

Estimação da Velocidade do Vento utilizando Transdutores Ultrassônicos baseada em Rede Neural Artificial

Lucas D. de Oliveira* José H. B. da Silva* Juan M. M. Villanueva*

* Departamento de Engenharia Elétrica, Universidade Federal da Paraíba, PB, e-mail: (lucasd.oliveira, jose.dasilva, jmauricio)@cear.ufpb.br.

Abstract: The measurement of wind speed is of interest in several applications, such as wind power generation, mainly for the optimal determination of locations for the installation of wind farms. In the current scenario, the ways of measuring this quantity are diverse, however, when the design restrictions point to a measurement with sufficient accuracy, instruments based on ultrasonic sensors stand out, as they present a low uncertainty compared to conventional mechanical instruments. In this sense, its measurement principle requires the estimation of the Time of Flight (ToF), which is the travel time of the ultrasonic signal from the transmitting transducer to its detection in the receiving transducer. Therefore, the conventional techniques for estimating the ToF are those based on time intervals and digital signal processing, but there are, on the other hand, those based on artificial intelligence. In this article, an artificial intelligence model based on Artificial Neural Networks capable of estimating the wind speed is presented. Furthermore, the construction process is described, as well as its experimental results commented.

Resumo: A medição da velocidade do vento é de interesse em diversas aplicações, como a geração de energia eólica, principalmente para a determinação ótima de locais para instalação de parques eólicos. No cenário atual, as formas de medição desta grandeza são diversas, porém, quando as restrições de projeto apontam para uma medição com precisão suficiente, os instrumentos baseados em sensores ultrassônicos se destacam, pois apresentam uma baixa incerteza em relação aos instrumentos mecânicos convencionais. Nesse sentido, seu princípio de medição requer a estimação do Tempo de Voo (ToF), que é o tempo de viagem do sinal ultrassônico desde o transdutor transmissor até sua detecção no transdutor receptor. Portanto, as técnicas convencionais para estimar o ToF são aquelas baseadas em intervalos de tempo e processamento digital de sinais, mas existem, por outro lado, aquelas baseadas em inteligência artificial. Neste artigo, um modelo de inteligência artificial baseado em Redes Neurais Artificiais capaz de estimar a velocidade do vento é apresentado. Além disso, seu processo de construção é descrito, assim como os resultados experimentais comentados.

Keywords: Ultrasonic; Ultrasonic Transducers; Wind Speed; Time of Flight; ToF; Artificial Intelligence; Artificial Neural Networks; ANN

Palavras-chaves: Ultrassônico; Transdutores Ultrassônicos; Velocidade do Vento; Tempo de Voo; ToF; Inteligência Artificial; Redes Neurais Artificiais; RNA

1. INTRODUÇÃO

O uso de transdutores ultrassônicos é uma tendência atual. Existem diversos arranjos e aplicações para esses componentes elétricos, principalmente no que diz respeito aos processos industriais, uma vez que o controle da produção é parte fundamental para o sucesso de um ambiente fabril. Como exemplo, existem vários estilos de medição, como temperatura, pressão, níveis de tanque e distâncias (Hauptmann, Hoppe and Puettmer, 2001). Mais especificamente, outras características também podem ser estimadas: aspectos químicos de soluções, atributos de reações químicas, velocidade de fluidos, entre outros são destacados no cenário atual de utilização de transdutores ultrassônicos. Como usuários dessa tecnologia, estão os

anemômetros ultrassônicos, instrumentos capazes de medir a velocidade do vento e a principal tendência para medir essa grandeza. De fato, esse cenário se justifica por um conjunto de características que diferenciam esse tipo de instrumento dos modelos mecânicos usuais, que podem ser considerados por alguns como desatualizados por apresentarem alta margem de erro em suas medições (Lihua and Dawei, 2019). Nesse sentido, os anemômetros ultrassônicos são considerados mais vantajosos, pois seu projeto é baseado no envio e recebimento de ondas sonoras por transdutores ultrassônicos, ignorando questões como atrito entre peças ou inércia de componentes (Fernandes, Gomes and Costa, 2017). Portanto, as vantagens que diferenciam os anemômetros ultrassônicos dos métodos convencionais são baseadas nas seguintes características.

Método não-invasivo: devido à natureza das ondas ultrassônicas, é possível estimar a velocidade dos fluidos independentemente do sistema principal. Um exemplo disso é a medição da velocidade de líquidos em tubos fechados. Baixo custo e pequeno volume: composto por pares de transdutores ultrassônicos e outros equipamentos eletrônicos simples, esse tipo de sistema não tem preço de mercado alto e o espaço que ocupa é menor que o de um anemômetro de copo, por exemplo. Alta precisão: a partir de uma boa calibração do sistema e do uso correto dos algoritmos de estimação, é possível reduzir consideravelmente o erro médio na velocidade do vento.

Em geral, existem algumas formas de medir a velocidade dos fluidos através das ondas sonoras, a principal, porém, é a partir do seu tempo de voo (ToF). Seu cálculo é baseado no intervalo de tempo que enquadra o movimento da onda ultrassônica através do ambiente externo desde o transdutor emissor até o transdutor receptor. Esse raciocínio implica que, a partir de oscilações na estimativa desta variável, possam ser feitas conclusões sobre o ambiente da rota.

Especificamente para a medição da velocidade do vento, questões como o ruído e o tempo de conversão inerente aos transdutores devem ser compensados, por isso, vários dispositivos foram desenvolvidos ao longo dos anos com o objetivo de otimizar seus cálculos. Em resumo, existem dois ramos principais de desenvolvimento, considerando questões como ruído do sinal recebido e alguns fatores físicos: algoritmos baseados em intervalos e janelas de tempo, como Diferença de Fase e Detecção de Limiar, e algoritmos baseados em técnicas de processamento digital de sinal, como o Filtro de Kalman, a Transformada Wavelet e a Transformada de Fourier (Gerasimov, Glushnev and Panov, 2018). No entanto, existem aqueles baseados em inteligência artificial.

Portanto, o objetivo desse artigo é demonstrar o processo de elaboração, treinamento, validação e teste de um algoritmo de aprendizado profundo utilizando RNAs (redes neurais artificiais) capaz de prever a velocidade do vento através de três variáveis: a distância entre os transdutores, a temperatura do ambiente e o ToF teórico da onda ultrassônica. Para isso, o processo de fundamentação teórica e método de construção do modelo são detalhados e aprofundados.

2. FUNDAMENTAÇÃO TEÓRICA

Nessa seção, serão abordados os conceitos necessários para a elaboração dessa pesquisa. Assim, são apresentados os modelos físicos e matemáticos utilizados.

2.1 Modelo de Estimação do Tempo de Voo Ultrassônico

Em (Villanueva, Catunda and Tanscheit, 2009) é proposto um sistema de transdutores com inclinação θ com o eixo horizontal e posicionados em lados opostos de um túnel de vento fechado. Essa configuração da Figura 1 servirá de base para o desenvolvimento teórico e prático desse artigo.

A partir da imagem, TX representa o transdutor emissor e RX o receptor. Nesse sentido, 4 variáveis principais influenciam os valores da velocidade do vento ϑ :




Figura 1. Configurao de estimaco da velocidade do vento utilizando transdutores ultrassnicos.

- Temperatura Ambiente (T_K): as ondas sonoras, na ausncia de qualquer corrente de ar, tm sua velocidade igual à velocidade do som C (Kaimal and Businger, 1963).

$$C \approx 20.074\sqrt{T_K} \quad (1)$$

- Distncia entre transdutores (L): logicamente, quanto maior a distncia entre os transdutores, maior ser o ToF da onda ultrassnica, logo, menor ser a ϑ .
- Ângulo dos transdutores (θ): ângulos de inclinao menores entre os transdutores resultam em menores ToF .
- Tempo de Voo da Onda Ultrassnica (ToF): valores mais baixos de ToF implicam em maiores ϑ .

Assim, é possvel descrever a velocidade do vento ϑ seguindo essa configurao.

$$\vartheta = \frac{1}{\cos(\theta)} \left(\frac{L}{ToF} - C \right) \quad (2)$$

2.2 Diferena de Fase (DF)

O rudo inerente ao funcionamento do transdutor RX aps amplificao de sinal no permite a medio do ToF diretamente, portanto, tendo em vista este aspecto, a tcnica DF consiste em uma estimativa mais robusta. Resumidamente, este mtodo se baseia na medio da diferena de fase entre as ondas emitidas pelo TX e recebidas pelo RX. Nesse raciocnio, o conceito de diferena de fase, expresso em radianos ou segundos, aplica-se a ondas que possuem a mesma frequncia e em referncia ao mesmo ponto no tempo (Figura 2). Portanto, este mtodo permite obter a janela de tempo que distancia duas oscilaes com as mesmas caractersticas. Na aplicao proposta, quanto maior a diferena de fase entre as oscilaes, maior ser o ToF , devido à influncia dos fatores externos citados anteriormente.

Matematicamente, reescrevendo a Equao 5, ϑ é expresso em (Villanueva, Catunda and Tanscheit, 2009) por:

$$\vartheta = \frac{1}{\cos(\theta)} \left(\frac{2\pi f L}{\Phi} - C \right) \quad (3)$$




Figura 2. Determinação do ToF utilizando o método DF em uma representação na ausência de ruído.

em que:

$$\Phi = 2\pi n - \Delta\Phi \quad (4)$$

$$n = \left\lceil \frac{Lf}{C} \right\rceil \quad (5)$$

Onde: $\Delta\Phi$ representa a diferença de fase calculada em radianos, enquanto n refere-se ao número inteiro mais próximo de (5), e f representa a frequência da onda. Além disso, calibrações devem ser realizadas para garantir a assertividade dessa técnica diante de situações específicas, como na ausência de correntes de ar. Assim, os deslocamentos em $\Delta\Phi$ são executados sob a seguinte condição:

$$\Delta\Phi^* = \Delta\Phi + 2\pi \langle \Delta\Phi < \Delta\Phi_0 \rangle \quad (6)$$

em que:

$$\Delta\Phi_0 = 2\pi \left(n - \frac{Lf}{C} \right) \quad (7)$$

A equação (6) tem um componente condicional: se a diferença de fase medida for menor que a diferença de fase com velocidade do vento zero, então $\langle \cdot \rangle$ é igual a 0, caso contrário 1. Finalmente, a diferença de fase corrigida é representada por $\Delta\Phi^*$.

2.3 RNAs Aplicadas a Medição

A justificativa para o uso de algoritmos de aprendizado de máquina estruturados em RNAs baseia-se na estimação da relação não linear entre variáveis em um método empírico. Dito isso, aplicações tornam-se possíveis em diversos setores, como no controle avançado de processos industriais (Morris et al., 2018), na estimativa do potencial de energia solar de diferentes locais (Kutucu and Almryad, 2016), na estimativa do rendimento energético do vento em usinas eólicas (Mabel and Fernandez, 2009), na previsão da velocidade do vento com base em dados meteorológicos (Ghanbarzadeh et al., 2009) e assim por diante.

Nessa linha de raciocínio, o modelo de IA proposto nesse artigo é baseado no conceito de aprendizado supervisionado: uma regressão múltipla usando uma RNA *Feed-forward* multicamadas para estimar a velocidade do vento. Mais especificamente, o aprendizado supervisionado ocorre quando o modelo aprende a partir de entradas e saídas predefinidas, ou seja, são fornecidos exemplos reais para realizar previsões computacionais. Em paralelo, os algoritmos

de regressão múltipla são análises usadas para modelar a relação entre uma variável contínua e outras variáveis de que podem ser contínuas, discretas ou categóricas.


3. MÉTODO PROPOSTO

Os tópicos a seguir caracterizam as etapas do processo prático de elaboração de um modelo de inteligência artificial baseado em RNAs.


3.1 Simulação: Sistema de Transdutores Ultrassônicos

Para criação de um banco de dados extenso para modelar um algoritmo de aprendizado supervisionado, é necessário utilizar dados factíveis e processamento computacional. Para tanto, o funcionamento integrado dos transdutores TX e RX juntamente com a influência externa das variáveis citadas foram simulados utilizando *MATLAB* e *Simulink*, conforme a Figura. 3.

Estágio I



Estágio II



Estágio III

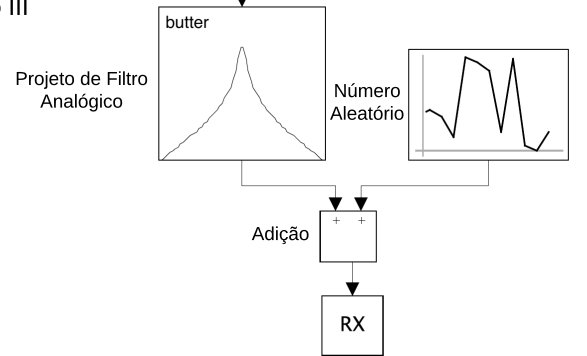


Figura 3. Modelo Simulink para comunicação entre TX e RX.

No Estágio I, simula-se o funcionamento do TX, portanto, para emitir intervalos de onda senoidal periódica, foi utilizado o produto de um gerador de pulso com uma onda senoidal. Logicamente, o ToF atua neste sistema como uma janela de tempo, então um agente de atraso

combinado com um *ToF* teórico representa o Estágio II. Para RX, deve-se prestar atenção à taxa de conversão natural dos transdutores do receptor. Nesse sentido, para espelhar tal dinâmica no Estágio III, foi aplicado ao sinal um filtro ButterWorth, componente este caracterizado como um filtro passa-faixa com banda passante de 37 kHz a 43 kHz, que proporciona uma saída flat em sua resposta em frequência. Além disso, diferentes ruídos gaussianos de variâncias fixas foram aplicados ao RX. Nesse sentido, brevemente, o modelo transmitirá sinais pulsados de 40 kHz adicionados de um ruído e do *ToF* em um tempo de simulação de 500 μ s. Assim, a Figura 4 ilustra o resultado do modelo proposto, o que valida a teoria inicial mencionada.




Figura 4. Resultado do modelo Simulink para comunicação entre TX e RX.

Por fim, considerando aspectos como acurácia das medidas e robustez em relação a sinais ruidosos, o método DF foi utilizado para a elaboração do banco de dados.

3.2 Construção do Banco de Dados

Para desenvolver um modelo de aprendizado supervisionado e medir seu desempenho, é indispensável o uso de um banco de dados, que é subdividido em conjuntos de dados para as fases de treinamento, validação e teste. Nesse sentido, sua estrutura é baseada na presença de variáveis preditoras e variáveis alvo que possuem relações não lineares. Portanto, o banco de dados gerado possui 6302 instâncias compostas pelas variáveis preditoras L , T_K , ToF e a variável alvo ϑ estimada pelo método DF (Tabela 1). Como mencionado, diferentes ruídos gaussiano teórico R de variância fixas foram atribuídos à operação RX de forma integrada.

Tabela 1. Estatísticas do Banco de Dados

Atributos	Variáveis Preditoras			Variável Integrada	Variável Alvo
	L	T_K	ToF	R	ϑ
Intervalo	0,1m - 0,15m	293,15°K - 313,15°K	2,691e-04s - 4,356e-04s	-	1m/s - 25m/s
Média	0,125m	303,15°K	3,484e-04s	-	13m/s
Mediana	0,125m	303,15°K	3,486e-04s	-	13m/s
Variância	4e-04	36,68	3,25e-09	0,001 - 0,01	52,02
Desvio Padrão	0,02	6,05	5,70e-05	0,031 - 0,1	7,21

Todas as variáveis do banco de dados foram normalizadas, ou seja, convertidas para o intervalo contínuo (0,1) e foi realizado um processo de randomização. Esses procedimentos contribuem para a mitigação das probabilidades

de *overfitting*, fenômeno que descreve um algoritmo estatístico adequado aos dados de treinamento e validação, mas incapaz de prever os resultados desejados (Li et al., 2019).

4. PREPARAÇÃO DO MODELO

O processo de adaptação de uma RNA consiste em um esforço de otimização: obter pesos sinápticos que minimizem a relação de erro entre a saída estimada pelo modelo e a saída real. Nesse sentido, para obter uma boa generalização, a escolha de uma arquitetura de rede *Feedforward* multicamadas justifica-se pelo aumento do poder computacional de processamento e armazenamento não linear da rede. Assim, tendo em vista o conceito de aprendizado supervisionado, na Tabela 2 foi proposta a seguinte divisão de banco de dados:

Tabela 2. Divisão do Banco de Dados

Base de Dados	Porcentagem do Banco de Dados
Treinamento	70%
Validação	10%
Teste	20%

Em adição, para o estabelecimento do modelo, alguns parâmetros devem ser especificados.

Tabela 3. Parâmetros do Modelo

Camadas	Parâmetros			
	Número de Neurônios	Função de Ativação	Otimizador	Métricas de Desempenho
Camada de Entrada	-	ReLu	Adam	MSE, MAE
1ª Camada Oculta	64	ReLu		
2ª Camada Oculta	128	ReLu		
3ª Camada Oculta	64	ReLu		
Camada de Saída	1	-		

4.1 Número de Neurônios Artificiais e Camadas Ocultas

Em *Deep Learning*, as camadas ocultas concentram a maior parte do setor de aprendizado de um modelo. Assim, cada camada consiste em um conjunto de neurônios que representa uma transformação matemática aplicada à camada anterior e assim por diante. A partir dos experimentos, foi encontrada uma minimização ótima da razão de erro através do uso de 3 camadas ocultas com, respectivamente, 64, 128 e 64 neurônios artificiais.

4.2 Função de Ativação

A partir da soma ponderada dos sinais de entrada em um neurônio, é emitida uma saída específica, o agente responsável por realizar tal conversão é a função de ativação. Na grande maioria dos casos não lineares, as funções de ativação funcionam dentro de uma faixa de excitação. No modelo proposto, tendo em vista o processo de normalização realizado, uma função de ativação ideal deve conter o intervalo (0,1). Assim, foi escolhida a Unidade Linear Retificada (ReLu), cujo intervalo de ativação é (0, $+\infty$).

4.3 Otimizador

No mesmo cenário, esses componentes realizam procedimentos para atualizar dinamicamente os pesos sinápticos com base nos dados de treinamento. O otimizador escolhido foi o Adaptive Moment Estimation (Adam), devido à sua rápida convergência com grandes bancos de dados quando comparado a outros métodos estocásticos de otimizadores.

4.4 Métricas de Desempenho

Para avaliar o desempenho do algoritmo em situações de treinamento e previsão, é necessário o uso de indicadores. Para isso, existem métricas específicas dependendo da estrutura e função do modelo. Nesse raciocínio, os modelos de regressão múltipla ou simples são qualificados através da relação de erro entre o resultado estimado e a saída desejada. Assim, as métricas de desempenho escolhidas foram:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - y^m)^2 \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - y^m| \quad (9)$$

Em que y representa os valores reais e y^m os valores estimados. Paralelamente, para estimar a precisão do modelo com base nos dados de testes, foi elaborada a seguinte métrica, denominada por D_m , em que:

$$D_m = \frac{100}{n} \sum_{i=1}^n \left| \frac{y^m}{y} - 2 \langle y < y^m \rangle \right| \quad (10)$$

Caso a fração interna ao somatório seja maior que 1, então, uma compensação é feita subtraindo 2 unidades, a fim de manter a média final entre o intervalo de 0 a 100%.

4.5 Arquitetura da Rede Neural Artificial

Tendo em vista as características escolhidas, a Figura 5 representa a arquitetura da RNA utilizada.

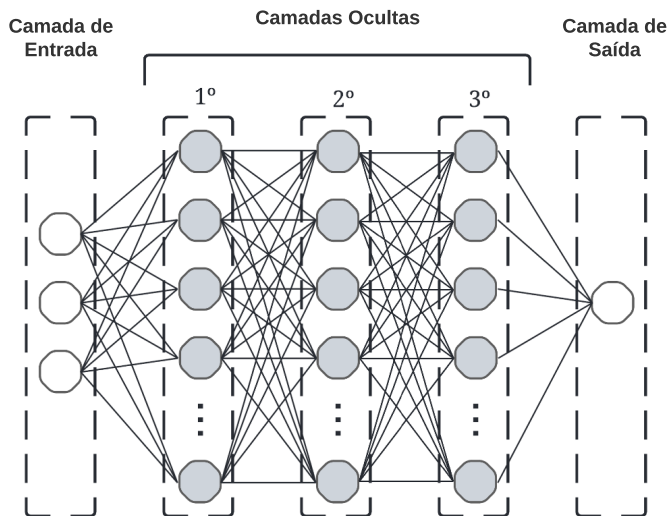


Figura 5. Estrutura da RNA.

5. RESULTADOS DE SIMULAÇÃO

Para analisar a resiliência do modelo à influência do ruído, foi proposto um estudo de caso de acordo com o nível de ruído gaussiano aplicado em RX. Dessa forma, cada etapa usa um intervalo do banco de dados referente ao valor de variância especificado de R . Além disso, os resultados apresentados em cada caso seguem uma análise descritiva subdividida para cada fase, composta pelos atributos: MSE, MAE, *Best Epoch* (o número de épocas é um hiperparâmetro que determina o número de vezes que os dados de treinamento são alimentados ao algoritmo) e D_m entre as previsões do algoritmo e os valores simulados. No final, todos os casos foram combinados e alimentados ao algoritmo para construir um caso geral.

5.1 Estudo de Caso I

- Ruído aplicado com variância igual a 0,001.

Como esperado, o modelo se adaptou bem ao banco de dados, uma vez que a ação do ruído nas medições ainda pode ser considerada desprezível.

Tabela 4. Estudo de Caso I

Atributos	Treinamento	Validação	Teste
<i>MSE</i>	5,8472e-06	6,6974e-06	5,5728e-06
<i>MAE</i>	0,0017	0,0017	0,0016
<i>Best Epoch</i>	248/250	240/250	-
D_m	-	-	99,573%

5.2 Estudo de Caso II

- Ruído aplicado com variância igual a 0,0055.

Tabela 5. Estudo de Caso II

Atributos	Treinamento	Validação	Teste
<i>MSE</i>	3,1303e-05	1,6700e-05	1,5094e-05
<i>MAE</i>	0,0035	0,0032	0,0029
<i>Best Epoch</i>	213/250	239/250	-
D_m	-	-	98,441%

Em geral, a ação do ruído começa a ser notada, principalmente a partir da métrica de precisão média, que diminui consideravelmente.

5.3 Estudo de Caso III

- Ruído aplicado com variância igual a 0,01.

Tabela 6. Estudo de Caso III

Atributos	Treinamento	Validação	Teste
<i>MSE</i>	3,7586e-05	5,9886e-05	8,7204e-05
<i>MAE</i>	0,0052	0,0073	0,0071
<i>Best Epoch</i>	224/250	243/250	-
D_m	-	-	97,135%

Vale ressaltar, primeiramente, o nível de ruído que esse valor de variância máxima de 0,01 significa, sendo assim, a Figura 6 ilustra esse sinal.

Resumidamente, mesmo com o ruído em altos níveis, o modelo conseguiu manter uma taxa de previsão média aceitável, ou seja, acima de 95%. Isso representa não só o sucesso do modelo, mas também a robustez do algoritmo desenvolvido com base no método DF, a fim de contornar a ação do ruído.




Figura 6. Estudo de caso III: exemplo de amostra.

5.4 Estudo de Caso IV

- Caso geral: ruído com variância fixa na faixa entre 0,001 e 0,01.

Tabela 7. Estudo de Caso IV

Atributos	Treinamento	Validação	Teste
<i>MSE</i>	3,4557e-05	3,5167e-05	4,0763e-06
<i>MAE</i>	0,0041	0,0047	0,0009
<i>Best Epoch</i>	239/250	225/250	-
<i>D_m</i>	-	-	96,769%

Por fim, após a junção de toda a base de dados, observa-se uma melhoria nas etapas de treinamento e validação do algoritmo, fato comprovado pela representação da capacidade preditiva do modelo na Figura 7.




Figura 7. Predição do modelo baseado nos dados de testes.

6. CONCLUSÕES

Como visto, a estimação da velocidade do vento permite inferir sobre diversas características do ambiente a ser estudado, seja na análise da viabilidade de instalação de usinas eólicas, controle de processos industriais de alta precisão, auxílio no dimensionamento e segurança de construções civis, previsão de eventos meteorológicos, entre outros. Dito isso, fica claro que a confiabilidade do método para estimar essa variável é um aspecto essencial.

Em paralelo, algoritmos de *Machine Learning* permitem automatizar processos de forma eficiente, proporcionando maior aproveitamento de janelas de oportunidades a partir de modelos analíticos, que requerem mínima intervenção humana. Nessa esfera, as vantagens dos modelos de RNA consistem em sua alta precisão quando comparada a outros tipos de IA, pois sua capacidade de abstração acompanha a complexidade das relações não lineares entre as variáveis.

Neste artigo, foi apresentado um modelo capaz de prever a velocidade do vento utilizando Redes Neurais Artificiais. Assim, uma descrição estatística das variáveis envolvidas, o processo de engenharia de dados, bem como as escolhas dos parâmetros do modelo foram devidamente demonstradas e justificadas. Por fim, foi possível verificar a robustez do método DF para medição de *ToF*, bem como uma grande capacidade de generalização da inteligência artificial desenvolvida contra sinais muito ruidosos, com precisão média de 96,76%.

Tal resultado serve para indicar a viabilidade do instrumento computacional e os algoritmos de inteligência artificial para a estimação da velocidade do vento. Ademais, pode-se confirmar a característica das RNAs de poderem ser usadas para construir sistemas de filtragem adaptativa e altamente não linear, separando os padrões ocultos nos dados.

Por outro lado, analisando mais intrinsecamente o método proposto, deve-se destacar a possibilidade de melhorias do algoritmo, seja a partir de uma melhor combinação de hiperparâmetros utilizando ferramentas como *Random Search* e *Grid Search*. Mas no geral, tornou-se clara a aplicabilidade desse tipo de algoritmo, seja de forma embutida em microcontroladores, com um resultado imediato (*online*), ou de forma posterior, como foi apresentado aqui (*offline*). Logo, tais resultados abrem margens para futuras pesquisas com o intuito de aperfeiçoar o processo de medição da velocidade do vento, grandeza de extrema importância para geração de energia elétrica a partir de meios sustentáveis.

AGRADECIMENTOS

Os autores agradecem ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e à UFPB (Universidade Federal da Paraíba) pelo apoio financeiro para o desenvolvimento dessa pesquisa por meio do edital PIBIC-UFPB-CNPQ-FAPESQ 2021-2022.

REFERÊNCIAS

- D. Fernandes, L. Gomes and A. Costa. Wind speed and direction measurement based on time of flight ultrasonic anemometer. 2017 IEEE 26th International Symposium on Industrial Electronics (ISIE), 2017, pp. 1417-1422, doi: 10.1109/ISIE.2017.8001453.
- S. Gerasimov, V. Glushnev and M. Panov. Applications of Digital Signal Processing Methods in Ultrasonic Flowmeters. 2018 IV International Conference on Information Technologies in Engineering Education (Inforino), 2018, pp. 1-6, doi: 10.1109/INFORINO.2018.8581723.
- A. Ghanbarzadeh, A. R. Noghrehabadi, M. A. Behrang and E. Assareh. Wind speed prediction based on simple meteorological data using artificial neural network.

- 2009 7th IEEE International Conference on Industrial Informatics, 2009, pp. 664-667, doi: 10.1109/INDIN.2009.5195882.
- P. Hauptmann, N. Hoppe and A. Puettmmer. Ultrasonic sensors for process industry. 2001 IEEE Ultrasonics Symposium. Proceedings. An International Symposium (Cat. No.01CH37263), 1, pp. 369-378.
- J. C. Kaimal and J. A. Businger. A continuous wave sonic anemometer-thermometer. *J. Appl. Meteorol.*, vol. 2, no. 1, pp. 156-164, Feb. 1963.
- H. Kutucu and A. Almryad. Modeling of solar energy potential in Libya using an artificial neural network model. 2016 IEEE First International Conference on Data Stream Mining & Processing (DSMP), 2016, pp. 356-359, doi: 10.1109/DSMP.2016.7583575.
- H. Li, J. Li, X. Guan, B. Liang, Y. Lai and X. Luo. Research on Overfitting of Deep Learning. 2019 15th International Conference on Computational Intelligence and Security (CIS), 2019, pp. 78-81, doi: 10.1109/CIS.2019.00025.
- W. Lihua and Y. Dawei. Study of anemometer for wind power generation. 2014 International Conference on Mechatronics and Control (ICMC), 2014, pp. 657-661, doi: 10.1109/ICMC.2014.7231636.
- M. C. Mabel and E. Fernandez. Estimation of Energy Yield From Wind Farms Using Artificial Neural Networks. *IEEE Transactions on Energy Conversion*, vol. 24, no. 2, pp. 459-464, June 2009, doi: 10.1109/TEC.2008.2001458.
- J. Morris, E. Martin, Jie Zhang and Rhao Shao. Building robust neural networks for industrial process applications. *IEEE Colloquium on Neural Networks for Industrial Applications (Digest No. 1997/014)*, 1997, pp. 7/1-7/3, doi: 10.1049/ic:19970105.
- J. M. M. Villanueva, S. Y. C. Catunda and R. Tanscheit. Maximum-Likelihood Data Fusion of Phase-Difference and Threshold-Detection Techniques for Wind-Speed Measurement. *IEEE Transactions on Instrumentation and Measurement*, vol. 58, no. 7, pp. 2189-2195, July 2009, doi: 10.1109/TIM.2009.2013666.