neural Artificial Toolbox**. Guia do Usuário. The Math Works, Inc., Natick, Massachusetts, United States. 2012.

MATSUNAGA, V. Y. **Curso de redes neurais utilizando o MATLAB**. Belém, Pará, Brasil, 2012.

MCCULLOCH, W.; PITTS, W. **Um cálculo lógico de ideias imanentes na atividade nervosa**. Boletim de Biofísica e Matemática, vol. 5, PP. 115-133. 1943.

MICALICHEN, M. L. M. M. **Uso de dados meteorológicos observacionais e de reanálise para a estimativa da velocidade do vento nos níveis de aero geradores**. Dissertação de Mestrado em Métodos Numéricos em Engenharia. Universidade Federal do Paraná. 83 p. Curitiba. 2018.

MOLION, L. C. B.; BERNARDO, S. O. **Uma revisão da Dinâmica das Chuvas no Nordeste Brasileiro**. Revista Brasileira de Meteorologia. v. 17, n. 1, p.1-10. 2002.

MOURA, J. D. O. **Refinamento das simulações de vento do modelo WRF utilizando Redes Neurais Artificiais**. Trabalho de Conclusão de Curso. Universidade Federal de Alagoas. 2014.

OLIVEIRA, A. F. S. **Avaliação do modelo WRF na previsibilidade do vento para geração de energia eólica na região de Laguna ó SC**. Trabalho de Conclusão de Curso em Meteorologia. Universidade Federal de Santa Catarina. 45 p. 2017.

OLIVEIRA, A. C. **Implementação do modelo atmosférico WRF acoplado com o modelo hidrológico top modelo para a bacia de união da vitória**. Dissertação de mestrado. Universidade Federal do Paraná. 2006.

OLIVEIRA, L. S. **Regras e boas práticas para instalação de torres anemométricas voltadas para estudo de potencial eólico**. Dissertação de Mestrado em Planejamento Energético, Rio de Janeiro: COPPE - Universidade Federal do Rio de Janeiro. 2011.

OLIVEIRA, Josinaldo Bezerra. **Sistemas inteligentes e wavelets para previsão de vento e geração eólica**. Dissertação de Mestrado em Engenharia Elétrica. Universidade Federal de Pernambuco. 96 p. Recife. 2008.

OLIVEIRA, S. S. **Análise do potencial eólico do estado da Paraíba utilizando modelos de meso escala**. Tese de Doutorado. Universidade Federal de Campina Grande, abril de 2013.

PICOLO, A. P. *et al.* **Uma abordagem sobre a energia eólica como alternativa de ensino de tópicos de física clássica**. Revista brasileira de Ensino de Física. 2014.

PINTO, L. I. C. **Avaliação do modelo WRF para aplicação em previsão de recursos eólicos no nordeste brasileiro**. Tese de Doutorado. Curso de Pós-Graduação em Ciência do Sistema Terrestre. INPE. São José dos Campos. 245 p. 2017.

RAMALHO, G. L. B.; Dias, S. V. **Estimativa da velocidade média diária do vento no município de fortaleza utilizando redes neurais artificiais.** Revista Conexões v. 3, p. 12-15. 2009.

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 Meteorologia, São Paulo, v. 28, n. 2, p. 163 - 172. 2013.

RAMOS, D. N. S. **Mapeamento eólico do Estado de Alagoas utilizando ferramentas computacionais e dados observados.** Dissertação de Mestrado. Universidade Federal de Alagoas. 2012.

RODRIGUES, C. M. F. O. **Previsão de ventos locais em ambiente urbano conjugando CFD e RNA.** Dissertação de Mestrado em Engenharia Mecânica. Universidade de Aveiro, 93 p. 2008.

RODRIGUES, G. C. **Utilização de redes neurais para previsão de ventos no horizonte de 24 horas.** Dissertação de Mestrado em Engenharia Elétrica, Rio de Janeiro: COPPE-UFRJ, 119 p. 2007.

ROSENBLATT, F. **Princípios da Neurodinâmica.** Washington, Spartan Books, 1962.

ROSSI, Daniela Jardim. **Previsão da velocidade dos ventos por redes neurais artificiais e ARIMA de Box & Jenkins.** Dissertação de Mestrado em Engenharia Elétrica. Universidade Estadual Paulista. 76 p. 2014.

SHEPHERD, G. **A Organização sináptica do cérebro.** New York: Oxford University Press, 2003.

SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A. **Redes Neurais Artificiais para**

**engenharias e ciências aplicadas.** São Paulo: Artliber. 2010.

SILVA, A. R. **Caracterização do vento e potencial eólico no Estado de Alagoas.** Dissertação de Mestrado em Meteorologia, Maceió: Universidade Federal de Alagoas, 95 p. 2011.

SILVA JÚNIOR, R. S. *et al.* **Mapeamento do potencial eólico do Estado de Alagoas utilizando o modelo WRF.** Anais do I Seminário Nacional de Engenharia do Vento (SENEV). Belo Horizonte: UFMG, p. 6. 2010.

SILVA, S. M. S. *et al* **Avaliação do desempenho do Modelo WRF para prognóstico do vento na região central de Alagoas ó Craíbas.** Artigo Original de micro meteorologia. Ciência e Natura, p. 187 ó 192. 2018.

SILVA, S. S. *et al.* **Refinamento das estimativas da velocidade do vento feitas pelo modelo WRF usando redes neurais artificiais e modelo físico ó estatístico.** Artigo científico. X Workshop Brasileiro de Micro Meteorologia. Santa Maria ó RS. 2017.

SILVA, F. P. **Caracterização da camada limite atmosférica em Fortaleza ó CE.** Dissertação de Mestrado em Meteorologia. Universidade Federal de Campina Grande. 85 p. 2017.

SKAMAROCK, W. C. *et al.* **Uma descrição de pesquisa avançada sobre o modelo WRF versão 3.** Centro Nacional de Pesquisa Atmosférica (NCAR). Boulder, Colorado (EUA), p. 125. 2008.

SOARES, Carina Alexandra Carvalho. **Validação de estimativas do recurso eólico obtidas com o modelo numérico WRF.** Dissertação de Mestrado em Meteorologia. Universidade de Aveiro. 61 p. 2010.

SOMAN, S. S.; ZAREIPOUR, H.; MALIK, O.; MANDAL, P. **Uma revisão dos métodos de previsão de energia eólica e velocidade do vento com diferentes horizontes de tempo, em: América do Norte Symposium 2010.** P. 1 - 8. 2010.

SOUZA, L. P. **Utilização de redes neurais artificiais para simulação de precipitação ó vazão na bacia hidrográfica do rio Mundaú/AL.** Dissertação (Mestrado em Meteorologia) - Universidade Federal de Alagoas, Maceió. 2005.

SOUZA, S. P. M.; JÚNIOR, J. M. P. M. **Predição de séries temporais do reservatório da Usina Hidrelétrica de Sobradinho através de redes neurais recorrentes NARX.** XIV SEPODE, CIGRE - Brasil, Recife-PE, 2018.

TABLADA, L. G. N. **Utilizando Redes Neurais para Previsão de Velocidade do Vento.** Trabalho de Conclusão de Curso. Universidade Federal de Pernambuco. 2010.

WILKS, D. S. **Métodos estatísticos nas ciências atmosféricas.** Departamento de Ciências Terrestres e Atmosféricas da Cornell Universidade. Segunda Edição. 2006.

WILLMOTT, C.J. **Alguns comentários sobre a avaliação de desempenho do modelo.** Boletim da Sociedade Meteorológica Americana, v. 63, p. 1309 ó 1313. 1982.

ZHAO, Pan *et al* **Avaliação de desempenho e aprimoramento da precisão de um sistema de previsão de energia eólica na China.** Artigo científico. Renewable Energy, volume 43, p 234 ó 241. 2012.

ZUCATELLI, P. J. *et al.* **Previsão da velocidade do vento a curto prazo usando redes neurais artificiais em Mucuri, Bahia.** X CONEM. 2018.

## 7 6 ANEXOS

```
% Laboratório de Micro Meteorologia da Universidade Federal de Alagoas
% Aluno: Iwldson Guilherme da Silva Santos
% Objetivo: Previsão da velocidade do vento.
% Variáveis:
%     WRF - série temporal de entrada
%     OBS - série temporal de alvo
%     N - número de previsão

N = 144;
inputSeries = WRF(1:end-N);
inputSeries = tonndata(WRF,true,false);
targetSeries = OBS(1:end-N);
targetSeries = tonndata(OBS,true,false);

% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:2;
feedbackDelays = 1:2;
hiddenLayerSize = 26;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares time series data for a particular
network, shifting time by the minimum amount to fill input states and layer
states. Using PREPARETS allows you to keep your original time series data
unchanged, while easily customizing it for networks with differing numbers
of delays, with open loop or closed loop feedback modes.
[inputs,inputStates,layerStates,targets] =
preparets(net,inputSeries,{},targetSeries);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

net.trainParam.max_fail = 10;
net.trainParam.epochs = 1000;
net.trainParam.goal = 0.1;
net.affinity.memoryReducFon = 1;
net.trainParam.mu = 0.001;
net.trainParam.mu_dec = 0.8;
```

```

net.trainParam.mu_inc = 1.3;

% Train the Network
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)
output = cell2mat(outputs);

% View the Network
% view(net)

inputSeriesVal = WRF(end-N+1:end);
inputSeriesVal = tonndata(inputSeriesVal,true,false);
targetSeriesVal = OBS(end-N+1:end);
targetSeriesVal = tonndata(targetSeriesVal,true,false);

inputSeriesRef = [inputSeries(end-inputDelays+1:end),inputSeriesVal];
targetSeriesRef = [targetSeries(end-feedbackDelays+1:end),targetSeriesVal];

% Early Prediction Network
% For some applications it helps to get the prediction a time step early.
The original network returns predicted y(t+1) at the same time it is given
y(t+1). For some applications such as decision making, it would help to
have predicted y(t+1) once y(t) is available, but before the actual y(t+1)
occurs. The network can be made to return its output a time step early by
removing one delay so that its minimal tap delay is now 0 instead of 1.
The new network returns the same outputs as the original network, but
outputs are shifted left one time step.
nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
% view(nets)
[xs,xis,ais,ts] = preparets(nets,inputSeriesRef,{},targetSeriesRef);
RNA = nets(xs,xis,ais);
earlyPredictPerformance = perform(nets,ts,RNA)

```