

Previsão de Curto Prazo da Velocidade do Vento Utilizando Transformada de Wavelet Discreta e Rede Neural Artificial no Município de Craíbas-AL

Iwldson G. S. Santos¹, Francisco A. S. Souza²

UFCG, Campina Grande, PB

Isnaldo I. Barbosa³, Roberto F. F. Lyra⁴

UFAL, Maceió, AL

Resumo. O objetivo deste estudo é analisar a previsibilidade da velocidade do vento de curto prazo, utilizando Transformada de Wavelet Discreta (TWD) e Rede Neural Artificial (RNA) não linear autorregressiva com entradas externas (NARX) e sem entradas externas (NAR). Os prognósticos são aferidos com dados os observados (OBS) mensurados a cada 10 minutos, em uma torre anemométrica de 100 m de altura, localizada em Craíbas (Agreste de Alagoas) de 01/04 a 30/04 de 2015. Estes resultados, apesar de considerar um período curto de dados, indicam o potencial de aplicação da TWD e RNA na previsão da velocidade do vento.

Palavras-chave. Variável Meteorológica, Energia Eólica, Inteligência Artificial, Wavelet

1 Introdução

O Brasil tem padrões de ventos considerado um dos melhores do mundo para produção de energia eólica, pois possui condições climáticas favoráveis, velocidade do vento ao longo do ano e um fator de capacidade acima da média mundial ([14]). A Associação Brasileira de Energia Eólica (ABEEólica), informa que, ao final de 2020, o Brasil atingiu 17,75 GW de potência eólica instalada acumulada com quase 700 usinas eólicas instaladas e mais de 7500 aerogeradores em operação, distribuídos em 12 estados, sendo 8 da região Nordeste ([1]). O Nordeste Brasileiro (NEB) é a região que mais gera e consome energia eólica, pois apresenta maior fator de capacidade, maior capacidade eólica instalada acumulada e maior quantidade de parques eólicos instalados. Alagoas é o único Estado desta região que ainda não possui parque eólico. Vários estudos recentes indicam que o Estado tem potencial para produção de energia eólica e o Agreste alagoano é uma ótima opção para a construção de parques eólicos ([16]; [15]). O objetivo geral deste estudo é desenvolver e melhorar técnicas de previsão da velocidade do vento. Objetivo específico é analisar a introdução de métodos de processamento de sinais, conhecida como Transformada de Wavelet Discreta (TWD) para pré-processar os dados observados (OBS) que servirão de entrada e/ou destino para Rede Neural Artificial (RNA) não linear autorregressiva (NAR) e não linear autorregressiva com entradas externas (NARX).

¹iwldson@gmail.com

²fsouza2011@gmail.com

³isnaldo@pos.mat.ufal.br

⁴rffl@ccen.ufal.br

2 Materiais e Métodos

2.1 Área de estudo e dados observados

A Figura 1 apresenta o Brasil, Alagoas e Craíbas. Os dados utilizados foram medidos em uma torre anemométrica instalada em uma área plana do Município de Craíbas, região semiárida (Agreste) do Estado (09°53'03" S; 36°49'44" O; 244 m). As medidas foram realizadas durante a fase observacional do Projeto Previsão do Vento em Parques Eólicos no NEB (PVPN). As medições da velocidade, direção e rajadas de vento foram feitas a 50, 70 e 100 metros de altura, a cada 15 segundos. As médias foram armazenadas a cada 10 minutos em um datalogger CR1000 (Campbell Scientific Inc. – EUA) alimentado por um sistema de eletricidade fotovoltaica (modelo KS-20 da Kyocera) e calibrados de acordo com as diretrizes de órgãos internacionais ([6]). Neste estudo considerou-se apenas os dados observados (OBS) de velocidade do vento (m/s), mensurados a 50 m. O período estudado foi todo o mês de abril de 2015, totalizando 30 dias de análise.

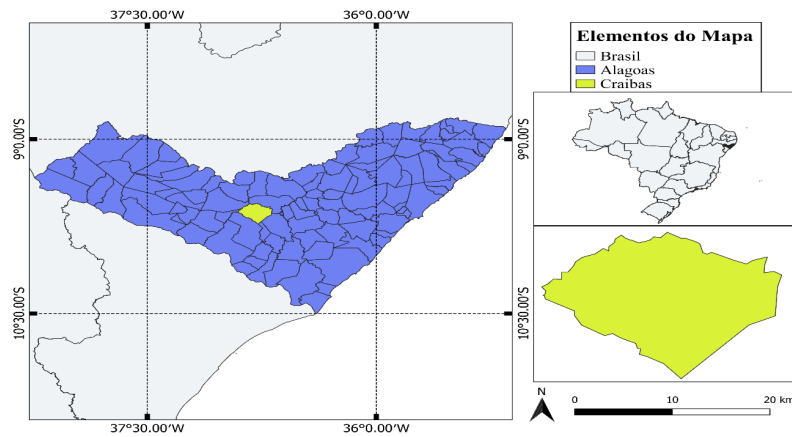


Figura 1: Localização geográfica da área de estudo. Fonte: Autores.

2.2 Transformada de Wavelet Discreta

A Transformação Wavelet (TW) é um método de processamento de sinal, que pode decompor o sinal em componentes de aproximação e componentes de detalhe. O tipo de Wavelet e os níveis de decomposição podem afetar profundamente o desempenho da TW ([8]; [9]). Existem dois tipos de TW utilizados: Transformada de Wavelet Contínua (TWC) e Transformada de Wavelet Discreta (TWD). A TWC pode ser descrita pela equação (1) a seguir:

$$TWC_x(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

onde $x(t)$ representa o sinal que será analisado, $\psi(t)$ representa a função Wavelet mãe, a denota o coeficiente de escala, b denota o coeficiente de translação e $*$ denota o conjugado complexo.

Substituindo $a = 2^j$ e $b = k2^j$ a TWD pode ser descrita pela equação (2) a seguir:

$$TWD_x(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t - k2^j}{2^j} \right) dt \quad (2)$$

onde j e k são o coeficiente de escala e coeficiente de translação, respectivamente.

A família de Wavelet utilizada foi a Daubechies (db4) com quatro níveis de decomposição, resultando em uma série de dados suavizada que chamaremos de WDB4. A escolha desta família de Wavelet Daubechies se deu pelo fato de fornecerem excelentes resultados no processamento de sinais, pois apresentam uma melhor caracterização dos coeficientes de Wavelets (detalhes e aproximação) e pelo grande número de estudos que a utilizaram em suas pesquisas, tais como ([7]; [2]; [12]; [17]).

2.3 Rede Neural Artificial

A previsão da velocidade do vento é via RNA (NAR e NARX). O funcionamento destas RNAs é praticamente idêntico, a principal diferença entre estas duas redes estão na introdução dos sinais de entrada e/ou alvo ([5]). Chamaremos de NAR o prognóstico da RNA-NAR realizado com apenas OBS funcionando como sinal de entrada e alvo. Chamaremos de WNAR o prognóstico da RNA-NAR feito com apenas WDB4 funcionando como sinal de entrada e alvo. Chamaremos de WNARX a previsão realizada pela RNA-NARX com WDB4 funcionando como sinal de entrada e OBS como sinal de alvo. Por fim, chamaremos de WNARX2 a previsão feita pela RNA-NARX com OBS funcionando como dado de entrada e WDB4 como dado de alvo.

Esta RNA foi configurada para fornecer a previsão da velocidade do vento para o dia seguinte. O triplo de dias utilizados para treinamento obteve os melhores resultados, ou seja, os três últimos dias de março (29, 30 e 31) são valores OBS e WDB4 iniciais utilizados para treinar, calibrar e validar a RNA que após esta fase extrapola a previsão da velocidade do vento para o dia seguinte (01 de abril). Novamente, utiliza-se três dias (30, 31 e 01) na fase de treinamento da RNA para depois gerar a previsão para o dia posterior (02 de abril). E assim por diante até utilizar os dias (27, 28 e 29 de abril) na fase de treino da RNA e na sequência produzir a previsão para o dia consecutivo (30 de abril) de acordo com o trabalho de Santos ([13]).

As RNAs e os parâmetros utilizados neste estudo tiveram como referência os trabalhos de Gonçalves ([4]) e Moura ([10]). A Tabela 2.3 mostra a configuração final na fase de treinamento da RNA. Na fase de previsão a arquitetura final da RNA é composta por uma camada de entrada (Input) como os dados OBS e WDB4 funcionando como sinal de entrada e/ou alvo ($x(t)$ e/ou $y(t)$), por uma camada escondida (Hidden) com 26 neurônios e função de ativação Tangente hiperbólica (Tansing), camada de saída (Output) com 1 neurônio e função de ativação Linear (Purelin), delay, pesos, bias e um sinal de saída $y(t + 1)$ que representa a previsão da velocidade do vento.

Tabela 1: Parâmetros utilizados na fase de treinamento das RNAs.

Parâmetros	Dados/valores
Sinais de entrada/alvo	OBS/WDB4
Algoritmo de treinamento	Levenberg-Marquardt (LM)
Algoritmo de desempenho	Erro médio quadrado
Épocas	1000
Verificação	10
Gradiente	0,00001
Treinamento, Teste e Validação	70%, 15% e 15%
Camada escondida	1
Atraso de entrada	1:2
Neurônios na camada escondida	26
Função de ativação	Tangente hiperbólica
Camada de saída	1
Função de ativação	Linear
Neurônios na camada de saída	1

2.4 Análise Estatística

Inicialmente é feita uma estatística univariada para descrever a análise separada dos dados (médias, mínimos, máximos, desvio padrão e variância), depois é feita uma estatística bivariada para descrever um relacionamento entre OBS e os prognósticos. As métricas estatísticas utilizadas foram erro médio, raiz do erro quadrático médio, erro percentual absoluto médio, coeficiente de correlação de Pearson, coeficiente de determinação e regressão linear simples.

Os três dias 29, 30 e 31 de março são dados iniciais e são utilizados unicamente para treinamento da RNA e não entram na fase de análise estatística. O número total de valores, N , é de 4.320, o índice, i , varia de 1 a N , RNA_i e OBS_i são os valores previstos e observados com seus respectivos índices \overline{RNA} e \overline{OBS} são os valores previstos e observados médios.

Em resumo, as etapas sequenciais do processo de previsão da velocidade do vento realizado neste estudo começam com os dados OBS sendo pré-processados pela TWD gerando outra série de dados chamada de WDB4. Estas duas séries são introduzidas nas RNAs como dados iniciais de entrada e/ou alvo, as RNAs treinam, testam e validam estes dados para depois extrapolar os dados de previsão da velocidade do vento para o dia seguinte, chamados de NAR, WNAR, WNARX e WNARX2. Por fim, é feita uma análise estatística e todos os prognósticos são comparados com a série OBS para averiguar qual prognóstico obteve melhor acurácia na precisão da previsão.

O pré-processamento dos dados OBS feito pela TWD, a previsão da velocidade do vento via RNAs, as análises estatísticas (univariada e bivariada) e todos os gráficos foram realizados no software computacional MATLAB (versão R2021b).

3 Resultados e Discussões

A Figura 2 mostra a evolução temporal da velocidade do vento observada e prevista no período estudado. Em todos os gráficos verifica-se a reprodução do padrão diário de variabilidade da velocidade do vento, e captura com certa similaridade a magnitude das velocidades máximas e mínimas diárias da velocidade do vento. No entanto, existem alguns períodos do dia em que se observa clara discordância entre os valores previstos e observados.

A maior diferença entre as séries previstas NAR, WNAR, WNARX e WNARX2 são as oscilações de baixa frequência, fica evidente que com a presença de WDB4 os prognósticos apresentam valores mais suaves diminuindo as pequenas oscilações.

Geralmente, quando OBS apresenta uma variabilidade diária diferente dos dias anteriores todas as previsões não conseguem representar bem esta mudança de comportamento do vento. Os prognósticos das RNAs carregam características da velocidade do vento dos dias usados para treinamento, ou seja, se os ventos que irão ser previstos forem muito distintos dos ventos anteriores usados para treinamento das RNAs, isto indica que a acurácia da previsão não será precisa.

A Tabela 2 mostra a estatística univariada e bivariada dos resultados. Nela podemos observar que todos os valores da estatística univariada foram próximos, as velocidades médias variaram de 5,47 m/s (WNAR) a 5,53 m/s (OBS e WDB4). As velocidades mínimas variaram de 0,01 m/s (OBS e WNARX) a 0,60 m/s (WDB4). As velocidades máximas variaram de 11,56 m/s (WDB4) a 13,06 m/s (WNARX). O desvio padrão variou de 2,38 m/s (WNARX2) a 2,47 m/s (WNARX). A variância variou de 5,66 m²/s (WNARX2) a 6,10 m²/s (WNARX).

Os EM foram próximos de zero, variaram de -0,06 m/s (WNAR) a 0,0001 m/s (WDB4). Todos os prognósticos subestimaram OBS. A REQM de todos os resultados variou de 0,37 m/s (WDB4) a 1,49 m/s (WNARX). O EPAM variou de 10,35% (WDB4) a 42,71% (WNARX). O coeficiente de correlação de Pearson variou de 0,71 (NAR e WNARX) a 0,98 (WDB4).

Vale salientar que WDB4 não é um prognóstico é uma técnica que decompõe o sinal OBS, ela aumentou o valor mínimo e diminuiu o valor máximo de OBS nos períodos de baixa frequência,

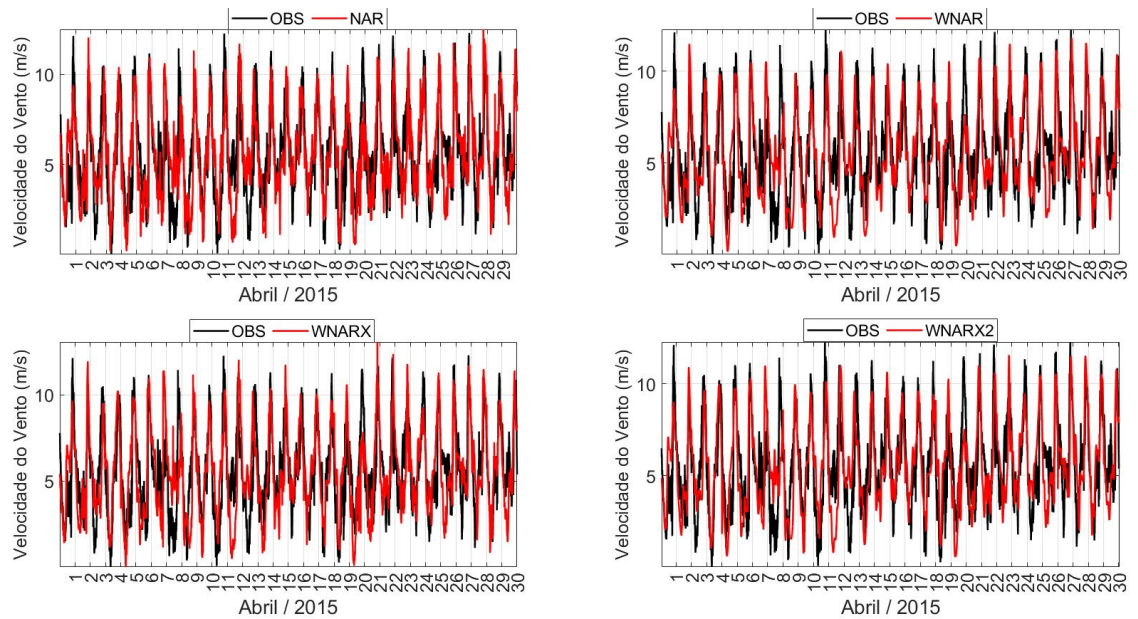


Figura 2: Evolução temporal da velocidade do vento das séries OBS (linha preta), NAR, WNAR, WNARX e WNARX2 (linhas vermelhas). Fonte: Autores.

manteve-se inalterada nos períodos de alta frequência e conservou as características de OBS. É importante destacar que apesar do caráter intermitente do vento e isto dificulta a sua previsibilidade, todos os erros dos prognósticos foram inferiores à margem do erro dos anemômetros (0,2 m/s).

Tabela 2: Estatística univariada e bivariada entre os dados observados, suavizado e previstos.

Série	Med	Min	Max	DP	Var	EM (m/s)	RDQM (m/s)	EPAM (%)	CP
OBS	5,53	0,01	12,29	2,46	6,04	-	-	-	-
WDB4	5,53	0,60	11,56	2,40	5,75	0,0001	0,37	10,35	0,98
NAR	5,52	0,19	12,49	2,39	5,72	-0,01	1,44	41,72	0,71
WNAR	5,47	0,16	11,82	2,42	5,85	-0,06	1,45	41,71	0,72
WNARX	5,49	0,01	13,06	2,47	6,10	-0,04	1,49	42,71	0,71
WNARX2	5,51	0,55	11,58	2,38	5,66	-0,02	1,43	41,81	0,72

A Figura 3 mostra os gráficos de dispersão no período estudado entre as variáveis dependentes (NAR, WNAR, WNARX e WNARX2) e variável preditora (OBS). Os parâmetros resultantes como coeficiente linear variaram de 1,57 a 1,71 e coeficiente angular variaram de 0,69 a 0,71. As equações das retas dadas pelas regressões lineares simples foram: $NAR=1,71+0,69xOBS$; $WNAR=1,57+0,70xOBS$; $WNARX=1,58+0,71xOBS$ e $WNARX2=1,67+0,69xOBS$. Os coeficientes de determinação pouco variaram de 0,50 a 0,51, indicando que 50 a 51% das variáveis dependentes são explicadas pelas variáveis observadas.

Os resultados deste estudo são equiparáveis aos encontrados na literatura ([4]; [10]; [11]; [3]). Os valores do EM dos trabalhos analisados estão variando entre -0,32 m/s e 0,15 m/s enquanto neste estudo variou entre -0,06 m/s e -0,01 m/s. Os valores de REQM obtidos em trabalhos analisados estão entre 0,89 m/s e 1,73 m/s enquanto neste estudo variou entre 1,43 m/s e 1,49 m/s. O EPAM dos trabalhos analisados variou entre 12,01% e 23% enquanto neste estudo os valores permaneceram

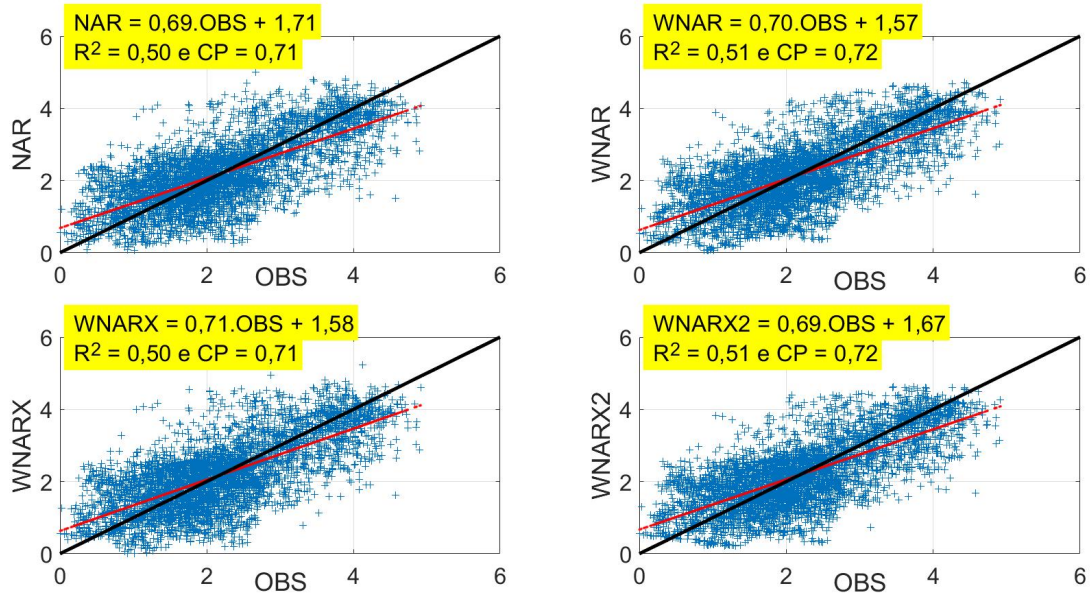


Figura 3: Gráfico de dispersão entre NAR, WNAR, WNARX e WNARX2 com OBS. Fonte: Autores.

muito acima deste intervalo variando entre 41,71% e 42,71%. Por fim, as correlações dos trabalhos analisados variaram entre -0,31 e 0,89 enquanto neste estudo variou entre 0,71 e 0,72.

Em geral, os resultados deste estudo, quando comparados à literatura, são considerados de satisfatórios a bons. 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.

4 Considerações Finais

Este estudo teve como objetivo avaliar o método de processamento de sinal TWD e prognósticos via RNA. Todos os resultados obtidos reproduziram bem a evolução temporal da velocidade do vento.

A TWD suavizou os mínimos e máximos e conservou as características principais de OBS. Todos os valores das métricas estatísticas utilizadas corresponderam aos resultados de trabalhos similares analisados. A maior limitação dos prognósticos é reproduzir dias atípicos.

Por fim, os resultados mostraram que a utilização de RNA com ou sem TWD são opções viáveis para prognóstico da velocidade do vento.

Referências

- [1] ABEEOLICA. **Associação Brasileira de Energia Eólica**. Online. Acessado em 28/12/2021, <https://abeeolica.org.br/>.
- [2] Farid Berzezzek, Khaled Khelil e Tahar Bouadjila. “Efficient wind speed forecasting using discrete wavelet transform and artificial neural networks”. Em: **Revue d’Intelligence Artificielle** 33.December, 2019, (2019).

- [3] Moniki Ferreira, Alexandre Santos e Paulo Lucio. “Short-term forecast of wind speed through mathematical models”. Em: **Energy Reports** 5 (2019), pp. 1172–1184.
- [4] André Rodrigues Gonçalves. **Refinamento estatístico das previsões de vento do modelo ETA aplicado ao setor eólico-elétrico do Nordeste Brasileiro**. 2011.
- [5] Simon Haykin. **Redes neurais: princípios e prática**. Bookman Editora, 2001.
- [6] Rosiberto Salustiano Da Silva Junior et al. “Prognóstico do vento para o Estado de Alagoas utilizando o modelo WRF em alta resolução: avaliação da melhoria da topografia, uso do solo e velocidade de fricção”. Em: **Ciência e Natura** 38 (2016), pp. 137–144.
- [7] Khaled Khelil, Farid Berrezzek e Tahar Bouadjila. “GA-based design of optimal discrete wavelet filters for efficient wind speed forecasting”. Em: **Neural Computing and Applications** 33.9 (2021), pp. 4373–4386.
- [8] Hui Liu, Xiwei Mi e Yanfei Li. “Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network”. Em: **Energy Conversion and Management** 166 (2018), pp. 120–131.
- [9] Stephane G Mallat. “A theory for multiresolution signal decomposition: the wavelet representation”. Em: **IEEE transactions on pattern analysis and machine intelligence** 11.7 (1989), pp. 674–693.
- [10] José Davi Oliveira de Moura. “Refinamento das simulações de vento do modelo WRF utilizando Redes Neurais Artificiais”. Em: **Monografia, Curso de Graduação em Meteorologia. Universidade Federal de Alagoas, Maceió, Alagoas** (2014).
- [11] Henrique do Nascimento Camelo et al. “Proposta para previsão de velocidade do vento através de modelagem híbrida elaborada a partir dos modelos ARIMAX e RNA”. Em: **Revista Brasileira de Meteorologia** 33 (2018), pp. 115–129.
- [12] Haidar Samet, Mohammad Reisi e Fatemeh Marzbani. “Evaluation of neural network-based methodologies for wind speed forecasting”. Em: **Computers & Electrical Engineering** 78 (2019), pp. 356–372.
- [13] Iwldson Guilherme da Santos. “Previsão da velocidade do vento na escala do parque Eólico utilizando o modelo WRF e Rede Neural e Artificial”. Em: (2019).
- [14] Iwldson Guilherme da Silva Santos, Roberto Fernando da Fonseca Lyra e Rosiberto Salustiano da Silva Júnior. “Comparativo de Prognósticos da Velocidade do Vento Utilizando Modelo WRF e Rede Neural Artificial”. Em: **Revista Brasileira de Meteorologia** 35 (2021), pp. 1017–1027.
- [15] Silvania Maria Santos da Silva et al. “Estudo dos parâmetros aerodinâmicos para melhoria da previsão do vento no estado de Alagoas”. Em: (2018).
- [16] Iwldson Guilherme da Silva Santos e Roberto Fernando da Fonseca Lyra. “Análise do Potencial de Previsão da Velocidade do Vento Utilizando Rede Neural Artificial”. Em: **Anuário do Instituto de Geociências** 43.4 (2020), pp. 11–17.
- [17] Chuanjin Yu, Yongle Li e Mingjin Zhang. “An improved wavelet transform using singular spectrum analysis for wind speed forecasting based on elman neural network”. Em: **Energy Conversion and Management** 148 (2017), pp. 895–904.