

13º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2022

UTILIZAÇÃO DE VISÃO COMPUTACIONAL USANDO MACHINE LEARNING NO RECONHECIMENTO DE TURBINAS E DE PÁS EÓLICAS DANIFICADAS

RAIMUNDO E. FIGUEREDO^{1,4}, GUILHERME C. DA SILVA¹, WALTER A. VARELA^{1,4}

¹ Graduando em Engenharia de Controle e Automação, IFSP, Câmpus Cubatão, eider.f@aluno.ifsp.edu.br.

² Graduando em Engenharia de Controle e Automação, IFSP, Câmpus Cubatão, g.cardoso@aluno.ifsp.edu.br

³ Docente de Engenharia de Controle e Automação, IFSP, Câmpus Cubatão, varella@ifsp.edu.br

⁴ Laboratório Maxwell de Micro-ondas e Eletromagnetismo Aplicado, LabMax, IFSP.

Área de conhecimento (Tabela CNPq): 3.04.00.00-7 Engenharia Elétrica e 1.03.00.00-7 Ciência da Computação

RESUMO: A instalação de parques eólicos cada vez mais ocupa espaço no Brasil e na matriz de geração de energia limpa. Um dos defeitos mais comuns nas turbinas envolve as superfícies danificadas nas pás por desgaste ou erosão. Assim sendo, este trabalho apresenta um sistema de visão computacional utilizando o ecossistema de Inteligência Artificial com *Machine Learning* (ML) e Redes Neurais Artificiais (RNA) com o uso de imagens para o reconhecimento de turbinas eólicas e as superfícies danificadas das pás. Foi utilizado um banco de dados de imagens para o treinamento da rede neural e para isso a plataforma Edge Impulse foi a escolhida por sua facilidade e precisão, sendo que a captura das imagens foi feita com o uso do microcontrolador ESP32 CAM. O treinamento do modelo de RNA utilizou 5, 15 e 30 neurônios, obtendo uma precisão 99,8% e para o modelo com 30 neurônios a perda foi de 0,01, com aumento da carga de processamento no dispositivo. O sistema conceitual de reconhecimento de erosões e danos nas pás eólicas foi capaz de diferenciar uma pá eólica danificada de uma em boas condições.

PALAVRAS-CHAVE: Visão Computacional; Turbina Eólica; Erosão de Pás Eólicas; Aprendizagem de Máquina; Inteligência Artificial em Energia Renováveis.

USE OF MACHINE LEARNING FOR COMPUTATIONAL VISION APPLIED IN THE RECOGNITION OF DAMAGED TURBINES AND WIND BLADE.

ABSTRACT: The installation of wind farms is increasingly taking up space in Brazil and in the clean energy generation matrix. One of the most common defects in turbines involves damaged surfaces on the blades by wear or erosion. Therefore, this work presents a computer vision system using the Artificial Intelligence ecosystem with Machine Learning (ML) and Neural Networks with the use of images for the recognition of wind turbines and the damaged surfaces of the blades. An image database was used to train the neural network and for that the Edge Impulse platform was chosen for its ease and precision, and the capture of the images was done using the ESP32-CAM microcontroller. The training of the Neural Networks model used 5, 15 and 30 neurons, obtaining an accuracy of 99.8% and for the model with 30 neurons the loss was 0.01, with an increase in the processing load on the device. The conceptual system for recognizing erosion and damage in wind blades was able to differentiate a damaged wind blade from one in good condition.

KEYWORDS: Computer vision; Wind turbine; Erosion of Wind Blades; Machine Learning; Artificial Intelligence in Renewable Energy.

INTRODUÇÃO

Em 2020 as energias renováveis (ER) representavam 25% da geração global que partiu de uma demanda da sociedade por energias que não emitissem poluentes na sua geração, aliado aos custos competitivos na geração e ao desenvolvimento de tecnologias para otimizar a geração (LIPU *et al.*, 2021). A energia eólica (EE), que utiliza o vento para gerar energia elétrica, é a terceira ER de maior capacidade instalada e a que apresenta desenvolvimento mais rápido na atualidade (ZHAO *et al.*, 2019) e responsável por 5% da produção de energia no mundo (LIPU *et al.*, 2021).

No Brasil em 2007 a EE gerava 663 GWh passando para 55.051 GWh em 2020 o que significava 8,8% de toda energia gerada, segundo balanço energético nacional (BEN) produzido pela Empresa de Pesquisa Energética (EPE) (EPE, 2022).

As ER's têm limitação quanto a imprevisibilidade climática devido à irregularidade do vento (ZHAO *et al.*, 2019), direção, temperatura, umidade, pressão atmosférica e altitude, que correlacionadas provocam características indesejáveis como sua aleatoriedade, intermitência e inflexibilidade aumentando os custos, imprevisibilidade e confiabilidade na geração da EE (LIPU *et al.*, 2021).

Com a utilização de Sistemas de Monitoramento de Condições (SMC) ou de Sistemas Supervisórios juntamente com a Inteligência Artificial é possível a geração de diagnósticos de falhas de forma preditiva, principalmente em componentes mecânicos e elétricos dos aerogeradores (MARQUEZ *et al.*, 2012).

O objetivo deste trabalho é utilizar a visão computacional aplicada na identificação de danos em pás das turbinas eólicas, tendo sido utilizado um banco de imagens de turbinas eólicas no treinamento da rede neural no ambiente Edge Impulse e compilador EON (*Edge Optimized Neural*), facilitando a seleção do melhor modelo e após treinado ser colocado em pequenos dispositivos (SENESE, 2022).

MATERIAL E MÉTODOS

As pás das turbinas eólicas são os componentes dos aerogeradores com maior probabilidade de serem danificados pela interação com o meio ambiente. Por elas estarem expostas a fortes ventos, gotas de chuva ou granizo com velocidades superiores a 100 m/s, raios, cargas de vento recursivas, além dos efeitos de cisalhamento. Essas exposições podem levar a danos na superfície das pás causando erosão nas bordas (KATSAPRAKAKIS *et al.*, 2021).

Esses tipos de danos afetam o desempenho dos aerogeradores, causando impactos econômicos devido a parada para manutenção com o desligamento dos aerogeradores danificados ou ainda na operação com baixa eficiência de geração. Deve ser considerado que as pás das turbinas eólicas constituem em uma estrutura única e grande, sendo que uma pá de médio porte de 2 MW tem aproximadamente 50 m de comprimento, pesando cerca de 7.000 kg (KATSAPRAKAKIS *et al.*, 2021).

A reparação de pás de turbinas eólicas cria desafios devido à localização remota dos parques eólicos, ao tamanho e altura das turbinas, à dificuldade de acesso às pás, à avaliação dos materiais das pás e às áreas de superfície são de complexa análise seja ela visual ou não (BOOPATHI *et al.*, 2022).

Os sistemas de monitoramento tradicionais requerem matrizes de sensores do tipo contato que envolvem problemas de instrumentação, manutenção e custo, bem como ineficácia na localização da falha ou que são simplesmente impraticáveis de implementar, fazendo com que inovações com análise de imagens de câmeras ganhe relevância (RAMON e HERNANDEZ, 2021).

O modelo de visão computacional desenvolvido utilizou a plataforma Edge Impulse que disponibiliza modelo de Rede Neural Artificial (RNA), com uso de banco de dados de imagens de turbinas eólicas disponível na plataforma Kaggle por Shihavuddin e Chen (2018), e foram selecionadas 2296 imagens de partes da turbina eólica das 13470 disponíveis, devido a capacidade limitada do micro controlador utilizado, e 75 imagens de áreas das pás eólicas danificadas foram utilizadas do banco de dados disponibilizado por Nikolov *et al.* (2020).

Para o treinamento do modelo da RNA foram usadas 20 épocas, taxa de aprendizado de 0,0005 e o tamanho de conjunto de validação de 20% sendo que esses parâmetros foram indicados pelo Edge Impulse, e neste trabalho foram testados modelos com 5, 15 e 30 neurônios com taxa de desistência 0,1.

Foram realizadas quatro etapas como mostradas na Figura 1, utilizando o Edge Impulse para o treinamento da visão computacional utilizando RNA, para identificar as pás eólicas danificadas seja por erosão causada pela dinâmica do fluido ou pá danificadas por impactos com objetos, partículas ou raios

e foi denominada *Damage Wind Blades* (DWB). Essas etapas foram a coleta de imagens de um banco de dados, o processamento dessas imagens e a transferência da aprendizagem, utilizando o modelo de *Transfer Learning*, e o treinamento, que cria modelo de reconhecimento. Neste trabalho foi utilizado o microcontrolador ESP32-CAM com câmera OV2640 de 2 MP para fazer o reconhecimento e testar o modelo.




FIGURA 1. Processo de desenvolvimento do modelo da RNA de pás eólicas com Edge Impulse para reconhecimento por imagem de pás danificadas.

Para o desenvolvimento deste projeto foi utilizado o conceito de Inteligência artificial em dispositivos de borda com uso de processadores com menor consumo de energia da ordem de miliwatts e capacidade de memória é conhecida como *TinyML* e aplicados em sistemas de IoT (RAY, 2022).

A Figura 2 mostra o sistema conceitual desenvolvido onde a ESP32-CAM que é treinado pela plataforma de aprendizado de máquina (Edge Impulse) capta as imagens e reconhece se é pá danificada ou uma turbina eólica sem danos e armazena esses dados em cartão de memória, e em caso de falha indica também a localização. Os teste foram realizados com imagens da Internet obtidas por buscas em site de pesquisas.

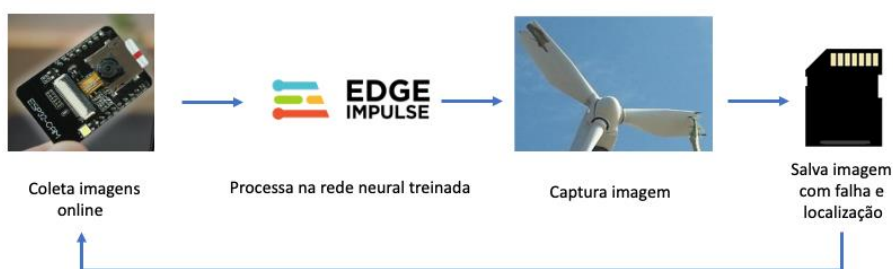


FIGURA 2. Sequência de processamento e coleta de falhas.

RESULTADOS E DISCUSSÃO

O primeiro modelo testado na plataforma Edge Impulse foi usando um treinamento da RNA com 5 neurônios na qual se obteve desempenho de treinamento com precisão de 99,4% e uma perda de 0,02. A matriz de confusão na Tabela 1, mostra os resultados do modelo da RNA utilizando 5 neurônios, com destaque na intercessão entre DWB e *Wind Turbine* (WT) (Turbina Eólica) com falso positivo de 18,8% o que resultou em desempenho de reconhecimento de DWB em 81,3%, WT resultou no verdadeiro positivo de 100%. A pontuação F1 está relacionada com a precisão do classificador, em que seu valor varia de 0 a 1, resultando em 0,90 e 1,00 neste trabalho, indicando uma elevada precisão.

TABELA 1. Matriz de confusão da RNA com 5 neurônios.

	<i>Damage Wind Blade</i>	<i>Wind Turbine</i>
<i>Damage Wind Blade</i>	81,3%	18,8%
<i>Wind Turbine</i>	0%	100%
Pontuação F1	0,90	1,00

O segundo modelo usou 15 neurônios e os resultados foram idênticos ao com 5 neurônios, o que os diferenciou foram os dados de desempenho nos dispositivos que serão tratados mais adiante.

O terceiro modelo que utilizou 30 neurônios melhorou a precisão de treinamento resultando em desempenho de 99,8% e perda de 0,01 em relação aos outros dois modelos mostrados anteriormente e

sua matriz de confusão é apresentada na Tabela 2, com a melhora no desempenho de conhecimento para 93,8% e diminuição do falso positivo e aumento do fator F1 isso melhora o modelo com maior desempenho de reconhecimento.

TABELA 2. Matriz de confusão da RNA com 30 neurônios.

	<i>Damage Wind Blade</i>	<i>Wind Turbine</i>
<i>Damage Wind Blade</i>	93,8%	6,3%
<i>Wind Turbine</i>	0%	100%
Pontuação F1	0,97	1,00

A Figura 4 mostra o modelo com 5 neurônios onde as amostras DWB possuem algumas incorretas (*incorrect*) (Figura 4a), no de 15 neurônios existem amostras incorretas para DWB, porém uma amostra está inserida nas de WT (Figura 4b) e o de 30 neurônios foi o que apresentou todas amostras corretas (*correct*) (Figura 4c).

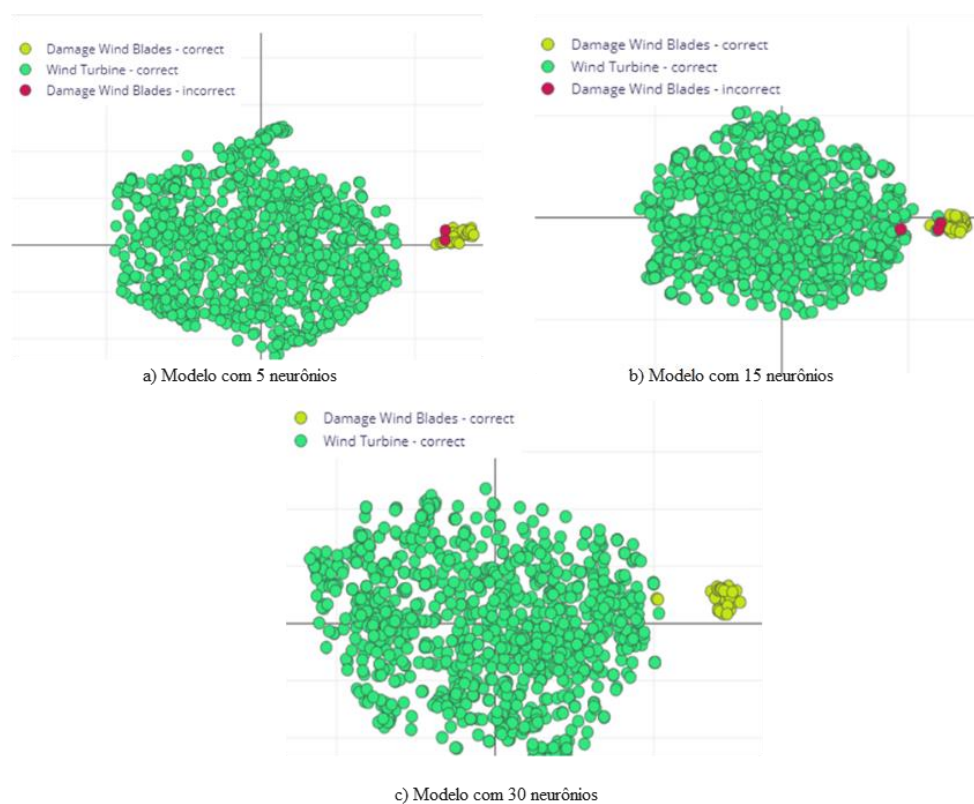


FIGURA 1. Conjunto das amostras dos modelos, sendo (a) 5 neurônios, (b) 15 neurônios e (c) 30 neurônios.

O aumento da quantidade de neurônios impacta no tempo de inferência e uso da memória flash, porém o pico de uso da RAM é igual para todos os modelos utilizados neste trabalho e os resultados são mostrados na Tabela 3. É importante observar que o tempo de inferência com 30 neurônios foi mais rápido 1 ms em relação ao com 15, mas mais lento do que o com 5 neurônios.

TABELA 3. Desempenho dispositivos de acordo com a quantidade de neurônios.

	Tempo de Inferência	Pico de Uso da RAM	Uso da Flash
5 Neurônios	101 ms	346,6 K	571,4 K
15 Neurônios	109 ms	346,6 K	584,1 K
30 Neurônios	108 ms	346,6 K	603,2 K

CONCLUSÕES

O uso de Visão Computacional para reconhecimento de danos ou erosões nas superfícies das pás podem ajudar na realização de manutenção preventiva, reduzindo os custos, diminuindo os riscos para os operadores, pois as pás ficam a muitos metros de altura e a inspeção visual com as câmeras instaladas em veículos não tripulados podem ajudar nesse processo sem expor o operador a riscos.

Os resultados dos três modelos testados neste trabalho mostra que uma grande quantidade de dados podem trazer resultados melhores de precisão no reconhecimento, porém surge uma maior quantidade de processamento dos equipamentos e dependendo da precisão que seja esperada modelos com menos neurônios podem resultar em uma capacidade de processamento menor aos dispositivos.

AGRADECIMENTOS

Agradecemos aos professores do Curso de Engenharia de Controle e Automação do Câmpus Cubatão por nos proporcionarem os conhecimentos necessários para este projeto.

REFERÊNCIAS

BOOPATHI K, Mishnaevsky, Sumantraa, Premkumar,Thamodharan, Balaraman , **Failure mechanisms of wind turbine blades in india: climatic, regional, and seasonal variability** ,Wind Energy ,v.25 , p. 968-979, 2022.

EPE, Empresa de Pesquisa Energética. **Balanco Energético Nacional 2020**. 2022.

MÁRQUEZ, Fausto Pedro García *et al.* **Condition monitoring of wind turbines: Techniques and methods**. Renewable energy, v. 46, p. 169 178, 2012.

KATSAPRAKAKIS, Papadakis, Ntintakis, **A Comprehensive Analysis of Wind Turbine Blade Damage**. Energies, 14(18), 5974, 2021.

LIPU, MS Hossain *et al.* **Artificial Intelligence Based Hybrid Forecasting Approaches for Wind Power Generation: Progress, Challenges and Prospects**. IEEE Access, v. 9, p. 102460-102489, 2021.

NIKOLOV, I.; *et al.*, **Wind Turbine Blade Surfaces Dataset**, Mendeley Data, V1, doi: 10.17632/jrmm82m4mv.1 – 2020.

RAMON, Ochoa,Hernandez e Rios. **Novel Method for Wind Turbines Blades Damage Classification using Image Processing**. Journal of Scientific & Industrial Research Vol. 80, pp. 75-79, 2021.

SENESE, Mike. **Edge AI developer tool of the year**, Maio 2022. Disponível em: <https://www.edgeimpulse.com/blog/eon-tuner-awarded-2022-edge-ai-developer-tool-of-the-year>, Acesso: 30 jun 2022.

SHIHAVUDDIN, A. S. M.; CHEN, Xiao. **DTU-Drone inspection images of wind turbine**. 2018.

ZHAO, Xuejing *et al.* **Research and application based on the swarm intelligence algorithm and artificial intelligence for wind farm decision system**. Renewable energy, v. 134, p. 681-697, 2019.

RAY, P. P. (2022). **A review on TinyML: State-of-the-art and prospects**. In Journal of King Saud University - Computer and Information Sciences (Vol. 34, Issue 4, pp. 1595–1623). King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2021.11.019>