

CATEGORIA 3

O&M



Correlação entre Falhas em Aerogeradores e Condições Ambientais: Uma Abordagem com Aprendizado de Máquina

Thadeu Carneiro da Silva¹; Fábio Augusto da Silva Antunes²; Júlio Carlos Teixeira³; Rodrigo Colnago Contreras⁴

¹TSX Engenharia e Consultoria, Itanhandu, MG, Brasil; ²Cemig Geração e Transmissão, Belo Horizonte, MG, Brasil; ³Universidade Federal do ABC (UFABC), Santo André, SP, Brasil;

⁴Universidade Federal de São Paulo (UNIFESP), São José dos Campos, SP, Brasil

thadeu.silva@tsenergyservice.com.br, fabio.antunes@cemig.com.br,
juliocarlos.teixeira@ufabc.edu.br, contreras@unifesp.br

RESUMO

A energia eólica emergiu como uma fonte renovável vital, competindo com a energia convencional devido à sua natureza limpa e inesgotável. Entretanto, a produção em massa global de aerogeradores frequentemente desconsidera as condições ambientais únicas dos locais de instalação, levando a desafios de desempenho e confiabilidade. Este estudo aplica metodologias de aprendizado de máquina para analisar a correlação entre falhas em aerogeradores e as condições ambientais locais. A pesquisa utiliza a Teoria dos Conjuntos Aproximados (*Rough Sets*) para transformar instâncias de desligamentos indesejáveis — especialmente aqueles influenciados por processos de tropicalização incompletos — em regras de decisão acionáveis. Os resultados oferecem insights práticos aplicáveis a parques eólicos em todo o mundo, permitindo estratégias de manutenção otimizadas e ajustes precisos dos parâmetros de proteção. Essas melhorias contribuem para a redução das taxas de falhas, o aumento da eficiência de conversão energética e a promoção da expansão sustentável da energia eólica em diferentes contextos geográficos e climáticos.

Palavras-chave:

Aprendizado de Máquina; Conjuntos Aproximados; Energia Eólica; Falhas em Aerogeradores; Tropicalização de Projetos

ABSTRACT

Wind energy has emerged as a vital renewable source, competing with conventional energy due to its clean and inexhaustible nature. However, the global mass production of wind turbines often disregards the unique environmental conditions of installation sites, leading to performance and reliability challenges. This study applies machine learning methodologies to analyze the correlation between wind turbine failures and local environmental conditions. The research leverages Rough Set Theory to transform instances of undesirable turbine shutdowns—especially those influenced by incomplete tropicalization processes—into actionable decision rules. The findings offer practical insights applicable to wind farms worldwide, enabling optimized maintenance strategies and precise adjustments of protection parameters. These improvements contribute to reducing failure rates, enhancing energy conversion efficiency, and promoting the sustainable expansion of wind energy across diverse geographic and climatic contexts.

Keywords:

Machine Learning; Rough Sets; Wind energy; Wind turbine failures; Wind turbine projects tropicalization

1. INTRODUÇÃO

A energia eólica é uma das fontes de energia renovável que mais cresce no mundo. No Brasil, ela representou 12,8% da matriz energética nacional em 2022 e espera-se que atinja 15% até 2026, tendo atendido 24% da demanda total do Sistema Interligado Nacional (SIN) em 15 de outubro de 2022 [1]. A energia eólica é limpa, inesgotável e não contribui para emissões de gases de efeito estufa ou poluição ambiental. Os aerogeradores, responsáveis por converter a energia cinética do vento em eletricidade, são a tecnologia central por trás dessa fonte de energia sustentável [2].

As regiões brasileiras mais favoráveis para a geração de energia eólica são as áreas costeiras do Nordeste (como Ceará, Rio Grande do Norte, Paraíba e Bahia) e do Sul (Rio Grande do Sul e Santa Catarina). Essas localidades apresentam padrões de ventos fortes e constantes: enquanto o Nordeste experimenta condições estáveis impulsionadas pelos ventos alísios, o Sul enfrenta mais variabilidade devido às frequentes frentes frias [3].

Os aerogeradores são produzidos comercialmente em escala global, muitas vezes sem adaptações específicas para as condições ambientais únicas de seus locais de instalação. Consequentemente, há uma oportunidade para estudos de engenharia aprofundados baseados em dados operacionais reais para identificar correlações entre falhas de aerogeradores e condições ambientais e geográficas locais. Compreender essas relações permite o desenvolvimento de estratégias de manutenção personalizadas e ajustes finos nas configurações de proteção, melhorando a confiabilidade operacional e o desempenho dos aerogeradores. Isso, por sua vez, leva a taxas de falha reduzidas, maior eficiência na conversão de energia e maiores retornos financeiros para os operadores de parques eólicos [4].

É importante notar que fatores ambientais como temperatura e umidade desempenham um papel na formação das características do vento. Variações de temperatura geram diferenciais de pressão e correntes de convecção, influenciando a velocidade e a turbulência do vento. Da mesma forma, a umidade afeta a densidade do ar e contribui para sistemas meteorológicos que impactam os padrões de vento. Assim, ao analisar variáveis relacionadas ao vento, como velocidade, direção e turbulência, estamos inerentemente considerando a influência indireta da temperatura e umidade. Essa abordagem garante que nossos achados reflitam interações climáticas mais amplas que afetam o desempenho dos aerogeradores, mesmo sem incluir explicitamente esses parâmetros ambientais adicionais.

Este estudo parte da hipótese de que certos tipos de falhas em aerogeradores estão fortemente correlacionados com condições ambientais específicas e que a aplicação de técnicas de aprendizado de máquina pode identificar padrões preditivos, permitindo estratégias de manutenção aprimoradas e redução do tempo de inatividade. Ao utilizar a Teoria dos Conjuntos Aproximados, buscamos descobrir regras de decisão acionáveis que facilitem ajustes proativos na operação dos aerogeradores, aumentando a eficiência e a confiabilidade em diversos contextos ambientais.

2. ESTADO DA ARTE

A análise de falhas em aerogeradores e sua relação com as condições ambientais é de grande importância para o setor de energia eólica, pois possibilita compreender as principais causas das falhas e implementar medidas preventivas para aumentar a confiabilidade e a eficiência desses equipamentos. Neste capítulo, serão discutidos estudos relevantes que abordam a relação entre falhas em aerogeradores e condições ambientais em diferentes locais.

Durante muitos séculos, a humanidade utilizou a força motriz dos ventos para a realização de trabalho. No entanto, a conversão da energia eólica em energia elétrica só ganhou escala comercial significativa nos anos 2000, como demonstrado na FIGURA 1, e, devido aos esforços nacionais e internacionais para a descarbonização da matriz energética, é altamente provável que essa tendência continue a crescer nas próximas décadas.




FIGURA 1. Evolução da Capacidade Instalada (MW) [5]

Em 2023, o Brasil manteve a sexta posição no Ranking Mundial de capacidade eólica acumulada, compilado pelo *World Wind Energy Association (WWEA) Annual Report 2023* [6], conforme mostrado na TABELA I.

TABELA I. Ranking Global de Capacidade de Energia Eólica por País em 2023

Posição	País	Capacidade Total Instalada (GW)
1	China	403,3
2	EUA	150,4
3	Alemanha	61,1
4	Índia	44,7
5	Espanha	30,6
6	Brasil	30,4
7	França	22,0
8	Canadá	17,0
9	Suécia	16,2
10	Reino Unido	14,8

O crescimento da matriz eólica no Brasil e no mundo desencadeou inúmeros estudos relacionados ao desempenho dos aerogeradores, especialmente porque esses equipamentos são projetados para operar em locais cujas condições ambientais podem ser significativamente diferentes das originalmente previstas. Silva [4] comenta que os projetos de aerogeradores são inicialmente introduzidos por meio de protótipos voltados a mercados-alvo. Por essa razão, a “tropicalização” dos projetos, geralmente concebidos na Europa e nos EUA, torna-se necessária para atender às exigências locais. Consequentemente, os parâmetros de operação e manutenção precisam ser constantemente ajustados ao longo da vida útil dos aerogeradores, incorporando resultados históricos.

Não existe uma solução única e simples para as complexidades envolvidas na operação e manutenção de aerogeradores. No entanto, a Ciência de Dados oferece ferramentas que possibilitam a construção de uma visão abrangente de todas as variáveis no contexto e de como elas se inter-relacionam para produzir seus respectivos efeitos. Diversos autores discutem o uso

de dados, estatística aplicada e técnicas de inteligência artificial para compreender problemas associados à operação e manutenção de aerogeradores.

Sankineni [7] explora a aplicação da ciência de dados para determinar tendências operacionais históricas de aerogeradores, razões para a variabilidade na produção de energia entre diferentes sítios e expectativas futuras, auxiliando no desenvolvimento de planos de ação. O estudo destaca como a produção de energia eólica é influenciada por diversos fatores, como velocidade dos ventos, rajadas e defeitos nos aerogeradores. Também aborda como a velocidade do vento impacta o hardware dos aerogeradores, afetando diretamente o desempenho e ocasionando paradas significativas. O trabalho examina o uso de várias técnicas de Machine Learning (ML) para comparar sua eficácia na prevenção de falhas futuras, com o objetivo de fornecer assistência imediata e minimizar o tempo de inatividade das máquinas.

Com ênfase na previsão de geração, Kokila [8] discute o monitoramento de condições e a detecção de falhas em aerogeradores utilizando curvas de potência, curvas do rotor e curvas de passo das pás, explicadas em algoritmos de mineração de dados. Com base em dados de vibração de alta frequência, o autor propõe uma estratégia de diagnóstico e solução de falhas usando análise da “curva envoltória”. A técnica de *Condition Monitoring System* (CMS) pode ser utilizada para identificar e resolver problemas no multiplicador e no rotor da turbina. A partir de medições de temperatura, é possível detectar falhas nos geradores eólicos por meio de um modelo de rede neural, que identifica problemas como vazamento de óleo do gerador, trincas nas pás, baixa velocidade do vento e temperatura de resfriamento do gerador. A técnica Random Forest também é utilizada para analisar falhas nas escovas do gerador. Com base em métodos estatísticos e de mineração de dados, o autor defende uma abordagem alternativa para avaliar o desempenho e monitorar as condições dos aerogeradores, em que sensores devem ser instalados em pontos específicos da turbina, monitorados por meio do sistema SCADA, permitindo alertas precoces de falhas.

Sambana [9] enfatiza que a segurança e a operação adequada dos aerogeradores dependem do monitoramento contínuo de condições, o que pode ser alcançado por meio de técnicas de ML. Seus estudos se concentram em métodos de detecção de anomalias e em Support Vector Machines (SVM), utilizando dados reais para identificar potenciais falhas, concluindo que o esquema proposto permite uma detecção mais rápida e confiável.

Singh [10] apresenta uma ferramenta de previsão baseada em séries temporais para estimar a energia eólica, além de uma abordagem para exploração de datasets do sistema SCADA com visualizações em coordenadas polares e diagramas de pares, a fim de compreender melhor a relação entre vento e produção de energia. A partir de variáveis de entrada como potência teórica, potência real produzida, direção do vento, velocidade, mês e hora, a energia gerada é estimada por algoritmos de ML.

Bilendo [11] foca em manutenção e apresenta um método para identificar comportamentos anômalos que possam levar a falhas em aerogeradores, validando a eficácia com dados reais. Uma limitação observada é o “custo do tempo de processamento”, devido à coleta e tratamento de dados não rotulados do SCADA.

Qian [12] utiliza dados SCADA de temperatura do óleo do gerador e da caixa de engrenagens para identificar falhas, aplicando o algoritmo *Extreme Learning Machine* (ELM).

Karadavi [13] utiliza dados de um parque eólico na Turquia para prever alarmes de falhas, comparando métodos de classificação como *Support Vector Classification* (SVC) e

Árvores de Decisão, sendo estas mais eficazes. O estudo destaca ainda o uso da técnica SMOTE para lidar com desbalanceamento de classes em *datasets*.

Yan [14] propõe um método de diagnóstico de falhas com Análise de Componentes Principais (PCA) e SVM, alcançando 100% de acurácia com apenas 200 amostras de treinamento, em comparação a redes neurais que requerem milhares de amostras.

Afrasiabi [15] propõe um arcabouço baseado em *Deep Learning* para diagnóstico de falhas, utilizando GANs e *Temporal Convolutional Neural Networks* (TCNN), testado em aerogeradores de 3 MW na Irlanda.

Mazidi [16] analisa fatores que afetam a potência ativa de aerogeradores, aplicando diferentes técnicas como Mapas de Kohonen, Perceptron Multicamadas, Árvores de Decisão e *Rough Sets*.

A metodologia *Rough Sets*, introduzida por Pawlak [17], é uma abordagem de mineração de dados voltada para descobrir relações em conjuntos complexos, mostrando aplicações em engenharia biomédica, RH e energia elétrica, incluindo manutenção preditiva, classificação de curvas de demanda e controle de fluxo de potência.

Mais recentemente, Xie [28] introduziu o *Granular-Ball Computing* (GBC), com o método GBG++ e o classificador GBkNN++, que demonstraram maior robustez e precisão frente a algoritmos tradicionais.

A integração dessas técnicas na análise de falhas em aerogeradores pode oferecer novas perspectivas para lidar com incertezas e aprimorar a eficiência da análise preditiva.

Assim, a integração de análise de dados, estatística aplicada e inteligência artificial desponta como um caminho para processos mais eficientes de operação e manutenção, contribuindo para a maximização da produção de energia eólica e a redução de custos com falhas e indisponibilidades.

Este trabalho se destaca pela abordagem detalhada e específica na análise das correlações entre falhas em aerogeradores e as condições ambientais de suas localidades, aspecto essencial para o desenvolvimento de estratégias eficazes de operação e manutenção. Em comum com outros estudos, envolve a aplicação de técnicas de ciência de dados a dados operacionais reais, visando obter diagnósticos, compreender padrões de falhas e identificar correlações entre variáveis. Essa abordagem não apenas amplia a compreensão do desempenho dos aerogeradores, como também auxilia na manutenção preditiva e no planejamento operacional.

3. DESENVOLVIMENTO

Este capítulo está organizado de acordo com a metodologia CRISP-DM [29]. Trata-se de um modelo estruturado para a condução de projetos de ciência de dados, garantindo que as análises sejam robustas, replicáveis e aplicáveis a problemas práticos. O processo é dividido em seis fases, que serão detalhadas nas seções a seguir: **Compreensão do Negócio, Compreensão dos Dados, Preparação dos Dados, Modelagem, Avaliação e Implantação.**

3.1. Compreensão do Negócio

A Usina Eólica Praias de Parajuru é composta por 19 aerogeradores, com capacidade instalada total de 28,8 MW. O equipamento é fabricado pela empresa alemã Vensys, modelo

VS77, equipado com geradores síncronos multipolares de ímãs permanentes e capacidade unitária de 1.540 kVA, tensão nominal de 690 Volts, operando a uma velocidade nominal do vento de 11 m/s, e instalados a uma altura de 85 metros.

A usina está localizada no município de Beberibe, Estado do Ceará, a 102 km a leste da capital Fortaleza. A subestação elevadora está localizada dentro do próprio parque eólico, composta por dois transformadores elevadores de 20 MVA e 15 MVA – 34,5 kV/69 kV, que constituem os barramentos Parajuru A e Parajuru B, por meio dos quais os aerogeradores estão conectados à Rede de Distribuição da Enel [30].

Conforme definido no manual do fabricante dos aerogeradores desses parques [31], as principais falhas do modelo VENSYS 77/62b incluem:

- **Erro Global:** falhas gerais que afetam a operação global do aerogerador.
- **Erro de Aceleração:** problemas relacionados à aceleração da nacela.
- **Erro de Resfriamento do Paine:** falhas associadas ao sistema de refrigeração do gabinete.
- **Erro do Conversor:** problemas detectados no conversor, incluindo monitoramento, temperatura dos IGBTs, entre outros.
- **Erro Hidráulico:** falhas no sistema hidráulico.
- **Erro do Sistema de Yaw:** problemas relacionados ao mecanismo de orientação, incluindo lubrificação.
- **Erro do Gerador:** falhas associadas ao gerador.
- **Erro do Transformador:** falhas detectadas no transformador.
- **Erro da Rede:** falhas relacionadas a tensão, corrente, frequência, potência ativa e reativa da rede elétrica.
- **Erro de Fusível:** problemas associados a fusíveis.
- **Erro do Sistema UPS:** falhas no sistema de alimentação ininterrupta (UPS).
- **Erro de Resfriamento da Torre:** problemas no sistema de resfriamento da torre.
- **Erro Profibus:** falhas associadas ao sistema de comunicação Profibus.
- **Erro de Medição do Vento:** problemas relacionados à medição anemométrica.
- **Erro da Luz de Navegação:** falhas nas luzes de sinalização.
- **Erro de Partida:** problemas durante o processo de startup.
- **Erro de Desligamento:** falhas durante o processo de shutdown.
- **Erro do Sistema de CPU:** problemas relacionados ao processador do sistema.
- **Erro do Sistema PitchW:** falhas associadas ao sistema PitchW, incluindo temperatura do motor, tensão do capacitor, entre outros.

Considerando que o projeto dos aerogeradores não leva em conta as características específicas dos locais onde são instalados, surge uma lacuna significativa entre o desempenho teórico e o desempenho operacional real desses equipamentos.

As variações inerentes nas condições locais de vento — como intensidade, direção e turbulência — podem afetar diretamente a eficiência e a segurança dos aerogeradores. Em alguns casos, essas variações podem exceder os parâmetros operacionais pré-definidos, levando a desligamentos não programados, redução da eficiência de geração de energia e, em casos extremos, danos ao equipamento.

Assim, torna-se imperativo adotar uma abordagem analítica e empírica, baseada em análise detalhada de dados operacionais e condições ambientais.

Ao estudar os dados de geração em conjunto com variáveis ambientais, é possível identificar padrões e anomalias que indiquem a necessidade de ajustes finos nos sistemas de proteção e controle. A análise pode revelar insights relevantes sobre como condições específicas de vento interagem com os aerogeradores, permitindo a implementação de medidas corretivas personalizadas que otimizam a eficiência e a resiliência dos equipamentos. Em última instância, uma abordagem orientada por dados não apenas melhora a eficiência energética, mas também estende a vida útil dos aerogeradores, reduz custos de manutenção e aumenta a confiabilidade do suprimento de energia. Assim, a integração da análise de dados torna-se uma estratégia capaz de mitigar os desafios associados a desajustes de proteção e controle, garantindo que os aerogeradores operem de forma otimizada, segura e eficiente, em conformidade com as dinâmicas ambientais únicas de cada local de instalação.

3.2. Compreensão dos Dados

A fase inicial deste estudo envolveu a coleta detalhada dos dados do parque eólico Praias de Parajuru. Os dados, obtidos a partir do sistema SCADA do Centro de Operações da Cemig, fornecem informações relevantes sobre a produção de energia e falhas operacionais durante um período contínuo de 12 meses, de 1º de abril de 2022 a 31 de março de 2023. Os conjuntos de dados originais, com granularidade de uma amostra a cada quatro segundos, foram integrados em intervalos de 10 minutos para tornar a análise gerenciável e alinhada com as práticas padrão na engenharia de aerogeradores. Isso resultou num total de 52.560 amostras para cada conjunto de variáveis, para cada um dos aerogeradores nos respectivos parques. Para o Parque Eólico Praias de Parajuru, há um total de 197 variáveis, incluindo medições individuais dos 19 aerogeradores e dados coletivos da torre anemométrica do parque.

Uma análise exploratória inicial revela uma diversidade de dados telemetrados abrangendo variáveis como direção do vento, velocidade do vento, direção da nacelle, limitação de geração, rotação da turbina, ângulos de passo das pás, entre outras. Variáveis coletivas, como direção e velocidade do vento em altitudes específicas, pressão atmosférica, temperatura ambiente e umidade relativa, fornecem informações adicionais sobre as condições ambientais prevalentes. Os registros de falhas, totalizando aproximadamente 6.100 ocorrências para Praias de Parajuru, complementam o conjunto de informações necessárias para a continuidade deste trabalho. Cada registro é detalhado, incluindo data e hora da ocorrência e do restabelecimento, o aerogerador associado, a causa identificada, uma descrição detalhada da ocorrência, a ação tomada para mitigar a falha e observações adicionais. As causas das falhas foram categorizadas com base na natureza e origem das ocorrências, facilitando uma análise mais aprofundada de tendências, padrões e anomalias associadas a componentes específicos dos aerogeradores, como sistema de pitch, yaw, entre outros, conforme citado em Vensys [31].

Com uma compreensão clara da estrutura, natureza e complexidade dos dados em questão, o estudo avança para as fases subsequentes de preparação dos dados. A riqueza dos dados coletados não só facilitará análise robusta como também apoiará a identificação e mitigação de desajustes em proteção e controle, otimizando a eficiência operacional e a produção de energia dos parques eólicos sob estudo.

3.3. Preparação dos Dados

Dada a natureza única e individual de cada aerogerador, decidiu-se criar um conjunto de dados específico para cada um, resultando em um total de 19 *datasets* distintos. Essa estratégia baseia-se na premissa de que cada aerogerador, com seus próprios ajustes, componentes e circunstâncias operacionais, representa um indivíduo particular no contexto do parque. Agrupar todos os aerogeradores num único *dataset* poderia inadvertidamente mascarar nuances críticas e variações individuais que cada um exibe. A individualidade de cada turbina é marcada por diferenças em ajustes operacionais, desgaste de componentes, eficiência dos sistemas de controle e proteção, e sua posição geográfica relativa às demais aerogeradores, entre outros fatores. Portanto, a análise de *datasets* individuais torna-se necessária para capturar e compreender essas diferenças sutis, porém significativas, que influenciam diretamente o desempenho e a eficiência de cada unidade.

Durante a fase de preparação dos dados, o foco principal foi a limpeza e filtragem dos registros. Identificou-se que uma porção significativa dos registros de abril a julho de 2022 estava comprometida, com medições de vento zeradas ou nulas. Esses registros foram removidos dos *datasets*. A razão para essa exclusão é que tais registros não agregam valor à análise subsequente e podem introduzir ruído ou distorções no estudo. A TABELA II demonstra o impacto total em termos de redução de registros no contexto da análise.

TABELA II. Resumo do Impacto da Limpeza de Dados


Dataset	Registros Nulos Removidos	Percentual Removido	Registros Restantes	Contagem de Paradas
UEPAJU_AG01	18,427	35.06%	34,133	123
UEPAJU_AG02	18,525	35.25%	34,035	133
UEPAJU_AG03	18,368	34.95%	34,192	57
UEPAJU_AG04	18,342	34.90%	34,218	202
UEPAJU_AG05	22,349	42.52%	30,211	5
UEPAJU_AG06	18,337	34.89%	34,223	52
UEPAJU_AG07	22,517	42.84%	30,043	20
UEPAJU_AG08	18,297	34.81%	34,263	29
UEPAJU_AG09	18,361	34.93%	34,199	195
UEPAJU_AG10	18,348	34.91%	34,212	20
UEPAJU_AG11	18,353	34.92%	34,207	272
UEPAJU_AG12	18,356	34.92%	34,204	37
UEPAJU_AG13	18,382	34.97%	34,178	67
UEPAJU_AG14	18,738	35.65%	33,822	52
UEPAJU_AG15	18,731	35.64%	33,829	180
UEPAJU_AG16	26,973	51.32%	25,587	49
UEPAJU_AG17	19,326	36.77%	33,234	146
UEPAJU_AG18	18,617	35.42%	33,943	45
UEPAJU_AG19	18,678	35.54%	33,882	63

A TABELA II ilustra os esforços abrangentes de limpeza de dados realizados para refinar a qualidade dos conjuntos de dados de cada aerogerador do Parque Eólico Praias de Parajuru. As colunas indicam o número de registros nulos removidos, o percentual de dados limpos em

relação ao conjunto de dados original, o total de registros restantes após a limpeza e o número de intervenções operacionais registradas. As variações nos percentuais de dados removidos entre os diferentes aerogeradores destacam os distintos desafios operacionais e ambientais enfrentados por cada unidade, ressaltando a importância de abordagens personalizadas no tratamento dos dados.

É importante analisar a informação apresentada na FIGURA 2, que mostra que o número de anomalias em cada categoria varia significativamente entre os aerogeradores. Por exemplo, o aerogerador 1 enfrentou predominantemente incidentes de “*Erro Conversor*”, enquanto o aerogerador 11 teve predominância de incidentes de “*Erro Aceleração*”. No caso do aerogerador 5, o número de incidentes é quase desprezível, o que torna difícil treinar um modelo de ML de forma efetiva. Essa variabilidade destaca a necessidade de abordagens personalizadas no monitoramento e diagnóstico de problemas específicos de cada aerogerador, enfatizando ainda mais a importância de entender as nuances operacionais de cada unidade para uma detecção de anomalias e otimização do sistema eficazes.

FIGURA 2. Número de Paradas, por Categoria e por Aerogerador



Quando se treina um modelo de ML para detecção de anomalias, é essencial ter um número suficiente de exemplos de cada tipo de anomalia para que o modelo possa aprender os padrões associados a essas condições anormais. A quantidade de dados requerida pode variar significativamente dependendo da complexidade do tipo de anomalia e da variação nos dados.

Tipos de anomalias com apenas um ou dois registros (como visto em várias categorias para a maioria dos aerogeradores) podem não ser suficientes para treinar um modelo de forma efetiva, mesmo quando técnicas de reamostragem (como SMOTE) são aplicadas. Um modelo pode não aprender a diferenciar adequadamente essas anomalias de variações normais nos dados. Idealmente, seria desejável ter dezenas ou até centenas de exemplos para cada categoria de anomalia, especialmente se houver variação significativa dentro dessa categoria. Por essa razão, o autor optou por considerar, nas análises subsequentes, apenas aqueles aerogeradores que apresentam anomalias com 20 ou mais ocorrências no conjunto de dados disponível, como mostrado na TABELA III. Além disso, ocorrências cujas causas foram claramente identificáveis como não associadas à dinâmica do vento, tais como problemas envolvendo infraestrutura de telecomunicações, supervisão e controle (Erro Profibus), e questões relacionadas à rede elétrica do parque (Erro Grid), também foram removidas da análise. Consequentemente, as categorias que formam o objeto deste estudo são aquelas associadas à proteção de aceleração (Erro Aceleração), conversor de potência (Erro Conversor) e ao sistema de passo das pás (Erro Pitch). Apesar da redução significativa nos tamanhos dos conjuntos de amostras, entende-se que o número de registros remanescentes continua substancial e não limita a continuidade e qualidade

dos estudos, bem como o alcance dos objetivos. Esse foco estratégico assegura que o treinamento dos modelos de ML seja baseado em *datasets* robustos e relevantes, aumentando a probabilidade de desenvolvimento de um sistema de detecção de anomalias eficaz. A TABELA III apresenta uma visão estruturada das anomalias que ocorreram pelo menos 20 vezes, organizadas por aerogerador e categoria. Os espaços em branco indicam que o número de anomalias naquela categoria não atingiu o limite de 20 ocorrências, evidenciando uma distribuição mais concentrada de anomalias significativas entre os aerogeradores. Essa abordagem direcionada de dados garante que a análise se concentre em problemas mais frequentes e potencialmente críticos, facilitando uma modelagem de *machine learning* mais precisa e uma melhor compreensão das questões predominantes em aerogeradores específicas.

TABELA III. Resumo de Anomalias com 20 ou mais Ocorrências por Aerogerador e Categoria

Categoria / Aerogerador	Erro Aceleração	Erro Conversor	Erro Pitch
1		118	
2		22	37
3		44	
4			54
6			33
9	39	137	
11	221	39	
12			
13		64	
14			
15			46
16			
17			43
18			
19			27

Utilizando a data e hora das medições e os registros de acionamento das proteções, cada evento nos aerogeradores foi então associado às respectivas medições de vento mencionadas, compondo assim conjuntos de dados semelhantes ao mostrado na Tabela IV, que ilustra como cada evento ou disparo de erro nos aerogeradores está vinculado a condições específicas de vento no momento da ocorrência. As colunas fornecem informações detalhadas sobre a direção e velocidade do vento, juntamente com seus respectivos desvios padrão, além de um índice de turbulência que pode indicar a severidade ou estabilidade do vento no momento do evento. Esse nível de detalhamento permite uma análise mais refinada das condições que antecedem cada erro, auxiliando na detecção e previsão de falhas potenciais com base em padrões específicos do vento.

TABELA IV. Associação das Ativações de Proteção com Variáveis Relacionadas ao Vento

Data e Hora	Direção do Vento (Graus)	Velocidade do Vento (m/s)	Desvio Padrão da Direção do Vento	Desvio Padrão da Velocidade do Vento	Índice de Turbulência	Disparo do Erro
22-09-27 21:00	186,05	12,83	3,41	0,73	0,06	Erro Pitch
22-10-04 03:00	172,59	11,15	92,21	0,75	0,07	Erro Conversor
23-02-07 02:00	194,16	2,24	13,80	0,81	0,36	Erro Conversor
23-03-09 03:00	170,37	10,78	93,64	1,03	0,10	Erro Aceleração
23-03-21 03:30	179,77	1,41	18,80	0,76	0,54	Erro Pitch

3.4. Modelagem

Na fase de modelagem, foi desenvolvida uma rotina para automatizar a análise e a modelagem dos dados de cada aerogerador do Parque Eólico Praias de Parajuru individualmente. O código foi estruturado para iterar sobre cada aerogerador, carregar seus dados específicos, preparar as informações e aplicar uma série de modelos de Machine Learning (ML) para identificar padrões e anomalias.

A escolha dos métodos de ML na etapa de modelagem considera que o problema em questão é a detecção de anomalias em sistemas complexos [32]. Esses sistemas são frequentemente caracterizados por dados desbalanceados, em que as falhas, embora críticas, são eventos raros em comparação com a operação normal. A complexidade é ainda ampliada pela alta dimensionalidade dos dados, com uma multiplicidade de variáveis monitoradas, cada uma contribuindo para a complexidade do ambiente de modelagem.

Segundo Alla e Adari [33], uma anomalia é um valor ou resultado que se desvia do esperado, mas a classificação exata pode variar. Existem três tipos principais de anomalias:

- **Baseadas em ponto (*point-based*):** valores que, embora não necessariamente outliers, são atípicos, como um resultado anormal em um exame de sangue.
- **Baseadas em contexto (*context-based*):** valores que seriam normais, mas tornam-se anômalos em determinados contextos, como um pico de vendas em um mês inesperado.
- **Baseadas em padrão (*pattern-based*):** desvios em relação a tendências históricas, como uma quantidade atípica de chuva em um mês específico.

A detecção de anomalias utiliza algoritmos avançados para identificar dados ou padrões anômalos, estando relacionada a técnicas de detecção de outliers, detecção de novidades e remoção de ruídos.

A necessidade de detecção em tempo real e a diversidade de tipos de anomalias apresentam desafios adicionais, exigindo uma abordagem cuidadosa na seleção e otimização dos modelos. A engenharia de atributos (*feature engineering*) torna-se um pilar central, garantindo que os modelos sejam alimentados com dados transformados e selecionados para maximizar a eficácia na identificação de padrões sutis e complexos associados a falhas específicas. A interpretabilidade dos modelos também é uma consideração crítica, assegurando que os insights obtidos possam ser reconhecidos e aplicados para a formulação de estratégias eficazes de manutenção preditiva e otimização operacional.

Portanto, a modelagem nesse contexto não é apenas uma questão técnica, mas também estratégica, integrando conhecimento do domínio, complexidade sistêmica e capacidades analíticas avançadas para assegurar a integridade operacional e a eficiência dos aerogeradores.

Diante dessas considerações, foram selecionados modelos analíticos específicos para classificação, cada qual caracterizado por suas peculiaridades e aplicabilidades intrínsecas. A aplicação desses modelos justifica-se pela complexidade inerente dos dados, que envolve significativa variabilidade das condições ambientais e diferenças operacionais entre aerogeradores. Essa variabilidade exige modelos capazes de capturar relações não lineares e lidar de forma eficaz com conjuntos de dados de alta dimensionalidade. Além disso, a presença de desbalanceamento de classes nos dados de falhas demanda algoritmos robustos, como

Gradient Boosting e Random Forest, que apresentam bom desempenho nesse tipo de cenário, mantendo a acurácia nas classes minoritárias.

Adicionalmente, a interpretabilidade é essencial no contexto de manutenção preditiva, em que são necessários insights acionáveis para apoiar decisões operacionais. Modelos como Random Forest e Support Vector Machine oferecem vantagens claras nesse aspecto, enquanto a integração da metodologia de *Rough Sets* proporciona regras de decisão transparentes, aprimorando a compreensão dos fatores que contribuem para as falhas dos aerogeradores. Essa abordagem integrada de modelagem melhora a detecção de padrões relevantes, apoia estratégias de manutenção eficientes e contribui para a confiabilidade e otimização do desempenho dos sistemas de energia eólica:

Modelos selecionados:

- **Random Forest (RF)** [32, 33]: método de *ensemble learning* amplamente reconhecido por sua robustez e acurácia em tarefas de classificação e regressão. Constrói múltiplas árvores de decisão, sendo resistente a *overfitting* e capaz de lidar com grande número de variáveis de entrada. Altamente adequado para conjuntos de dados complexos e não lineares, é ideal para prever diferentes tipos de anomalias na operação de aerogeradores.
- **Gradient Boosting (GB)** [6, 34]: constrói árvores sequencialmente, cada uma corrigindo os erros da anterior. Destaca-se em tarefas de regressão, classificação e ranqueamento, com reconhecida eficiência computacional. Tem sido utilizado para comparar desempenho com redes neurais LSTM, analisando desvios entre dados medidos e previsões de modelos, auxiliando na detecção de comportamentos anormais dos aerogeradores.
- **Support Vector Machine (SVM)** [37]: versátil, capaz de realizar classificações lineares e não lineares, regressão e detecção de outliers. É particularmente eficaz em espaços de atributos de alta dimensionalidade, comuns em diagnósticos de aerogeradores.
- **K-Nearest Neighbors (KNN)** [7]: modelo de aprendizado baseado em instâncias, que aproxima a função local e posterga o cálculo até a avaliação. Intuitivo e simples, é eficaz em cenários em que a proximidade entre pontos de dados é indicativa para a classificação, sendo aplicado em diagnósticos de padrões operacionais em aerogeradores.
- **Multilayer Perceptron (MLP)** [38]: rede neural artificial *feedforward* com pelo menos três camadas de nós. Capaz de capturar relações não lineares complexas e interações entre variáveis, sendo amplamente utilizado em problemas de classificação complexos com dados de aerogeradores.
- **Logistic Regression (LR)** [39]: modelo estatístico simples e poderoso, fácil de implementar e interpretar. Usado para compreender relações entre variáveis independentes e dependentes, é útil em tarefas de classificação binária e multiclasse, fornecendo insights sobre a probabilidade de ocorrência de determinadas anomalias.
- **Naive Bayes (NB)** [37]: semelhante à Regressão Logística, é um modelo estatístico utilizado em tarefas de classificação binária e multiclasse. Destaca-se pela simplicidade e eficiência, sendo eficaz em problemas que envolvem variáveis categóricas.

A seleção desses modelos foi guiada por suas forças complementares no enfrentamento das características específicas dos dados de operação dos aerogeradores. Dada a alta dimensionalidade dos dados ambientais e operacionais, modelos como Random Forest e SVM foram escolhidos por sua robustez e capacidade de lidar com espaços de atributos complexos. O desbalanceamento das classes de falha motivou o uso de *Gradient Boosting*, eficiente em cenários onde a detecção de classes minoritárias é crítica. O KNN foi incluído pela simplicidade e eficácia em identificar padrões locais, particularmente úteis em condições isoladas de anomalias. *Logistic Regression* e *Naive Bayes* foram selecionados por sua interpretabilidade e eficiência, fornecendo baselines sólidos e insights rápidos sobre o desempenho da classificação. Por fim, o *Multilayer Perceptron* foi escolhido por sua capacidade de capturar relações não lineares, essenciais na modelagem dos fatores dinâmicos e interdependentes que afetam o desempenho dos aerogeradores. Essa seleção diversificada de modelos garante uma análise abrangente, capaz de revelar tanto tendências amplas quanto anomalias sutis nos dados.

3.4.1. Considerações sobre os modelos empregados

No desenvolvimento deste estudo, compreender os diferentes modelos de aprendizado de máquina (ML) utilizados e as principais variáveis ajustadas para otimizar seu desempenho é fundamental. A Tabela V apresenta um resumo dos modelos empregados na análise. Para cada modelo, são descritas as principais características, os hiperparâmetros otimizados por meio do GridSearchCV e as respectivas referências bibliográficas.

Tabela V. Resumo dos Modelos de ML e Hiperparâmetros a serem Otimizados

Modelo	Hiperparâmetros Considerados no Processo de Otimização	Valores dos Hiperparâmetros
RF	n_estimators: Controla o número de árvores na floresta. Aumentar esse número melhora a acurácia e a estabilidade do modelo, mas com maior custo computacional. O intervalo escolhido equilibra desempenho e eficiência.	[50, 100, 150]
	max_depth: Define a profundidade máxima de cada árvore. Um valor <i>None</i> permite que as árvores cresçam até que todas as folhas sejam puras, o que pode levar a <i>overfitting</i> . Profundidades de 10 e 20 foram testadas para avaliar o efeito na generalização.	[<i>None</i> , 10, 20]
	min_samples_split: Especifica o número mínimo de amostras necessário para dividir um nó interno, influenciando a granularidade do modelo. Valores baixos promovem árvores mais profundas, enquanto valores maiores reduzem a complexidade.	[2, 4]
GB	n_estimators: Regula o número de estágios de <i>boosting</i> . Mais estágios aumentam o potencial de melhoria do modelo, mas também exigem maior computação, por isso foi selecionado um intervalo moderado.	[50, 100]
	learning_rate (α): Controla a velocidade com que o modelo se adapta aos erros de cada árvore. Taxas menores, embora exijam mais árvores, frequentemente produzem modelos mais robustos.	[0.05, 0.1]
	max_depth: Limita a complexidade das árvores individuais, equilibrando o trade-off entre capturar padrões complexos e evitar <i>overfitting</i> .	[3, 5]
SVM	kernel: Determina a transformação aplicada aos dados. O kernel RBF é eficaz para capturar relações não lineares, enquanto o kernel linear oferece simplicidade e eficiência para dados linearmente separáveis.	['rbf', 'linear']
	C: Parâmetro de regularização que controla o equilíbrio entre acurácia da classificação e maximização da margem. Valores menores evitam <i>overfitting</i> , enquanto valores maiores permitem que o modelo foque na classificação correta.	[0.1, 1, 10]
	gamma (γ): Define o raio de influência de pontos individuais nos kernels não lineares. Impacta como o modelo se ajusta aos dados, com <i>'scale'</i> adaptando-se à variância das features.	['scale', 'auto']

KNN	n_neighbors (K): Especifica o número de vizinhos mais próximos usados na classificação. Menos vizinhos tornam o modelo mais sensível a ruídos, enquanto mais vizinhos geram fronteiras de decisão mais suaves.	[3, 5, 7]
	weights: Determina se todos os vizinhos contribuem igualmente ('uniform') ou se vizinhos mais próximos têm maior influência ('distance'), aumentando a adaptabilidade do modelo à densidade dos dados.	['uniform', 'distance']
MLP	hidden_layer_sizes: Controla o número de neurônios na camada oculta, influenciando a capacidade da rede em aprender representações complexas. Tamanhos menores reduzem o custo computacional, enquanto tamanhos maiores aumentam a capacidade de aprendizado.	[(50,), (100,)]
	activation: Define a transformação aplicada aos dados de entrada nos nós neurais. <i>ReLU</i> acelera a convergência, enquanto <i>tanh</i> é útil quando a normalização dos dados em torno de zero é benéfica.	['relu', 'tanh']
LR	alpha (α): Parâmetro de regularização (penalidade L2) para controlar <i>overfitting</i> . Valores menores permitem modelos mais flexíveis, enquanto valores maiores impõem regularização mais forte.	[0.0001, 0.001]
	Penalty: Aplica regularização L2 para penalizar coeficientes maiores, prevenindo <i>overfitting</i> e mantendo a simplicidade na interpretação do modelo.	['l2']
NB	C: Inverso da força de regularização. Valores menores impõem regularização mais forte, melhorando a generalização, especialmente em <i>datasets</i> ruidosos.	[0.1, 1, 10]
	Normalmente, não envolve ajuste de hiperparâmetros devido à sua simplicidade e dependência de fortes pressupostos probabilísticos. Seu desempenho depende principalmente da natureza dos dados de entrada em vez de ajustes de parâmetros.	N/A

A TABELA V auxilia na configuração dos modelos e contribui para a compreensão de como cada hiperparâmetro impacta o processo de aprendizado e a eficácia geral do modelo no tratamento de conjuntos de dados complexos, como os encontrados no monitoramento e diagnóstico de operações de aerogeradores.

3.4.2. Considerações sobre o pré-processamento de dados

A aplicação dos modelos de ML foi realizada utilizando uma biblioteca de código aberto para aprendizado de máquina que suporta aprendizado supervisionado e não supervisionado, conhecida como *Grid Search CV*, do ScikitLearn [40], que facilita a otimização de hiperparâmetros, garantindo a configuração mais favorável para maximizar a acurácia e a eficiência dos modelos. Este método explora sistematicamente múltiplas combinações de parâmetros e realiza validação cruzada (com cinco iterações de testes com diferentes conjuntos de dados) para determinar qual ajuste oferece o melhor desempenho.

Cada modelo foi integrado em um fluxo de trabalho (*pipeline*) que inclui a normalização de dados via *Standard Scaler* [40]. O *Standard Scaler* é uma técnica amplamente utilizada em ML e estatística para normalizar ou padronizar um conjunto de dados. A padronização transforma os dados de forma que eles tenham média (μ) zero e desvio padrão (σ) igual a um. Essa transformação é realizada subtraindo-se a média de cada observação e dividindo pelo desvio padrão, garantindo que o modelo não seja tendencioso ou influenciado pela variação natural do conjunto de dados.

A principal vantagem dessa técnica é que ela melhora a convergência e a eficiência dos algoritmos de aprendizado de máquina, especialmente aqueles sensíveis à escala das features, como SVM e redes neurais. Além disso, facilita a interpretação de coeficientes em modelos lineares. Entretanto, apresenta desvantagens, como sensibilidade a *outliers*, já que a média e o desvio padrão podem ser significativamente afetados por valores extremos. O *StandardScaler* não é recomendado para dados que não seguem uma distribuição normal, pois nem sempre transforma os dados em uma distribuição normal. Para o caso em estudo, outros métodos de

normalização também foram considerados, especificamente *RobustScaler* e *MinMaxScaler*, todos do ScikitLearn [40]. Em testes preliminares, os três métodos apresentaram desempenho bastante similar, com o *StandardScaler* ligeiramente superior aos outros dois.

Além disso, foi aplicada a técnica de *Análise de Componentes Principais* (PCA). PCA é um procedimento estatístico que utiliza uma transformação ortogonal para converter um conjunto de observações de variáveis possivelmente correlacionadas em um conjunto de valores de variáveis linearmente não correlacionadas, chamadas componentes principais. A primeira componente principal tem a maior variância e representa o máximo da variabilidade dos dados possível. Cada componente subsequente é ortogonal às anteriores e representa a variabilidade restante. Essa redução simplifica os dados e acelera o processamento sem perda significativa de informação. Neste estudo, o PCA foi configurado para manter as componentes principais que representam até 95% da variância total dos dados, sendo útil para reduzir a dimensionalidade mantendo a maior parte da informação original.

3.4.3. Aplicação da Metodologia de Conjuntos Aproximados (*Rough Sets*)

Para a implementação da abordagem de *Rough Sets* na análise dos dados dos aerogeradores, uma etapa essencial envolve a transformação de dados quantitativos em categorias com base em conhecimento específico do domínio. Os dados de velocidade do vento foram divididos em quatro categorias distintas [41], refletindo diferentes faixas de velocidade, conforme segue:

- Classe A: Velocidade do vento $\leq 5,5$ m/s (condições de vento fraco)
- Classe B: $5,5$ m/s < Velocidade do vento ≤ 12 m/s (condições de vento moderado)
- Classe C: 12 m/s < Velocidade do vento $\leq 20,5$ m/s (condições de vento forte)
- Classe D: $20,5$ m/s < Velocidade do vento ≤ 25 m/s (condições de vento muito forte)

O desvio padrão da velocidade do vento é categorizado para refletir a variação da velocidade do vento, dividido em baixa, média e alta variação:

- Baixa variação: Desvio $\leq 0,5$ m/s
- Variação média: $0,5$ m/s $\leq$ Desvio < 1 m/s
- Alta variação: Desvio ≥ 1 m/s

O índice de turbulência, definido como a razão entre a velocidade do vento e o desvio padrão das amostras de velocidade, é classificado em três níveis distintos considerando [42], representando condições de baixa, média e alta turbulência, auxiliando na avaliação das condições operacionais do aerogerador:

- Baixa turbulência: Índice < $0,08$
- Turbulência média: $0,08 \leq$ Índice < $0,12$
- Alta turbulência: Índice $\geq 0,12$

A direção do vento é categorizada em oito direções principais, segundo a rosa dos ventos padrão, cada uma representando um intervalo específico de graus. Essa categorização é importante para identificar a direção predominante do vento e suas variações:

- N: $0 \leq \text{Direção} < 45$ ou $\text{Direção} = 360$
- NE: $45 \leq \text{Direção} < 90$
- E: $90 \leq \text{Direção} < 135$
- SE: $135 \leq \text{Direção} < 180$
- S: $180 \leq \text{Direção} < 225$
- SW: $225 \leq \text{Direção} < 270$
- W: $270 \leq \text{Direção} < 315$
- NW: $315 \leq \text{Direção} < 360$

De forma semelhante, o desvio padrão da direção do vento é dividido em três categorias para representar a variação angular da direção, crucial para entender a estabilidade das condições do vento:

- Baixa variação angular: $\text{Desvio} < 4^\circ$
- Variação angular média: $4^\circ \leq \text{Desvio} < 7^\circ$
- Alta variação angular: $\text{Desvio} \geq 7^\circ$

Essas transformações permitem a aplicação eficaz do método *Rough Sets*, fornecendo uma base clara para analisar e comparar os diferentes estados operacionais e condições ambientais dos aerogeradores, facilitando a identificação de padrões relevantes para manutenção preditiva e otimização de desempenho.

A aplicação do método *Rough Sets* aos dados em questão foi suportada pelo software ROSETTA [43], uma ferramenta desenvolvida especificamente para reconhecimento de padrões e mineração de dados no contexto da Teoria dos Conjuntos Aproximados. Diferentemente da maioria dos métodos de ML, os modelos baseados em regras são facilmente interpretáveis e podem ser usados para identificar padrões nos dados e gerar previsões. As regras geradas pelo ROSETTA seguem o formato:

"SE premissa_1 E premissa_2 E ... E premissa_n ENTÃO conclusão_1 OU conclusão_2 OU ... OU conclusão_m"

onde n é o número de premissas, limitado ao número de variáveis; m é o número de conclusões, limitado ao número de classes existentes.

No contexto deste trabalho, dois resultados dessa aplicação são particularmente relevantes: as regras e as métricas de desempenho. Cada regra produzida pelo método *Rough Sets* vem acompanhada de um conjunto de parâmetros que qualificam a regra em determinados aspectos:

- *Suporte LHS*: Número de objetos no conjunto de treinamento que correspondem à parte SE da regra;
- *Suporte RHS*: Número de objetos no conjunto de treinamento que correspondem simultaneamente à parte SE e ENTÃO da regra (LHS e RHS serão iguais, a menos que a parte ENTÃO contenha múltiplas decisões);

- *Precisão RHS*: Suporte RHS dividido pelo suporte LHS (Precisão será 1,0 a menos que a parte ENTÃO contenha múltiplas decisões);
- *Cobertura LHS*: Suporte LHS dividido pelo número de objetos no conjunto de treinamento;
- *Cobertura RHS*: Suporte RHS dividido pelo número de objetos da classe de decisão listada na parte ENTÃO da regra;
- *Comprimento LHS*: Número de atributos na parte SE da regra;
- *Comprimento RHS*: Número de decisões na parte ENTÃO da regra.

A tabela de decisão (TABELA VI) é derivada do conjunto de dados transformado, agora estruturado de acordo com a metodologia *Rough Sets*. Esse formato facilita a aplicação de regras de decisão baseadas em condições definidas categoricamente. Cada linha representa um caso específico com a categorização da direção do vento, classe de velocidade do vento e outros atributos relevantes, combinados com o tipo de erro acionado. Essa abordagem estruturada permite uma análise mais clara de como diferentes condições levam a problemas operacionais específicos.

As regras de decisão derivadas da Teoria dos Conjuntos Aproximados são obtidas analisando padrões recorrentes em dados históricos de falhas dos aerogeradores. A metodologia envolve categorizar condições ambientais—como velocidade do vento, índice de turbulência e direção—em classes discretas, permitindo uma comparação sistemática entre diferentes cenários operacionais. Ao identificar combinações de variáveis que frequentemente precedem modos de falha específicos, o método extrai regras no formato:

"SE condição do vento X E turbulência Y ENTÃO falha Z".

Essas regras fornecem uma estrutura interpretável para prever e prevenir falhas, oferecendo insights valiosos para ajustes operacionais nos aerogeradores.

3.5. Avaliação

Para os modelos de aprendizado de máquina (ML) baseados em classificação, uma variedade de métricas de desempenho pode ser utilizada para avaliar a eficácia dos modelos empregados. Estas incluem acurácia, acurácia balanceada, precisão, sensibilidade (ou recall), F1 Score, entre outras. Dadas as características do problema apresentado, conforme detalhado anteriormente, decidiu-se utilizar a Acurácia Balanceada como métrica, devido à sua capacidade de fornecer uma avaliação equilibrada em cenários com distribuições desiguais de classes.

TABELA VI. Tabela de Decisão, Formada a partir da Transformação dos Dados Originais

Direção do Vento	Classe de Velocidade do Vento	Desvio Padrão Direção do Vento	Desvio Padrão Velocidade do Vento	Índice de Turbulência	Gatilho
S	C	baixa var	média var	baixa turb	Erro pitch
SE	B	alta var	média var	baixa turb	Erro conversor
S	A	alta var	média var	alta turb	Erro conversor
S	A	alta var	média var	alta turb	Erro aceleração
SE	B	alta var	alta var	média turb	Erro pitch
SE	A	alta var	média var	alta turb	Erro pitch

Além disso, a estratégia “one-vs-all” foi adotada para otimizar o desempenho dos modelos de aprendizado de máquina utilizados. Essa técnica permite o tratamento individual de cada classe contra todas as outras, facilitando o gerenciamento de desequilíbrios entre categorias.

A FIGURA 3 apresenta uma série de gráficos do tipo *box plot* demonstrando o desempenho dos algoritmos de ML utilizados na previsão de desligamentos dos aerogeradores, para cada tipo de erro associado, considerando os 19 aerogeradores do Parque Eólico Praias de Parajuru.




FIGURA 3. Box plots demonstrando o desempenho dos algoritmos de ML utilizados na previsão de desligamentos dos aerogeradores, para cada tipo de erro associado, considerando os 19 aerogeradores do Parque Eólico Praias de Parajuru

A partir da FIGURA 3, pode-se observar que:

- **Erro no Conversor:** O modelo *K Nearest Neighbours* (KNN) apresenta a maior mediana de acurácia balanceada, indicando desempenho geralmente superior na previsão dessa categoria de falha. O modelo *Multi-layer Perceptron* (MLP) também demonstra boa acurácia mediana, porém com maior variação, sugerindo uma consistência ligeiramente menor.
- **Erro de Aceleração:** Os modelos *Gradient Boosting* (GB), *Multi-layer Perceptron* (MLP), *Naive Bayes* (NB) e *Support Vector Machine* (SVM) apresentaram desempenhos similares, com variabilidade relativamente baixa.
- **Erro no Sistema de Pitch:** Nesta categoria, o modelo *K Nearest Neighbours* (KNN) foi o que apresentou melhor desempenho entre os modelos considerados, embora as medianas fiquem ligeiramente acima de 0,5, o que, na prática, não representa resultados satisfatórios.

Em resumo, os modelos *K Nearest Neighbours* (KNN) e *Multi-layer Perceptron* (MLP) mostram-se mais eficientes do ponto de vista da acurácia balanceada para o tipo de problema apresentado. No entanto, vale destacar que a escolha do melhor modelo pode depender de outros fatores, como complexidade do modelo, tempo de treinamento e interpretabilidade, que não são diretamente abordados pela acurácia balanceada.

Também é necessário discutir a ocorrência de resultados em que a Acurácia Balanceada resultou em 0,5. Em um cenário de classificação binária, isso significa que o modelo está fazendo previsões corretas em um nível equivalente ao de um classificador aleatório, ou seja, não possui capacidade discriminativa entre classes melhor que o acaso. O desempenho subótimo dos modelos de ML na previsão de certos tipos de falhas em aerogeradores pode ser atribuído à natureza complexa dessas falhas, que nem sempre estão diretamente correlacionadas com as variáveis operacionais utilizadas, como direção do vento, velocidade do vento e suas respectivas variações (variáveis fornecidas como entrada aos modelos). Por exemplo, falhas mecânicas internas, como defeitos em rolamentos ou problemas de alinhamento no sistema de transmissão, podem estar mais relacionadas ao histórico de manutenção e à idade do equipamento do que a variáveis meteorológicas ou operacionais imediatas. De forma similar, falhas elétricas podem estar mais conectadas a flutuações na rede elétrica ou defeitos em componentes que não são evidentes a partir dos dados operacionais padrão. A ausência de variáveis de entrada que capturem diretamente a condição e desgaste de componentes críticos, ou mesmo aspectos como qualidade de instalação e manutenção, pode limitar a capacidade dos modelos de prever com precisão tais falhas. Portanto, é importante reconhecer que a inclusão de dados de manutenção, histórico de falhas anteriores e análises do estado dos equipamentos pode ser necessária para melhorar o desempenho de modelos preditivos em cenários de monitoramento de aerogeradores, quando este for o objetivo da análise.

É necessário estabelecer um limiar para a Acurácia Balanceada, que permita inferir que as variáveis de entrada explicam adequadamente as anomalias observadas nos aerogeradores. Segundo critério do autor, resultados acima de 0,70 são considerados razoáveis para prever com precisão ambas as classes; acima de 0,80, o modelo é considerado eficaz na classificação de instâncias em ambas as classes; e acima de 0,90 são considerados excelentes.

A TABELA VII, portanto, destaca os eventos que foram adequadamente previstos pelos modelos de ML considerados neste trabalho. Pragmaticamente, revela que, apesar das diferenças entre os modelos de ML aplicados a vários tipos de erros em aerogeradores, as variações na acurácia balanceada são relativamente pequenas. Isso sugere que, na prática, a eficácia dos diferentes modelos é bastante semelhante, indicando certa uniformidade no desempenho desses modelos em contextos variados. Essa uniformidade no desempenho dos modelos pode indicar que os algoritmos de ML estão capturando de forma eficiente as tendências subjacentes nos dados, independentemente de suas abordagens específicas. Isso é uma boa notícia em termos de flexibilidade e robustez, pois sugere que engenheiros e cientistas de dados podem escolher entre uma variedade de modelos sem comprometer significativamente a acurácia.

Os padrões e tendências identificados refletem a complexidade e as peculiaridades operacionais dos aerogeradores. Esses padrões, destacados pela precisão e equilíbrio das métricas de desempenho, fornecem a base para a próxima fase da investigação, na qual os insights obtidos serão aprofundados por meio do método de *Rough Sets*.

Essa transição é essencial, pois permite que os achados derivados dos modelos de machine learning sejam integrados e interpretados em um contexto mais amplo de análise operacional e tomada de decisão. Os *Rough Sets*, com sua capacidade de lidar com incertezas e imprecisões, permitem uma exploração mais profunda das condições críticas que levam a desligamentos indesejáveis e falhas em aerogeradores. Assim, a relação entre a avaliação dos modelos e a implementação do método de *Rough Sets* não é apenas metodológica, mas também

conceitual, promovendo uma abordagem holística para compreender e mitigar os desafios enfrentados na operação de parques eólicos.

TABELA VII. Categorias de Anomalias que Alcançaram Resultados Adequados de Acurácia Balanceada, com os Respectivos Modelos de ML

Categoria	Aerogerador Eólica	Modelo de ML	Acurácia Balanceada
Erro de Aceleração	11	GB	0,71
Erro de Aceleração	11	MLP	0,77
Erro no Conversor	01	KNN	0,87
Erro no Conversor	01	MLP	0,84
Erro no Conversor	01	SVM	0,89
Erro no Conversor	03	KNN	0,74
Erro no Conversor	03	MLP	0,76
Erro no Conversor	03	SVM	0,74
Erro no Conversor	11	KNN	0,77
Erro no Conversor	11	MLP	0,82
Erro de Pitch	19	NB	0,79

3.6. Implementação

A aplicação do modelo de *Rough Sets* aos dados processados pelos modelos de machine learning revela padrões significativos por meio de regras de associação. Essas regras destacam condições específicas de vento que estão frequentemente associadas a falhas particulares em aerogeradores.

Para os fins deste trabalho, maior atenção deve ser dada às regras cujos eventos são considerados indesejáveis do ponto de vista de especialistas em manutenção de aerogeradores, conforme mostrado na TABELA VIII. Especificamente, interrupções operacionais associadas às funções de "Pitch" e "Conversor" não são justificáveis em condições de vento leve, caracterizadas por baixa velocidade, variações mínimas e baixa turbulência. Da mesma forma, paradas devido à "Aceleração" são consideradas inadequadas em cenários de intensidade de vento média ou baixa, acompanhadas de variações e turbulências igualmente médias ou baixas.

As causas das falhas dos aerogeradores podem ser classificadas de forma ampla em três categorias: estrutural, ambiental e operacional. Problemas estruturais surgem de limitações de projeto, fadiga de materiais e imperfeições na montagem, como observado no aerogerador #11, onde a deformação da torre aumentou a susceptibilidade a vibrações. Fatores ambientais, como turbulência do vento e mudanças rápidas de direção, contribuem para cargas inesperadas na nacelle e no rotor, potencialmente acionando mecanismos de proteção desnecessários. Fatores operacionais incluem desgaste de componentes, imprecisões em sensores e falhas na configuração do sistema de controle, como observado no aerogerador #10, onde encoders defeituosos levaram a falhas no sistema de pitch. Compreender essas causas subjacentes permite ações corretivas direcionadas, melhorando tanto a confiabilidade do aerogerador quanto a eficiência da manutenção.

As implicações práticas dessas regras de decisão se estendem diretamente às estratégias de manutenção e operação de parques eólicos. Ao implementar essas regras, os operadores podem ajustar os limites de proteção para minimizar paradas desnecessárias, mantendo a segurança. Por exemplo, se um determinado nível de turbulência for identificado

como gatilho recorrente para erros de aceleração na nacelle, uma estratégia temporária de redução de potência pode ser adotada para mitigar o problema sem exigir desligamento completo. Esses insights apoiam estratégias de manutenção baseadas em dados, reduzindo o tempo de inatividade e aumentando a confiabilidade dos aerogeradores.

Essas condições específicas apontam uma oportunidade significativa para investigar as causas internas que promovem tais interrupções indesejáveis. Uma análise detalhada seguida de intervenções adequadas nos sistemas de proteção e controle dos aerogeradores pode mitigar essas falhas. Consequentemente, espera-se que tais ações resultem em um aumento significativo na disponibilidade desses ativos. Esse aumento na disponibilidade não só melhora a eficiência operacional dos aerogeradores, mas também reforça a confiabilidade do sistema de energia eólica como um todo.

No contexto da implementação de medidas corretivas direcionadas aos aerogeradores 9, 10 e 11, que apresentaram maior frequência e relevância de falhas, várias estratégias específicas foram adotadas.

Para a aerogerador #11, foi confirmado que uma deformação em uma das seções durante a montagem da torre aumentou a susceptibilidade do equipamento a problemas de vibração. Em resposta, uma nova lógica de proteção de aceleração da nacelle foi implementada. Essa lógica visa mitigar falhas relacionadas à aceleração da nacelle, embora a aerogerador possa continuar apresentando um número significativo de falhas devido ao problema estrutural em uma de suas seções. Além disso, um estudo estrutural está em andamento para avaliar a condição da torre, focando na integridade e na implementação de possíveis reforços para aumentar sua rigidez.

A aerogerador #09, que não apresentou causas conhecidas específicas para as falhas, também teve alterações na lógica de proteção de aceleração da nacelle. A nova lógica reduz a potência instantânea por um minuto quando vibrações excessivas são detectadas, visando atenuar a aceleração para valores abaixo de 0,03G. Essa ação busca reduzir a oscilação da estrutura e evitar o desligamento do aerogerador. Essa mesma lógica foi estendida a todos os aerogeradores da frota, buscando um benefício coletivo.

Para a aerogerador #10, dois defeitos foram relatados intermitentemente. Além disso, dois encoders defeituosos foram descobertos e substituídos imediatamente. Após essas intervenções, observou-se que não houve mais atuações de proteção de pitch, e as falhas continuam sendo monitoradas para garantir que os problemas foram efetivamente resolvidos.

TABELA VIII. Análise Comparativa das Condições de Vento Associadas a Desligamentos Indesejáveis em Diferentes Categorias de Erros de Aerogerador Eólica, Com Ênfase nas Aerogeradores 09, 10 e 11, que Apresentaram Maiores Valores em LHS Support e em LHS Coverage, Indicando Maior Recorrência e Relevância para as Falhas Identificadas

Aerogerador	Acionamento	Classe de Velocidade do Vento	Desvio Padrão Velocidade	Índice de Turbulência	Direção do Vento	Desvio Padrão Direção	LHS Support	LHS Coverage
01	conversor	B	baixa_var	baixa_turb	SE	média_var	2	1%
01	conversor	B	baixa_var	baixa_turb	S	baixa_var	1	1%
02	pitch	B	baixa_var	baixa_turb	S	média_var	2	2%
02	conversor	B	baixa_var	baixa_turb	S	baixa_var	1	1%
03	aceleração, conversor	B	média_var	baixa_turb	S	baixa_var	14	18%
03	aceleração, conversor	B	média_var	baixa_turb	SE	baixa_var	8	11%
03	aceleração	B	baixa_var	baixa_turb	SE	baixa_var	1	1%
03	aceleração	B	baixa_var	baixa_turb	S	baixa_var	1	1%
04	pitch	B	baixa_var	baixa_turb	S	baixa_var	1	1%
07	conversor	B	baixa_var	baixa_turb	S	média_var	1	25%
09	conversor	B	baixa_var	baixa_turb	SE	baixa_var	1	0%
09	aceleração, conversor	B	média_var	baixa_turb	SE	baixa_var	44	21%
09	aceleração, conversor	B	média_var	baixa_turb	S	baixa_var	24	11%
09	aceleração, conversor	B	média_var	média_turb	S	baixa_var	14	7%
09	aceleração, conversor	B	média_var	média_turb	SE	baixa_var	8	4%
10	pitch	B	baixa_var	baixa_turb	SE	baixa_var	2	20%
10	aceleração, conversor	B	média_var	média_turb	SE	baixa_var	2	20%
10	aceleração	B	média_var	média_turb	S	baixa_var	1	10%
11	aceleração, conversor	B	baixa_var	baixa_turb	S	baixa_var	8	2%
11	aceleração, conversor	B	média_var	média_turb	S	baixa_var	56	17%
11	aceleração, conversor	B	média_var	média_turb	SE	baixa_var	47	14%
11	aceleração, conversor	B	média_var	baixa_turb	SE	baixa_var	43	13%
11	aceleração, conversor	B	média_var	baixa_turb	S	baixa_var	35	10%
11	aceleração	B	baixa_var	baixa_turb	SE	baixa_var	18	5%
11	aceleração, conversor	B	baixa_var	baixa_turb	S	baixa_var	8	2%
13	conversor	B	baixa_var	baixa_turb	SE	baixa_var	1	1%
19	pitch	B	baixa_var	baixa_turb	SE	baixa_var	3	4%
19	pitch	B	baixa_var	baixa_turb	S	baixa_var	2	3%
19	aceleração, conversor, pitch	B	média_var	média_turb	SE	baixa_var	6	9%

4. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

Este estudo apresentou uma análise detalhada das correlações entre falhas em aerogeradores e condições ambientais. Por meio do uso de técnicas de ciência de dados, foi possível identificar padrões significativos que contribuem para otimizar a manutenção e a eficiência operacional dos aerogeradores. Os resultados demonstram a viabilidade e a importância da aplicação de análises avançadas de dados no setor de energia eólica. Além disso, este estudo abre caminho para pesquisas futuras e aplicações práticas voltadas à melhoria contínua na operação e manutenção dos aerogeradores.

A aplicação de técnicas de Ciência de Dados na operação e manutenção de aerogeradores representa o estado da arte no campo das energias renováveis. Essa abordagem é crucial devido ao crescimento acelerado das fontes de energia renováveis, que geram volumes de dados além da capacidade de processamento humano. A análise eficiente desses dados é essencial para promover o desenvolvimento sustentável alinhado aos princípios ESG (Ambiental, Social e Governança). Esse campo emergente está em constante evolução, e o aprendizado contínuo nessa área é fundamental para avançar na sustentabilidade e na eficiência energética.

Durante o desenvolvimento, verificou-se que os modelos de machine learning utilizados revelaram padrões importantes a partir dos dados fornecidos, contribuindo para a otimização da manutenção e da eficiência operacional de alguns aerogeradores. Algumas anomalias detectadas não puderam ser totalmente explicadas com base nas informações disponíveis, sugerindo a necessidade de dados adicionais ou de outras abordagens analíticas para um entendimento mais profundo desses fenômenos. Essa limitação evidencia a complexidade dos sistemas de aerogeradores, onde fatores operacionais e estruturais, além das condições ambientais, podem influenciar o comportamento das falhas. Pesquisas futuras devem considerar a incorporação de dados complementares, como variáveis elétricas (corrente, tensão, qualidade de energia) e registros detalhados de manutenção, para fornecer uma compreensão mais abrangente da dinâmica das falhas. Contudo, essa percepção corrobora o objetivo deste trabalho, que é a identificação e caracterização da influência de variáveis ambientais (especialmente relacionadas ao vento) na ocorrência de falhas e atuações de proteção em aerogeradores.

A aplicação do método de *Rough Sets* permitiu uma visão analítica mais profunda dos eventos ocorridos sob condições de vento que, supostamente, não deveriam ter acionado proteções. Como os métodos de predição produziram resultados satisfatórios em termos de *balanced accuracy*, a combinação com o método de *Rough Sets* trouxe ainda maior robustez ao diagnóstico de falhas e ao consequente direcionamento para ajustes e correções, visando aumentar a confiabilidade na operação e manutenção dos aerogeradores.

Além disso, recomenda-se a aplicação de técnicas de Inteligência Artificial Explicável (XAI) para aprimorar a interpretabilidade dos modelos de machine learning, permitindo uma identificação mais clara das variáveis ambientais que mais influenciam as falhas observadas. Essas iniciativas futuras têm como objetivo complementar os achados atuais, promovendo uma análise mais holística do comportamento dos aerogeradores em diversos contextos operacionais. Em conclusão, este trabalho representa um avanço significativo na aplicação da ciência de dados para otimizar a operação e manutenção de aerogeradores, contribuindo não apenas para o aumento dos resultados operacionais dos empreendimentos, mas também estabelecendo um caminho para futuras inovações no uso de metodologias de ML no campo das energias renováveis.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ONS - Operador Nacional do Sistema Elétrico. "Relatório Anual 2022." Rio de Janeiro, 2022. Disponível em: https://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/Relatorio_Anual_ONS_2022.pdf
- [2] LAVEZZO, C. A. L. "Fontes de energia." Revista Eletrônica Gestão em Foco, Amparo, p. 102, 2016.
- [3] Amarante, O. A. C., Zack, M. B. J., & De Sá, A. L. "Atlas do Potencial Eólico Brasileiro." Brasília, 2001. Disponível em: http://www.cresesb.cepel.br/publicacoes/download/atlas_eolico/Atlas do Potencial Eolico Brasileiro.pdf. Accessed on April 15, 2023.
- [4] Silva, T. C. "Proposta de Planejamento de Manutenção de Aerogeradores, com base nas condições ambientais locais." Dissertação de Mestrado, Universidade Federal do ABC, Santo André, 2020.
- [5] Global Wind Energy Council (GWEC). "Global Wind Report 2024." Edited by Joyce Lee and Feng Zhao. Brussels, Belgium, 2024. Disponível em: www.gwec.net.
- [6] WWEA Annual Report 2023. World Wind Energy Association, 2024. WWEA Head Office – Charles-de-Gaulle-Str. 5, 53113 Bonn, Germany, 2023
- [7] Sankineni, P. V., Grace, A. H., Juliet, S., Lincy, E. U., & Joanna, J. "Data Analytics in Wind Turbine Generators for Improving Efficiency." Proceedings of the International Conference on Sustainable Computing and Data Communication Systems (ICSCDS), Erode, India, 2022, pp. 1-5. doi: 10.1109/ICSCDS53736.2022.9760
- [8] Kokila, M., & Isakki, P. "A survey of wind turbine control monitoring and fault detection on wind energy." Proceedings of the International Conference on Computing Technologies and Intelligent Data Engineering (ICCTIDE'16), Kovilpatti, India, 2016, pp. 1-4. doi: 10.1109/ICCTIDE.2016.7725341
- [9] Sambana, B., Naidu, P. A., Jarabala, R., & Narayana, V.N.S.L. "Performance validation of wind turbines using machine learning methodologies." Materials Today: Proceedings, vol. 80, part 3, 2023, pp. 2845-2849. ISSN 2214-7853. <https://doi.org/10.1016/j.matpr.2021.07.049>
- [10] Singh, U., & Rizwan, M. "SCADA System Dataset Exploration and Machine Learning Based Forecast for Wind Turbines." Results in Engineering, vol. 16, 2022, 100640, ISSN 2590-1230.
- [11] Bilendo, F., Badihi, h., Lu, N., Cambron, P., & Jiang, B. "An Intelligent Data-Driven Machine Learning Approach for Fault Detection of Wind Turbines." Proceedings of the 6th International Conference on Power and Renewable Energy (ICPRE), Shanghai, China, 2021, pp. 444-449. doi: 10.1109/ICPRE52634.2021.9635340. <https://doi.org/10.1016/j.rineng.2022.100640>.
- [12] Qian, P., Ma, X., Wang, Y. "Condition monitoring of wind turbines based on extreme learning machine." Proceedings of the 21st International Conference on Automation and Computing (ICAC), Glasgow, UK, 2015, pp. 1-6. doi: 10.1109/ICAC.2015.7313974.
- [13] Karadayi, B., Kuvvetli, Y., Ural, S. "Fault-related Alarm Detection of a Wind Turbine SCADA System." Proceedings of the 3rd International Congress on Human-Computer Interaction,

Optimization and Robotic Applications (HORA), Ankara, Turkey, 2021, pp. 1-5. doi: 10.1109/HORA52670.2021.9461331.

[14] Yan, H., Mu, H., Yi, X., Yang, Y., & Chen, G. "Fault Diagnosis of Wind Turbine Based on PCA and GSA-SVM." Proceedings of the 2019 Prognostics and System Health Management Conference (PHM-Paris), Paris, France, 2019, pp. 13-17. doi: 10.1109/PHM-Paris.2019.00010.

[15] Afrasiabi, S., Afrasiabi, M., Parang, B., Mohammadi, M., Arefi, M. M., & Rastegar, M. "Wind Turbine Fault Diagnosis with Generative-Temporal Convolutional Neural Network." Proceedings of the IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), Genova, Italy, 2019, pp. 1-5. doi: 10.1109/EEEIC.2019.8783233.

[16] Mazidi, P., Mian, D., & Sanz-Bobi, M. A. "A comparative study of techniques utilized in analysis of wind turbine data." Proceedings of the China International Conference on Electricity Distribution (CICED), Xi'an, China, 2016, pp. 1-5. doi: 10.1109/CICED.2016.7576412.

[17] Pawlak, Z. "Rough sets." International Journal of Computer and Information Sciences, vol. 11, pp. 341-356, 1982.

[18] Chaudhuri, B.B., Mitra, M., & Mitra, S. "A Rough-Set-Based Inference Engine for ECG Classification." IEEE Transactions on Instrumentation and Measurement, vol. 55, no. 6, pp. 2198-2206, Dec. 2006.

[19] Jagielska, I., Matthews, C., & Whitfort, T. "An Investigation Into The Application Of Neural Networks, Fuzzy Logic, Genetic Algorithms, And Rough Sets To Automated Knowledge Acquisition For Classification Problems." ELSEVIER Neurocomputing, vol. 24, pp. 37-54, 1999.

[20] Chen, L. F., & Chien, C.F. "Using Rough Set Theory To Recruit And Retain High-Potential Talents For Semiconductor Manufacturing." IEEE Transactions on Semiconductor Manufacturing, vol. 20, no. 4, Nov. 2007.

[21] Han, L., Peters, J.F., Ramanna, S., & Zhai, R. "Classifying Faults in High Voltage Power Systems: A Rough-Fuzzy Neural Computational Approach." Springer Berlin, Lecture Notes in Computer Science, vol. 1711, pp. 47-54, 1999.

[22] Bonaldi, E. L., Lambert-Torres, G., Silva, L. E. B., Oliveira, L. E. L. "A Rough Sets Based Classifier For Induction Motors Fault Diagnosis." WSEAS Transactions on Systems, London, vol. 2, no. 2, pp. 230-237, 2002.

[23] Cao, Y.J., Feng, L., Qiu, J.J. "Performance of the novel rough fuzzy-neural network on short-term load forecasting." Proceedings of the IEEE Power Systems Conference And Exposition, vol. 1, pp. 543-547, October 2004.

[24] Cerchiari, S. C., Lambert-Torres, G., Pinto, J. O. P., Sauer, L., Teurya, A., Zorzate, E.H. "Data Mining in Distribution Consumer Database using rough sets and Self-Organizing Maps." Proceedings of the IEEE PES Power Systems Conference and Exhibition, vol. 1, pp. 38-43, November 2006.

[25] Coutinho, M. P. "Detecção de Ataques em Infra-Estruturas Críticas de Sistemas Elétricos de Potência Usando Técnicas Inteligentes." Universidade Federal de Itajubá, 2007.

- [26] Crossley, P.A., Hor, C.L., Watson, S.J. "Building Knowledge for Substation-Based Decision Support Using Rough Sets." IEE Transactions on Power Delivery, vol. 22, no. 3, July 2007.
- [27] Chen, T. C., Pai, P. F. "Rough set theory with discriminant analysis in analyzing electricity loads." ELSEVIER Expert Systems with Applications, vol. 36, pp. 8799-8806, 2009.
- [28] Q. Xie et al., "GBG++: A Fast and Stable Granular Ball Generation Method for Classification." in IEEE Transactions on Emerging Topics in Computational Intelligence, vol. 8, no. 2, pp. 2022-2036, April 2024, doi: 10.1109/TETCI.2024.3359091.
- [29] Panda, B. "Why Data Science Projects Fail." ArXiv preprint arXiv:2308.04896, 2023. Disponível em <https://scholar.google.com/scholar?oi=bibs&cluster=12916297035869555991&btnI=1&hl=en>. Accessed on October 7, 2023.
- [30] Cemig, Companhia Energética de Minas Gerais. "Praias de Parajuru." 2023a. Disponível em <https://www.cemig.com.br/usina/praias-de-parajuru/>. Accessed on October 7, 2023.
- [31] Vensys. "Windturbine VENSYS 77/62b Event and Error Handling." Version 0.07, July 16, 2007.
- [32] Borges, M. M. "Machine Learning como ferramenta gerencial para predição de indicadores e detecção de anomalias." Master's Thesis, UFRGS, 2020. Disponível em <https://lume.ufrgs.br/handle/10183/218603?show=full>. Accessed on October 7, 2023.
- [33] Alla, S., & Adari, S. K. Beginning Anomaly Detection Using Python-Based Deep Learning: With Keras and PyTorch. 1st ed., Apress, 2019. <https://doi.org/10.1007/978-1-4842-5177-5>.
- [34] Muralidharan, S., et al. "A Comparative Study of Machine Learning Techniques for Wind Turbine Performance Prediction." E3S Web of Conferences, EDP Sciences, 2023, p. 04011.
- [35] Liu, Y., Wang, Y., & Zhang, J. "New Machine Learning Algorithm: Random Forest." In Information Computing and Applications, ICICA 2012. Lecture Notes in Computer Science, vol 7473, edited by B. Liu, M. Ma, J. Chang, Springer, Berlin, Heidelberg, 2012. https://doi.org/10.1007/978-3-642-34062-8_32.
- [36] Trizoglou, P., Liu, X., & Lin, Z. "Fault detection by an ensemble framework of Extreme Gradient Boosting (XGBoost) in the operation of offshore wind turbines." Renewable Energy, vol. 179, 2021, pp. 945-962, ISSN 0960-1481. <https://doi.org/10.1016/j.renene.2021.07.085>.
- [37] Liang, J., Zhang, K., Al-Durra, A., Mueen, S. M., & Zhou, D. "A state-of-the-art review on wind power converter fault diagnosis." Energy Reports, vol. 8, 2022, pp. 5341-5369, ISSN 2352-4847. <https://doi.org/10.1016/j.egy.2022.03.178>.
- [38] Helbing, G., & Ritter, M. "Deep Learning for Fault Detection in Wind Turbines." Renewable and Sustainable Energy Reviews, vol. 98, 2018, pp. 189-198, ISSN 1364-0321. <https://doi.org/10.1016/j.rser.2018.09.012>.
- [39] Waqas Khan, P., & Byun, Y.-C. "Multi-Fault Detection and Classification of Wind Turbines Using Stacking Classifier." Sensors, vol. 22, 6955, 2022. <https://doi.org/10.3390/s22186955>.
- [40] Pedregosa, F., et al. "Machine Learning in Python." Journal of Machine Learning Research, vol. 12, 2011, pp. 2825-2830.

- [41] Teixeira, V., Hetem, A., & Teixeira, J. (2022). "Analytical Model to Estimate the Influence of Turbulence Intensity on the Capacity Factor of Wind Farms."
- [42] Santos, M. V. H. G. dos, et al. "An Estimation Model for the Turbulence Index Using Wind Speed Averages in Wind Turbines." 2023 15th IEEE International Conference on Industry Applications (INDUSCON), 2023, pp. 1051-1054.
- [43] Komorowski, J., Øhrn, A., & Skowron, A. (2002). "The ROSETTA Rough Set Software System." In Handbook of Data Mining and Knowledge Discovery, edited by W. Klösgen and J. Zytkow, ch. D.2.3, Oxford University Press. ISBN 0-19-511831-6.

PANORAMA DAS TECNOLOGIAS INTELIGENTES E IOT PARA MONITORAMENTO DE CABOS EM PARQUES EÓLICOS: TENDÊNCIAS E DESAFIOS

Autores Jonas Duarte Molleta¹, Francisco Rodrigues¹, Paula Valerio¹, Carlos Koda²

FIT – Flextronics Instituto de Tecnologia¹, Prysmian Cabos e Sistemas do Brasil²

jonas.molleta@fit-tecnologia.org.br, francisco.rodrigues@fit-tecnologia.org.br, paula.valerio@fit-tecnologia.org.br, carlos.koda@prysmian.com.

RESUMO

A atual transição para fontes de energia renovável coloca a energia eólica como uma alternativa estratégica de grande relevância. No entanto, sua expansão exige uma infraestrutura robusta, na qual os cabos de energia assumem papel fundamental no transporte da eletricidade gerada. O monitoramento e a manutenção desses cabos representam desafios significativos, principalmente em áreas de difícil acesso, onde os métodos convencionais se mostram limitados ou ineficazes. Nesse contexto, tecnologias inteligentes têm se destacado como soluções promissoras.

Este trabalho realiza uma revisão crítica sobre a aplicação da Internet das Coisas (IoT) no monitoramento de cabos em parques eólicos, enfocando dispositivos e técnicas como RFID, Gêmeos Digitais, Inteligência Artificial e Aprendizado de Máquina. Por meio de uma análise sistemática da literatura recente, foram identificadas tendências, aplicações e barreiras técnicas. Os resultados apontam que a IoT possibilita o acompanhamento em tempo real e a manutenção preditiva, contribuindo para a redução de custos e melhoria da segurança operacional. Enquanto a tecnologia RFID facilita o rastreamento dos cabos, Gêmeos Digitais e técnicas de IA aprimoram a detecção rápida e precisa de falhas. Entretanto, a implementação industrial dessas ferramentas ainda enfrenta desafios como interferências de sinal, condições ambientais adversas, necessidade de integração entre sistemas, elevados investimentos iniciais e falta de mão de obra especializada. O progresso nesse campo depende do avanço tecnológico e da colaboração entre instituições acadêmicas, setor privado e políticas públicas que fomentem inovação e capacitação.

Palavras-chaves: IoT; Monitoramento de Cabos; Parques Eólicos; RFID; Digital Twin; Inteligência Artificial;

ABSTRACT

The current energy transition positions wind power as a key strategic alternative. However, its large-scale deployment requires a robust infrastructure, with power cables playing a crucial role in energy transmission. Monitoring and maintenance of these cables pose significant challenges, especially in hard-to-reach locations where traditional methods are limited or ineffective. In this context, intelligent technologies have emerged as promising solutions.

This paper presents a critical review of the application of the Internet of Things (IoT) in cable monitoring within wind farms, focusing on devices and methodologies such as RFID, Digital Twins, Artificial Intelligence, and Machine Learning. Through a systematic analysis of recent literature, trends, applications, and technical barriers were identified. Findings indicate that IoT enables real-time monitoring and predictive maintenance, reducing costs and enhancing operational safety. RFID technology facilitates cable tracking, while Digital Twins and AI techniques improve rapid and accurate fault detection. Nonetheless, industrial adoption faces challenges including signal interference, harsh environmental conditions, system interoperability requirements, high initial investments, and a shortage of qualified professionals. Progress in this field depends on technological advancement and collaboration between academia, industry, and public policies that encourage innovation and specialized training.

Keywords: IoT; Cable Monitoring; Wind Farms; RFID; Digital Twin; Artificial Intelligence.

1. INTRODUÇÃO

O aumento expressivo da demanda global por energia, impulsionado tanto pelo crescimento populacional quanto pelo ritmo acelerado da industrialização, tem sido acompanhado por uma urgência crescente em lidar com os impactos das mudanças climáticas. Esse contexto tem desencadeado uma transição energética sem precedentes, centrada na redução das emissões de carbono e na ampliação do uso de fontes renováveis, como a energia solar e a eólica. No cenário brasileiro, a energia eólica assume um papel de liderança na América Latina, com um potencial técnico *offshore* que excede 1.200 GW. Projeções indicam que essa indústria pode gerar mais de 516.000 empregos e um rendimento superior a R\$900 bilhões para a economia nacional até 2050 [1]. Para que essa transição seja viável e sustentável, torna-se essencial o desenvolvimento de uma infraestrutura de transmissão robusta, eficiente e, acima de tudo, resiliente [1]. Essa infraestrutura precisa ser capaz de conectar, com segurança e confiabilidade, fontes de geração frequentemente localizadas em áreas remotas — como parques eólicos em alto-mar ou grandes usinas solares instaladas em regiões áridas — à malha elétrica principal e, por consequência, aos consumidores [1].

Dentro desse cenário em transformação, os cabos de energia ocupam um papel estratégico. Funcionando como verdadeiras "artérias" do sistema, são eles que transportam a energia dos pontos de geração até a rede elétrica e, por fim, até residências, comércios e indústrias [1]. Por isso, atributos como desempenho, eficiência e vida útil desses cabos são determinantes para a operação confiável dos sistemas energéticos, bem como para a viabilidade econômica e ambiental dos projetos a longo prazo [1].

Atualmente, o mercado global de cabos de alta tensão vive um período de rápida expansão, impulsionado não apenas pela proliferação de projetos de energia limpa, mas também pela necessidade de modernização da infraestrutura elétrica já existente. Nos Estados Unidos, por exemplo, projeta-se que esse mercado registre um crescimento anual composto (CAGR) de 7,3% até 2033, com destaque para projetos eólicos de grande porte e novas interconexões hidrelétricas [2]. No entanto, a velocidade com que a capacidade de geração renovável está sendo instalada tem exposto um desafio estrutural relevante: a rede de transmissão não está evoluindo no mesmo ritmo [3].

Nesse contexto, a confiabilidade dos cabos e sua manutenção adequada tornam-se pontos centrais para garantir o êxito da transição energética. Ao mesmo tempo, políticas públicas e incentivos financeiros expressivos têm acelerado a demanda por infraestrutura elétrica mais avançada. Iniciativas como o *Inflation Reduction Act* (IRA) nos Estados Unidos, que destina US\$ 60 bilhões à modernização da rede, e o pacote *Fit for 55* da União Europeia, que prevê uma expansão de 35% na capacidade da rede até 2030, demonstram que essa transformação está sendo ativamente fomentada por governos [4].

Por outro lado, os desafios técnicos associados ao monitoramento e à manutenção de cabos de média e alta tensão permanecem, especialmente quando instalados em ambientes hostis, como túneis subterrâneos ou leitos oceânicos [5]. A dependência de sistemas externos e sensores adicionais, a ausência de cobertura por GPS ou rádio em ambientes com alta umidade e interferência eletromagnética, além das condições físicas adversas, limitam a confiabilidade e a durabilidade dos métodos tradicionais [6]. Esses problemas não são triviais: falhas em cabos representam um custo elevado para as operadoras, sendo que, no setor eólico offshore, estima-se que até 75% das solicitações de seguro estejam relacionadas a falhas em cabos de exportação [7].

Diante desse cenário, tecnologias inteligentes e soluções baseadas em Internet das Coisas estão ganhando protagonismo como alternativas viáveis para enfrentar esses obstáculos. A IoT permite conectar dispositivos físicos em larga escala, criando um sistema de comunicação contínuo entre sensores, equipamentos e plataformas de análise, o que viabiliza o monitoramento constante da integridade da infraestrutura elétrica [8, 9].

O presente artigo tem como objetivo preencher lacunas relevantes na literatura científica,

oferecendo uma análise abrangente e contextualizada das aplicações da IoT e de tecnologias inteligentes no monitoramento de cabos em parques eólicos e no setor de energia renovável como um todo.

1.1. OBJETIVO E ESTRUTURA DO ARTIGO

Este artigo analisa criticamente o uso de tecnologias inteligentes e IoT no monitoramento e gestão da integridade de cabos em parques eólicos, expandindo a análise ao setor de energia renovável. O objetivo é identificar avanços, tendências e barreiras à adoção em larga escala. A estrutura abrange a metodologia da revisão bibliográfica (Seção 2), fundamentos teóricos e tecnológicos da IoT no monitoramento (Seção 3), resultados e aplicações práticas como RFID e estudos de caso (Seção 4), desafios técnicos e operacionais (Seção 5), e perspectivas futuras para pesquisa e desenvolvimento (Seção 6).

2. METODOLOGIA

Este trabalho desenvolve uma revisão bibliográfica de caráter crítico e sistemático sobre a aplicação de tecnologias inteligentes e da Internet das Coisas (IoT) no monitoramento de cabos em parques eólicos, estendendo a análise ao setor de energia renovável.

2.1. ESTRATÉGIA DE BUSCA


O levantamento bibliográfico foi conduzido nas bases *Scopus*, *Web of Science*, *IEEE Xplore* e *Google Scholar*, abrangendo o período de 2013 a 2025, alinhado ao crescimento da pesquisa em IoT aplicada ao setor energético [12]. Utilizou-se uma combinação estratégica de palavras-chave em português e inglês, com operadores booleanos, para garantir abrangência e precisão. As buscas contemplaram termos relacionados a cabos inteligentes, monitoramento, detecção de falhas, manutenção preditiva, IoT, RFID, Gêmeos Digitais, Inteligência Artificial, aprendizado de máquina, além de temas específicos como parques eólicos, energia renovável, infraestrutura elétrica, cabos subterrâneos e submarinos, rastreabilidade e desafios tecnológicos.

2.2. ANÁLISE BIBLIOMÉTRICA

A revisão sistemática foi enriquecida por uma análise bibliométrica, que buscou mapear o crescimento e a direção da produção científica relacionada ao tema. Esse levantamento quantitativo serviu de suporte para entender o dinamismo da área e reforçar a importância de uma revisão crítica atualizada.

A Figura 1 apresenta o crescimento expressivo das publicações científicas que tratam da aplicação da Internet das Coisas (IoT) no setor de energia, com destaque para o pico de 3.330 publicações em 2024, conforme dados da base *Scopus*.


Figura 1 – Evolução do número de publicações relacionadas a “*IoT applications*” e “*energy*” na base *Scopus* (2024).



Fonte: Scopus (2025). Gráfico gerado pela base de dados.

Já a Figura 2 detalha a distribuição dessas publicações por país, revelando uma liderança da Índia (4.368 publicações), seguida por China (2.730) e Estados Unidos (2.274). O Brasil aparece com apenas 340 publicações nesse recorte, o que evidencia uma lacuna significativa na produção científica nacional frente ao cenário internacional.


Figura 2 – Distribuição das publicações por país relacionadas a “IoT applications” e “energy”.



Fonte: Scopus (2025). Gráfico gerado pela base de dados.

Complementando esse panorama, a Figura 3 mostra o crescimento contínuo das publicações científicas que combinam os termos “smart power grid” e “wind power”, com um total de 656 publicações no ano de 2024. Esse dado evidencia a importância crescente da integração entre redes inteligentes e geração eólica, refletindo o interesse por soluções tecnológicas mais eficientes e sustentáveis no setor elétrico.


Figura 3 – Evolução do número de publicações relacionadas a “smart power grid” e “wind power” na base Scopus (2010–2024).



Fonte: Scopus (2025). Gráfico gerado pela base de dados.

No entanto, a Figura 4 revela que, nesse mesmo recorte temático, o Brasil contribuiu com apenas 133 publicações — um número ainda muito modesto frente ao potencial do país na matriz eólica. Isso reforça a necessidade de políticas científicas, investimentos e incentivos à pesquisa nacional voltada à integração de tecnologias digitais com fontes renováveis.

Figura 4 – Distribuição das publicações por país relacionadas a “smart power grid” e “wind power”.



Fonte: Scopus (2025). Gráfico gerado pela base de dados.

Mais do que um aumento em números absolutos, esse cenário revela um campo em expansão acelerada, tanto no meio acadêmico quanto na indústria — o que reforça a atualidade e a necessidade da presente revisão.

A literatura analisada revela ainda uma convergência crescente entre disciplinas, configurando um ecossistema de pesquisa interligado. A infraestrutura digital, envolvendo IoT e redes inteligentes, vem sendo destacada como uma linha de investigação emergente dentro do campo das energias renováveis [11]. Estudos sobre cidades inteligentes baseadas em IoT reforçam esse panorama, evidenciando temas como gestão de energia, segurança da informação, privacidade e tratamento de dados como eixos centrais do debate [14].

3. FUNDAMENTAÇÃO TEÓRICA


3.1. ARQUITETURA IOT PARA MONITORAMENTO DE CABOS

A arquitetura típica de sistemas IoT para monitoramento de cabos elétricos organiza-se em três camadas: percepção, rede e aplicação [12]. A camada de percepção inclui sensores instalados nos cabos ou em sua vizinhança, responsáveis por medir variáveis como temperatura, corrente, umidade, vibração e acústica [12]. Esses dados permitem identificar alterações indicativas de falhas, como microfissuras (detectadas por sensores ultrassônicos) e corrosão (por sensores magnéticos) [13]. Em ambientes adversos, como túneis ou instalações submarinas, a robustez desses sensores é crítica [14]. Destaca-se a técnica de detecção de Descargas Parciais (DP), capaz de indicar degradações no isolamento elétrico que, agravadas por estresse elétrico, podem evoluir para falhas críticas [15].

A camada de rede trata da transmissão dos dados coletados, utilizando protocolos como LoRaWAN, Zigbee, MQTT ou CoAP, conforme os requisitos de alcance, energia e largura de banda [16]. Gateways são comumente empregados para integrar sistemas legados à rede IP. A eficiência da comunicação depende da escolha adequada do protocolo e infraestrutura.

Por fim, na camada de aplicação, os dados são processados e analisados por plataformas baseadas em cloud ou edge computing [17,18,19]. A relevância do tema se confirma pelo crescimento contínuo de publicações científicas sobre IoT e monitoramento de cabos, conforme demonstrado na Figura 5 (dados da Scopus), refletindo o avanço técnico-científico e o interesse industrial por soluções preditivas na gestão de infraestruturas elétricas.

Figura 5 – Evolução anual de publicações científicas com os termos "IoT" e "Cable Monitoring" (Fonte: SCOPUS, 2024).




Fonte: Scopus (2025). Gráfico gerado pela base de dados.

3.2. O PAPEL DA INTELIGÊNCIA ARTIFICIAL E DO APRENDIZADO DE MÁQUINA

O uso de Inteligência Artificial (IA) e Aprendizado de Máquina (ML) tem viabilizado a transformação de dados em ações preventivas por meio da identificação de padrões e anomalias [21]. Algoritmos aplicados à manutenção preditiva analisam dados históricos e em tempo real, permitindo reduzir até 70% do tempo de inatividade e 25% dos custos de manutenção [21]. Técnicas como redes neurais convolucionais (CNNs) e recorrentes (RNNs), integradas a sensores IoT, elevam em até 28% a acurácia na detecção precoce de falhas [20], enquanto modelos como a regressão Tobit auxiliam na previsão da degradação do isolamento em casos de Descargas Parciais [22]. Algoritmos como XGBoost e LightGBM têm se mostrado eficazes na priorização de intervenções e na otimização da vida útil dos equipamentos [17][20]. A Figura 6, baseada em dados da plataforma Scopus, destaca o crescimento exponencial das publicações científicas sobre IA na manutenção preditiva, com 2.048 registros apenas em 2024.

Figura 6 – Número de publicações sobre “Artificial Intelligence” e “Predictive Maintenance” ao longo dos anos



Fonte: Scopus (2025). Gráfico gerado pela base de dados.

4. RESULTADOS E DISCUSSÃO: APLICAÇÕES E DESEMPENHO NO MONITORAMENTO DE CABOS


Esta seção apresenta os principais achados da revisão bibliográfica, explorando como as tecnologias inteligentes e a Internet das Coisas (IoT) vêm sendo aplicadas no monitoramento de cabos. São discutidas também as tendências tecnológicas mais recentes, com o suporte de estudos de caso e exemplos reais que ilustram de maneira concreta o impacto dessas soluções.

4.1. RASTREABILIDADE E IDENTIFICAÇÃO COM RFID

A tecnologia de Identificação por Radiofrequência (RFID) tem se destacado na gestão de cabos por superar limitações de métodos tradicionais, como códigos de barras e registros manuais [23]. A identificação automática, sem necessidade de contato ou linha de visão, agiliza processos em ambientes complexos e permite a leitura simultânea de múltiplas etiquetas, otimizando a inspeção em grandes instalações [23][24]. Cada etiqueta possui um identificador único (UID), assegurando a integridade dos dados e dificultando fraudes [24]. Informações como número de série, data de instalação e características técnicas podem ser armazenadas na própria etiqueta, promovendo rastreabilidade contínua, automação de registros e redução de erros humanos e custos operacionais [24].

Para localização subterrânea, modelos geométricos baseados em círculos circunscritos, combinados com coordenadas GPS, permitem estimativas precisas de posição e profundidade dos cabos [25][26]. Em solos úmidos, modelos de campo magnético que consideram frequência e propriedades eletromagnéticas do solo são fundamentais, sendo o modelo de Morrison indicado para terrenos complexos [28]. A Figura 1 evidencia o crescimento de publicações sobre RFID no setor energético, refletindo o aumento do interesse científico por soluções inteligentes na área.

Figura 7 – Número de publicações relacionadas a “RFID” no setor de “Energia”




Fonte: Scopus (2025). Gráfico gerado pela base de dados.

4.2. MONITORAMENTO EM TEMPO REAL E MANUTENÇÃO PREDITIVA

A adoção de sensores IoT e plataformas de análise de dados tem impulsionado a transição de manutenções corretivas para estratégias preditivas mais eficazes. Tecnologias como o Smart Cable Guard detectam descargas parciais (DP) por meio de pulsos de teste, permitindo identificar falhas iminentes com dias ou semanas de antecedência [27]. A localização de defeitos utiliza ondas viajantes geradas pelo próprio evento, com erro inferior a 1% do comprimento do cabo, sem impactar sua estrutura — abordagem crucial em ambientes remotos, como parques eólicos *offshore* [27]. Sistemas baseados em IoT e inteligência artificial podem reduzir até 70% do tempo de inatividade e 25% dos custos de manutenção [21], além de antecipar intervenções e minimizar riscos para técnicos em campo [25]. O crescente interesse por essas soluções é confirmado pela Figura 8, que mostra o aumento constante de publicações na base Scopus sobre sensores subterrâneos (“*Underground Sensors*”), ultrapassando 600 por ano em 2024, o que evidencia a relevância de tecnologias robustas e inteligentes para garantir a confiabilidade de infraestruturas elétricas subterrâneas.

Figura 8 – Evolução anual das publicações científicas sobre “*Underground Sensors*” para monitoramento de infraestruturas



Fonte: Scopus (2025). Gráfico gerado pela base de dados.

4.3. CASOS REAIS E APLICAÇÕES PRÁTICAS

O uso de tecnologias inteligentes e IoT no monitoramento de cabos e infraestruturas elétricas já não se limita a ambientes experimentais. Várias empresas e instituições têm adotado essas soluções com sucesso, como demonstram os estudos de caso apresentados na Tabela 1, que resume as iniciativas analisadas nesta revisão.

Tabela 01 – Casos Reais e Aplicações práticas de IoT no monitoramento de cabos.

Estudo/Sistema	Objetivo Principal	Metodologia/Tecnologia	Principais Achados/Resultados
Sistema Smart Cable Guard [1]	Monitoramento em tempo real de cabos de distribuição para detecção de falhas e pontos fracos.	Tecnologia de injeção de pulso para vigilância 24/7 de Descarga Parcial (DP); Algoritmos avançados de ML e IA; Detecção de ondas viajantes.	Detecta falhas em minutos e pontos fracos semanas/meses antes; Alta precisão na localização de falhas (1% do comprimento do cabo); Reduz falsos positivos e classifica urgência; Integração com GIS e SCADA.
Sistemas de Marcação Eletrônica (EMS) [2]	Marcação e localização precisa de utilidades subterrâneas, incluindo cabos, com opções RFID.	Marcadores eletrônicos passivos e RFID enterrados; Codificação por frequência/cor; Armazenamento de dados específicos da instalação; Integração com GIS.	Localização precisa por anos; Facilita identificação rápida e precisa; Reduz riscos de segurança, atrasos e custos em projetos de construção (ex: Virginia DOT).
Sistemas Inteligentes de Monitoramento Online para Cabos de Energia [3]	Detecção e posicionamento de falhas em cabos de energia subterrâneos.	Microcontroladores (Arduino/ESP32); Simulação de linha de cabo com resistores e chaves; Detecção de mudanças de voltagem; Transmissão de dados para nuvem (Blynk) via Wi-Fi.	Vantagens de conveniência, baixo custo e alta confiabilidade; Dados de monitoramento válidos e confiáveis; Supera métodos tradicionais em continuidade e erro de diferença da curva medida; Detecta curto-circuito, circuito aberto e falhas de aterramento.
Iniciativa SMART Subsea Cables [4]	Integrar sensores ambientais em cabos de telecomunicações submarinos para coleta de dados oceânicos.	Integração de sensores de temperatura, pressão, aceleração sísmica em cabos de telecomunicações.	Viabilidade de usar infraestrutura de cabos de telecomunicações para fins científicos; Coleta de dados oceânicos em tempo real com impacto mínimo no ambiente e na indústria.
Ferramenta de Detecção de Cabos Subterrâneos com RFID [5]	Inovar na localização de interferências em linhas de cabos subterrâneos de MT e pontos de conexão.	Sistema baseado em RFID; Leitor RFID ativa tags enterradas; Alcance de leitura de até 30 cm de profundidade.	Reduz tempo de localização de interferências (de 4-7 dias); Destaca importância de sinais de identificação para cabos e junções não visíveis.
Método de Localização RFID Passiva LF Subterrânea [6]	Propor novo método de localização RFID passiva LF para dutos subterrâneos não metálicos.	Modelo de campo magnético da antena do leitor considerando influência do meio subterrâneo; Plataformas experimentais de localização RFID subterrânea.	Erro máximo de localização inferior a 0,32 cm; Aprimora a precisão da localização RFID em ambientes subterrâneos complexos.
Viabilidade de RFID UHF para Sensores de Solo Subsuperficiais [7]	Investigar viabilidade de RFID UHF para comunicação com sensores subsuperficiais no solo.	Experimentos com leitor operando próximo ao limite da FCC; Variação de umidade do solo.	Alcances de leitura superiores a meio metro para umidade $\leq 15\%$; Atenuação significativa/total acima de 15% de umidade; Alcances desejáveis para profundidades de até 15 cm.
Localização de Objetos Enterrados no Solo Usando Tags RFID [8]	Introduzir protocolo de localização para objetos não metálicos enterrados em solo não magnético usando tags RFID.	Método deduz profundidade do objeto a partir da indução magnética no campo próximo; Foco em 13,56 MHz; Análise de precisão da estimativa de profundidade.	Modelo suportado por experimentos laboratoriais; Relevante para detecção de dutos enterrados, considerando variação das propriedades dielétricas do solo.
REFERÊNCIAS: [1] DNV. Smart Cable Guard: integrated real-time monitoring for power distribution cables. [S.l.]: DNV, [s.d.]. Disponível em: https://www.dnv.com/energy/services/smart-cable-guard/ . Acesso em: 18 jul. 2025. [2] 3M. Locating & Marking. 3M Infrastructure. [S.l.]: 3M, [s.d.]. Disponível em: https://www.3m.com/3M/en_US/infrastructure-us/applications/locating-marking/ . Acesso em: 18 jul. 2025. [3] HOSSAIN, Md Sanwar; RAHMAN, Mostafizur; SARKER, Md Tuhin; HAQUE, Md Ershadul; JAHID, Abu. A smart IoT based system for monitoring and controlling the sub-station equipment. Internet of Things, [S.l.], v. 7, p. 100085, 2019. [4] SMART Cables. The SMART Cables Joint Task Force (JTF): visão geral da iniciativa SMART Subsea Cables. [S.l.]: SMART Cables, [s.d.]. Disponível em: https://www.smartcables.org/jtf . Acesso em: 18 jul. 2025. [5] RAMADHANI, Lindu Adji; SUDJOKO, Rifiandri Indrianto; HARIYADI, Setyo. Detection tool for underground cable lines and connections in distribution systems based on Radio Frequency Identification (RFID). In: INTERNATIONAL CONFERENCE OF ADVANCED TRANSPORTATION, ENGINEERING, AND APPLIED SOCIAL SCIENCE, 2., 2023, [S.l.]. Proceedings. [S.l.]: [s.n.], 2023. v. 2, n. 1, p. 524–531. [6] ZHU, Jixuan; CHEN, Guang; TIAN, Guoping; LIU, Huan. Underground passive LF RFID localization method based on magnetic field model of reader coil antenna. IEEE Transactions on Instrumentation and Measurement, v. 73, p. 1–10, 2023. [7] BAUER-REICH, Cherish; TAN, Kay Chen; HARING, Frederik; SCHNECK, N.; WICK, A.; BERGE, L.; HOEY, Jesse; SAILER, Rudolf; ULVEN, Chad. An investigation of the viability of UHF RFID for subsurface soil sensors. In: IEEE INTERNATIONAL CONFERENCE ON ELECTRO/INFORMATION TECHNOLOGY, 2014, Piscataway. Anais. Piscataway: IEEE, 2014. p. 577–580. [8] KHOKHLOVA, Vitalia; DELEVOYE, Elisabeth. The localization of buried objects in the soil using an RFID tag: protocol description and parameter estimation with the model of the oscillating magnetic field in media. IEEE Transactions on Magnetics, v. 55, n. 5, p. 1–16, 2019.			

Fonte: Elaborado pelo autor.

4.4. TENDÊNCIAS E INOVAÇÕES EMERGENTES NO MONITORAMENTO DE CABOS

O monitoramento de cabos vem passando por mudanças significativas, impulsionado por inovações tecnológicas como Gêmeos Digitais, Inteligência Artificial (IA) e Aprendizado de Máquina (ML). Essas ferramentas vêm se consolidando como peças-chave na transformação digital das infraestruturas energéticas, abrindo caminho para uma gestão mais precisa, preditiva e automatizada.

4.5.1. Gêmeos Digitais (*Digital Twins*)

A aplicação de Gêmeos Digitais (*Digital Twins - DT*) no setor elétrico, fundamento da Indústria 4.0, possibilita a criação de modelos virtuais detalhados de ativos físicos, como cabos de energia, alimentados por dados coletados por sensores e processados por algoritmos inteligentes [29]. Esses modelos permitem monitoramento quase em tempo real com visualizações interativas que replicam ambientes de difícil acesso, como instalações subterrâneas ou submersas [30]. Os DTs aprimoram a manutenção preditiva ao simular o comportamento dos sistemas em diferentes condições, antecipando falhas e reduzindo incidentes inesperados em até 35% [20]. Além disso, promovem colaboração remota entre equipes multidisciplinares, otimizando decisões e reduzindo custos logísticos [30]. Facilitam ainda a inspeção e o cumprimento normativo ao digitalizar informações, agilizando a identificação de riscos [30]. Estrategicamente, a integração dos Gêmeos Digitais transforma práticas reativas em proativas, aumentando transparência, confiabilidade operacional e alinhamento com objetivos de sustentabilidade [31].

4.5.2. Inteligência Artificial e Aprendizado de Máquina

As aplicações de IA e ML têm impulsionado soluções avançadas para monitoramento inteligente de cabos, aumentando a precisão das análises, automatizando processos e fortalecendo a resiliência dos sistemas. Modelos preditivos baseados em IA alcançam acurácia entre 85% e 95%, reduzindo alarmes falsos em até 50% e diminuindo o tempo de restauração em até 60% [20]. Técnicas como Redes Neurais Convolucionais (CNNs) e Redes Neurais Recorrentes (RNNs) identificam padrões temporais complexos nos dados elétricos [20]. A IA também otimiza a gestão, priorizando intervenções conforme a criticidade dos ativos e prolongando sua vida útil [20]. Algoritmos de aprendizado por reforço aplicados a redes auto-regenerativas detectam falhas, isolam trechos afetados e redirecionam o fluxo de energia, prevenindo até 45% das interrupções típicas de redes convencionais [20].

4.5.3. Integração com Smart Grids e Cidades Inteligentes

O monitoramento inteligente de cabos integra-se cada vez mais a redes elétricas inteligentes (*Smart Grids*) e cidades inteligentes (*Smart Cities*), formando uma arquitetura tecnológica integrada e dinâmica [32]. Os cabos, antes passivos, passam a atuar como nós inteligentes capazes de gerar e transmitir dados em tempo real, refletindo a aplicação dos princípios da Indústria 4.0 na infraestrutura elétrica e tornando a rede mais responsiva e adaptativa [33], [23]. A incorporação de sensores, IA e comunicação bidirecional melhora a eficiência energética, a coordenação de fontes distribuídas e a confiabilidade da rede, essenciais diante da crescente descentralização e complexidade dos sistemas modernos [8].

5. DESAFIOS E BARREIRAS

Apesar dos benefícios evidentes trazidos pelas tecnologias inteligentes e pela Internet das Coisas (IoT) na gestão de cabos, a adoção em larga escala dessas soluções ainda esbarra em obstáculos relevantes. Tais barreiras envolvem não apenas aspectos técnicos e operacionais, mas também questões econômicas, de segurança da informação e organizacionais.

5.1. LIMITAÇÕES TÉCNICAS

Cabos instalados em ambientes subterrâneos ou subaquáticos enfrentam condições severas, como alta umidade, variações extremas de temperatura, espaço restrito e difícil acesso, comprometendo a confiabilidade dos sensores e dificultando o uso de RFID, que requer encapsulamentos robustos e componentes especializados [14]. A umidade interfere na propagação de sinais de radiofrequência, limitando leituras RFID UHF a cerca de 15 cm sob solo com umidade acima de 15% [34]. A interferência eletromagnética dos cabos energizados e a atenuação do sinal em solo úmido afetam a comunicação com etiquetas, especialmente em frequências acima de 800 MHz; por isso, frequências mais baixas, como HF (13,56 MHz), são preferidas para melhor penetração [35]. Em cabos submarinos, sensores devem operar durante toda a vida útil sem manutenção, impondo exigências rigorosas de durabilidade e confiabilidade, área ainda em pesquisa ativa [35].

5.2. DESAFIOS TÉCNICOS E CONTEXTO DE CABOS INTELIGENTES NO BRASIL

5.2.1 INFLUÊNCIA DE TIPOS DE SOLO E UMIDADE

A instalação de cabos subterrâneos no Brasil depara-se com particularidades do solo e altos níveis de umidade que representam obstáculos significativos. Simplesmente enterrar os cabos diretamente no solo não é uma prática aconselhável devido à ação de elementos químicos presentes no solo sobre o material isolante dos cabos, um efeito intensificado pela umidade. Os solos argilosos comuns no Brasil, ao secarem, podem rachar e formar lacunas de ar ao redor dos cabos, elevando a resistência térmica e gerando pontos quentes que aceleram a degradação do isolamento [36]. A densidade e o teor de água do solo influenciam diretamente na resistividade térmica, tornando essencial sua medição em projeto [37]. Além disso, a alta umidade do solo favorece a penetração de água no isolamento, reduzindo sua resistência e favorecendo falhas elétricas [38]. Em cenários de aterro mal compactado, a expansão e contração podem criar bolsões de ar, aumentando a temperatura dos cabos e risco de falha do isolamento [38].

5.2.2 EFEITOS DA SALINIDADE E CLIMAS EXTREMOS

A salinidade é fator crítico no Brasil, especialmente em regiões semiáridas e costeiras, onde altas concentrações de sais no solo e ar intensificam a corrosão eletroquímica em cabos subterrâneos, comprometendo a integridade estrutural e a confiabilidade do isolamento [39], [40]. A combinação de alta umidade e salinidade acelera a degradação do isolante por meio da formação de zonas anódicas e catódicas, reduzindo a vida útil dos cabos e aumentando intervenções corretivas [41]. Ensaios laboratoriais confirmam a degradação acelerada da isolação em ambientes salinos, simulando condições marinhas e alagadiças [42]. Em áreas costeiras, névoa salina e sais de cloreto ameaçam tanto os cabos quanto sensores embarcados para monitoramento [39]. Portanto, soluções para o contexto brasileiro exigem materiais e encapsulamentos resistentes à corrosão, conforme padrões industriais marítimos, elevando a complexidade e custo dos projetos em comparação a ambientes menos agressivos [42].

5.2.3 DESAFIOS DO RELEVO COSTEIRO E ACIDENTADO

Embora não haja dados detalhados sobre os desafios do relevo costeiro na instalação de cabos inteligentes em parques eólicos brasileiros, observa-se crescimento de projetos offshore no Rio Grande do Sul, com diversas propostas em licenciamento ambiental [43], [44]. O relevo costeiro gaúcho, formado por planícies litorâneas, cordões arenosos e coxilhas suaves, impõe riscos logísticos e de segurança na instalação do cabeamento onshore vinculado aos parques offshore [45], [46]. Áreas com topografia acidentada, como planaltos dissecados e escarpas, aumentam a complexidade técnica para sistemas subterrâneos [46]. A falta de estudos específicos indica lacuna na pesquisa sobre a interação entre relevo, técnicas de instalação e operação de cabos inteligentes [44], [47]. Essa complexidade requer engenharia avançada, eleva riscos e custos, impactando a viabilidade técnica e econômica dos projetos [47].

5.2.4 ESTUDOS DE CASO E EXPERIÊNCIAS BRASILEIRAS

A literatura e documentos analisados indicam escassez de dados e experiências

brasileiras sobre cabos inteligentes com sensores embarcados (RFID, fibra óptica, telemetria) para monitoramento em parques eólicos onshore e offshore, evidenciando a necessidade de mais pesquisa, regulamentação e investimento no tema no Brasil. Embora existam iniciativas relacionadas, a aplicação documentada em cabos de energia eólica com monitoramento avançado ainda é limitada. Destaca-se o projeto da Planta Piloto de Energia Eólica *Offshore* do SENAI RN, em Areia Branca (RN), que funciona como sítio de testes para aerogeradores offshore (8,5 MW e 16 MW), conectados por cabos submarinos à subestação local, visando substituir combustíveis fósseis e reduzir emissões [48]–[51]. O monitoramento ambiental obrigatório inclui fauna marinha, ruído subaquático, qualidade da água e ar [48], [51]. A Prysmian integra o consórcio do projeto [49]. O Laboratório de Sensores a Fibra Óptica (LSFO) da PUC Rio, referência nacional em sensoriamento por fibra óptica e integração com IoT e IA, demonstra potencial para desenvolvimento de monitoramento inteligente de cabos, apesar da ausência de casos específicos em energia eólica [49], [52], [53].

6. COMPARATIVO DE DESAFIOS: BRASIL VS. CENÁRIO GLOBAL

A adoção de tecnologias inteligentes para monitoramento de cabos no setor de energia, com foco em parques eólicos, apresenta desafios tanto em escala global quanto no contexto específico brasileiro. Enquanto alguns obstáculos são universais, as particularidades geográficas, econômicas e regulatórias do Brasil acentuam ou modificam a natureza desses desafios, conforme ilustrado na Tabela 02.

Tabela 02: Comparativo de Desafios na Adoção de Cabos Inteligentes: Cenário Global vs. Brasil

Categoria de Desafio	Desafios no Cenário Global	Desafios no Contexto Brasileiro	Análise Comparativa e Nuances Brasileiras
Técnicos	- Ambientes Hostis: Limitações de sensores e RFID em condições extremas (umidade, temperatura, espaço físico). - Interferência Eletromagnética: Atenuação de sinal em solo úmido e campos eletromagnéticos de cabos energizados. - Engenharia de Sensores: Requisitos rigorosos de durabilidade e confiabilidade para sensores em ambientes agressivos (submarinos).	- Ambientes Hostis: Exacerbado pela alta umidade e variações climáticas regionais, exigindo encapsulamentos ultrarresistentes. - Interferência Eletromagnética e Atenuação de Sinal: Problema acentuado pela heterogeneidade dos solos brasileiros (arenosos, argilosos, lateríticos) e alta umidade, que limitam a profundidade de leitura de RFID UHF. - Corrosão e Degradação de Isolamento: Acentuada pela alta umidade e salinidade em regiões costeiras, com degradação da isolação após ~1000h de operação em contato com umidade. - Engenharia de Sensores: Necessidade de P&D local para adaptação a condições geotécnicas e ambientais específicas, elevando custos.	Os desafios técnicos são universais, mas as condições climáticas e geográficas do Brasil (extensa costa, alta umidade, solos diversos) intensificam a complexidade. A propagação de sinal e a corrosão são problemas mais críticos, demandando soluções de engenharia de materiais e sensoriamento mais robustas e adaptadas localmente, o que eleva os custos de P&D e implementação.
Operacionais	- Escalabilidade das Soluções: Dificuldade em expandir a aplicação de tecnologias inteligentes em larga escala. - Interoperabilidade: Necessidade de comunicação entre diferentes plataformas e fornecedores. - Escassez de Profissionais Qualificados: Dificuldade em encontrar mão de obra com formação técnica adequada.	- Furtos de Cabos: Problema operacional significativo (ex: furtos de cobre), gerando interrupções e prejuízos. - Fim da Vida Útil de Ativos: Desafios na repotenciação e manutenção de parques eólicos antigos, com dependência de cadeia de suprimentos externa. - Escalabilidade e Interoperabilidade: Agravada pela infraestrutura legada e pela falta de padronização, criando risco de aprisionamento tecnológico.	Além dos desafios globais de escalabilidade e interoperabilidade, o Brasil enfrenta problemas operacionais específicos como furtos de cabos. A escassez de mão de obra qualificada é um gargalo mais acentuado, impactando diretamente a capacidade de implementação e manutenção.
Econômicos	- Custos Iniciais Elevados: Alto investimento inicial para implantação das tecnologias.	- Custo Elevado de Tecnologias Importadas: A dependência de componentes estrangeiros aumenta o investimento inicial e compromete a competitividade. - Lacuna Regulatória e de Padrões: A indefinição normativa desestimula investimentos e inovações, atrasando a adoção de smart grids.	O custo inicial elevado é um desafio global, mas no Brasil é intensificado pela dependência de importação e pela ausência de uma cadeia de valor local robusta.

Fonte: Elaborado pelo autor.

A análise comparativa indica que, apesar de o Brasil enfrentar desafios globais na adoção

de cabos inteligentes, fatores locais — como alta umidade, salinidade costeira e infraestrutura elétrica obsoleta — intensificam essas dificuldades. A necessidade de materiais avançados e mais caros, a escassez de mão de obra qualificada, dependência de importações e lacunas regulatórias agravam os obstáculos econômicos e operacionais para a implementação em larga escala. A ausência de uma estratégia integrada e incentivos fiscais específicos limita o aproveitamento do potencial brasileiro em energia eólica, retardando a adoção plena de redes elétricas inteligentes.

7. CONSIDERAÇÕES FINAIS

A crescente demanda por transmissão devido à transição para fontes renováveis, como a energia eólica, destaca o papel crucial dos cabos na infraestrutura elétrica. Monitorar e manter esses ativos em ambientes adversos, como subsolo e fundo do mar, permanece desafiador com métodos tradicionais. Tecnologias inteligentes, integradas à IoT, sensores conectados, processamento Edge e Cloud, e técnicas de IA e Aprendizado de Máquina possibilitam monitoramento contínuo e preditivo, com a tecnologia RFID destacando-se na rastreabilidade dos ativos. Avanços em Gêmeos Digitais e algoritmos sofisticados ampliam a automação e confiabilidade das redes. Entretanto, obstáculos técnicos — interferência eletromagnética, limitações de sinal em ambientes úmidos e encapsulamentos — e preocupações com segurança cibernética, privacidade e integridade dos dados limitam sua implementação. Desafios operacionais e econômicos incluem escalabilidade, interoperabilidade, custos iniciais e déficit de competências técnicas. Assim, a colaboração entre pesquisa, indústria e políticas públicas é vital para superar esses entraves, promovendo inovação, capacitação e regulação adequada. O monitoramento inteligente de cabos é essencial para consolidar uma matriz energética global eficiente, resiliente e segura, sustentando o futuro energético com solidez e visão de longo prazo.

REFERÊNCIAS

- [1] WORLD ECONOMIC FORUM. 'More than ambition': 6 experts on what's needed to accelerate the global energy transition. 2025. Disponível em: <https://www.weforum.org/stories/2025/06/experts-accelerate-the-global-energy-transition/>. Acesso em: 12 jul. 2025.
- [2] INKWOOD RESEARCH. High Voltage Cable Market Size to Surpass USD 58433.99 Million by 2032. 2024. Disponível em: <https://www.inkwoodresearch.com/reports/high-voltage-cable-market/>. Acesso em: 12 jul. 2025.
- [3] CSIS. Electricity Supply Bottleneck: U.S. AI Dominance. 2024. Disponível em: <https://www.csis.org/analysis/electricity-supply-bottleneck-us-ai-dominance>. Acesso em: 12 jul. 2025.
- [4] EPA. Summary: Inflation Reduction Act Provisions Related to Renewable Energy. 2022. Disponível em: <https://www.epa.gov/green-power-markets/summary-inflation-reduction-act-provisions-related-renewable-energy>. Acesso em: 12 jul. 2025.
- [5] EUROPARL. The 'fit for 55' package of July and December 2021. 2022. Disponível em: ([https://www.europarl.europa.eu/RegData/etudes/BRIE/2022/733513/EPRS_BRI\(2022\)733513_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2022/733513/EPRS_BRI(2022)733513_EN.pdf)). Acesso em: 12 jul. 2025.
- [6] MDPI. Existing condition monitoring techniques are restricted to highly constrained online monitoring systems. *Sensors*, v. 23, n. 17, p. 6172, 2023. Disponível em: <https://www.mdpi.com/1996-1073/16/17/6172>. Acesso em: 12 jul. 2025.
- [7] ACTEON. Maximising Power Cable Reliability for Offshore Wind. 2023. Disponível em: <https://acteon.com/blog/maximising-power-cable-reliability-for-offshore-wind/>. Acesso em: 12 jul. 2025.

[8] AIMS ENERGY. INTERNET OF THINGS FOR SMART ENERGY SYSTEMS: A review on its applications, challenges and future trends. 2023. Disponível em: (<https://www.aimspress.com/article/doi/10.3934/electreng.2023004?viewType=HTML>). Acesso em: 12 jul. 2025.

[9] FARDAPAPER. Internet of Things (IOT) Definition, Characteristics, Architecture, Enabling Technologies, Application, Future Challenges. 2019. Disponível em: (<https://fardapaper.ir/mohavaha/uploads/2019/09/Fardapaper-Internet-of-Things-IOT-Definition-Characteristics-Architecture-Enabling-Technologies-Application-Future-Challenges.pdf>). Acesso em: 12 jul. 2025.

[10] PRISMA STATEMENT. PRISMA 2020 statement. 2020. Disponível em: <https://www.prisma-statement.org/prisma-2020>. Acesso em: 15 jul. 2025.

[11] RESEARCHGATE. IoT Solutions for Energy Efficiency: A Bibliometric Analysis of Environmental Impact and Resource Management. 2024. Disponível em: (https://www.researchgate.net/publication/387960952_IoT_Solutions_for_Energy_Efficiency_A_Bibliometric_Analysis_of_Environmental_Impact_and_Resource_Management). Acesso em: 12 jul. 2025.

[12] IEEE SENSORS JOURNAL. Edge-Cloud Architectures for Hybrid Energy Management Systems: A Comprehensive Review. 2024. Disponível em: (https://www.researchgate.net/publication/379626101_Edge-Cloud_Architectures_for_Hybrid_Energy_Management_Systems_A_Comprehensive_Review). Acesso em: 12 jul. 2025.

[13] RESEARCHGATE. A Comprehensive Review of Sensor Technologies and Signal Processing Solutions for Low-Power IoT Systems with Mini Computing Devices. 2023. Disponível em: (https://www.researchgate.net/publication/385923535_A_Comprehensive_Review_of_Sensor_Technologies_and_Signal_Processing_Solutions_for_Low-Power_IoT_Systems_with_Mini_Computing_Devices). Acesso em: 12 jul. 2025.

[14] PMC. Due to failures brought on by corrosion, electrical disturbance, creep and plastic deformation, and hostile conditions, such sensors have a limited lifespan. *Sensors*, v. 22, n. 23, p. 9688474, 2022. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9688474/>. Acesso em: 12 jul. 2025.

[15] HASSAN, W. et al. Investigating the progression of insulation degradation in power cable based on partial discharge measurements. *Electric Power Systems Research*, v. 221, p. 109452, 2023.

[16] RESEARCHGATE. Edge-Cloud Architectures for Hybrid Energy Management Systems: A Comprehensive Review. 2024. Disponível em: (https://www.researchgate.net/publication/379626101_Edge-Cloud_Architectures_for_Hybrid_Energy_Management_Systems_A_Comprehensive_Review). Acesso em: 12 jul. 2025.

[17] ARXIV. It means integrating computers into everyday objects so seamlessly that they become a natural and unnoticed part of the environment, with people interacting with them effortlessly. 2025. Disponível em: <https://arxiv.org/abs/2503.13466>. Acesso em: 12 jul. 2025.

[18] RESEARCHGATE. Introduction to edge computing. 2020. Disponível em: (https://www.researchgate.net/profile/Yogesh-Sharma-32/publication/344218125_Introduction_to_edge_computing/links/6043c41c92851c077f210b97/Introduction-to-edge-computing.pdf). Acesso em: 12 jul. 2025.

[19] SMART-ENERGY.COM. How grid edge computing is revolutionising real-time power management. 2024. Disponível em: <https://www.smart-energy.com/industry-sectors/energy-grid-management/how-grid-edge-computing-is-revolutionising-real-time-power-management/>. Acesso

em: 12 jul. 2025.

[20] IARJSET. Cloud computing is a one of the most emerging technologies. International Advanced Research Journal in Science, Engineering and Technology, v. 9, n. 2, p. 11-16, 2022. Disponível em: (<https://iarjset.com/wp-content/uploads/2022/02/IARJSET.2022.9212.pdf>). Acesso em: 12 jul. 2025.

[21] RESEARCHGATE. AI-DRIVEN FAULT DETECTION AND PREDICTIVE MAINTENANCE IN ELECTRICAL POWER SYSTEMS: A SYSTEMATIC REVIEW OF DATA- DRIVEN] APPROACHES, DIGITAL TWINS, AND SELF-HEALING GRIDS. 2025. Disponível em: (https://www.researchgate.net/publication/390095870_AI-DRIVEN_FAULT_DETECTION_AND_PREDICTIVE_MAINTENANCE_IN_ELECTRICAL_POWER_SYSTEMS_A_SYSTEMATIC_REVIEW_OF_DATA-DRIVEN_APPROACHES_DIGITAL_TWINS_AND_SELF-HEALING_GRIDS). Acesso em: 12 jul. 2025.

[22]MDPI. Statistical parameters calculated from various discharge distributions can help to determine the type of discharge source and the development of its activities. Applied Sciences, v. 15, n. 10, p. 5455, 2025. Disponível em: <https://www.mdpi.com/2076-3417/15/10/5455>. Acesso em: 12 jul. 2025.

[23] PEERBITS. RFID and IoT in Asset Tracking. [s.d.]. Disponível em: <https://www.peerbits.com/blog/rfid-and-iot-in-asset-tracking.html>. Acesso em: 12 jul. 2025.

[24] AXIA INSTITUTE. The Axia Institute White paper - RFID Uses, Benefits, and Costs. 2022. Disponível em: (https://axia.msu.edu/wp-content/uploads/2022/05/The-Axia-Institute-White-paper-RFID-Uses_Benefits_and-Costs.pdf). Acesso em: 12 jul. 2025.

[25] RESEARCHGATE. RFID based 3D buried assets location system. 2008. Disponível em: (https://www.researchgate.net/publication/237525396_RFID_based_3D_buried_assets_location_system). Acesso em: 12 jul. 2025.

[26] KHOKHLOVA, V.; DELEVOYE, E. The Localization of Buried Objects in the Soil Using an RFID Tag: Protocol Description and Parameter Estimation With the Model of the Oscillating Magnetic Field in Media. IEEE Transactions on Magnetism, v. 55, n. 5, p. 1-16, 2019.

[27] DNV. Smart Cable Guard Technology. [s.d.]. Disponível em: <https://www.dnv.com/energy/services/smart-cable-guard/technology/>. Acesso em: 12 jul. 2025.

[28] ACTEON. Maximising Power Cable Reliability for Offshore Wind. 2023. Disponível em: <https://acteon.com/blog/maximising-power-cable-reliability-for-offshore-wind/>. Acesso em: 12 jul. 2025.

[29] MDPI. The increasing complexity and vulnerability of modern energy systems underscore the urgent need for intelligent, resilient, and sustainable infrastructure solutions. Energies, v. 17, n. 4, p. 3618, 2024. Disponível em: <https://www.mdpi.com/2071-1050/15/4/3618>. Acesso em: 12 jul. 2025.

[30] CUPIX. Digital Twins transform operational efficiency in oil and gas. 2023. Disponível em: <https://www.cupix.com/resources/digital-twins-transform-operational-efficiency-in-oil-and-gas>. Acesso em: 12 jul. 2025.

[31] FRONTIERS IN ENERGY RESEARCH. Integrating Renewable Energy with Internet of Things (IoT): Pathways to a Smart Green Planet. 2024. Disponível em: <https://www.frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2024.1397748/full>. Acesso em: 12 jul. 2025.

[32] SUSTAINABILITY DIRECTORY. Industry 4.0 Integration with Smart Grids. [s.d.]. Disponível em: <https://prism.sustainability-directory.com/scenario/industry-4-0-integration-with-smart-grids/>. Acesso em: 12 jul. 2025.

[33] INTERNATIONAL HYDROGRAPHIC REVIEW (IHR). Science Monitoring and Reliable Technology (SMART) to Monitor the Ocean Using Submarine Cables. 2024. Disponível em: <https://ihr.iho.int/articles/science-monitoring-and-reliable-technology-smart-to-monitor-the-ocean-using-submarine-cables/>. Acesso em: 12 jul. 2025.

[34] RESEARCHGATE. Application of Standard EPCGEN2 UHF RFID Tags as Soil Moisture Sensors. 2016. Disponível em: (https://www.researchgate.net/publication/310754032_Application_of_RFID_Technology_in_Life_Cycle_Management_of_Power_Grid_Assets). Acesso em: 12 jul. 2025.

[35] RESEARCHGATE. Insulation Degradation Mechanism and Diagnosis Methods of Offshore Wind Power Cables: An Overview. 2023. Disponível em: (https://www.researchgate.net/publication/366644751_Insulation_Degradation_Mechanism_and_Diagnosis_Methods_of_Offshore_Wind_Power_Cables_An_Overview). Acesso em: 12 jul. 2025.

[36] METER Group. Por que as instalações de cabos de energia subterrâneos precisam de medições de resistividade térmica do solo. In: Meter Group. Measurement Insights. [online]. Disponível em: . Acesso em: 18 jul. 2025.

[37] Multlab. Resistência de Isolamento de Cabos Elétricos Explicada. Portal do Teste e Ensaio de Isolação. [online]. Disponível em: . Acesso em: 18 jul. 2025.

[38] LONG-TERM PERFORMANCE OF SOIL AND BACKFILL SYSTEMS. Direct buried cables: air pockets and thermal resistance, etc. [online]. Disponível em: . Acesso em: 18 jul. 2025.

[39] RIEDER, E. S. et al. Investigação dos principais processos de corrosão em estações de energia elétrica do Estado do RS. Revista Matéria, v. 14, n. 3, p. 1013–1014, 2009. Disponível em: <https://www.scielo.br/j/rmat/a/QJfjVGdrZtw9JWLHJHLXgHz>. Acesso em: 18 jul. 2025.

[40] MESH Engenharia. Corrosão no sistema de aterramento. Disponível em: <https://meshengenharia.com/artigos/corrosao-em-aterramentos/>. Acesso em: 18 jul. 2025.

[41] REBELO, R.; FIALHO, L.; NOVAIS, M. H. Floating photovoltaic systems: photovoltaic cable submersion and impacts analysis. arXiv preprint, 2021. Disponível em: <https://arxiv.org/abs/2103.12083>. Acesso em: 18 jul. 2025.

[42] AMBIENTAL MERCANTIL. Como mudanças climáticas vão afetar cabos de aço em atividades offshore. Abril 2025. Disponível em: <https://www.ambientalmercantil.com/>. Acesso em: 18 jul. 2025.

[43] ESTADO DO RIO GRANDE DO SUL. RS tem maior número de projetos de parques eólicos offshore. 20 jan. 2025. Disponível em: <estado.rs.gov.br/noticias/rs-tem-maior-numero-de-projetos-de-parques-eolicos-offshore>. Acesso em: 30 jun. 2025.

[44] DESENVOLVIMENTO RS. Rio Grande do Sul lança novo Atlas Eólico. 04 jul. 2025. Disponível em: <desenvolvimentors.rs.gov.br/noticias/rio-grande-do-sul-lanca-novo-atlas-eolico>. Acesso em: 3 jul. 2025.

[45] Geografia do Rio Grande do Sul – planície litorânea, coxilhas, relevo dissecado. Wikipedia. Disponível em: https://pt.wikipedia.org/wiki/Geografia_do_Rio_Grande_do_Sul. Acesso em: 18 jul. 2025.

[46] Parque Nacional de Aparados da Serra – relevo acidentado, escarpas e vales na transição para a costa. Wikipedia. Disponível em: https://pt.wikipedia.org/wiki/Parque_Nacional_dos_Aparados_da_Serra. Acesso em: 18 jul. 2025.

[47] O papel da topografia na otimização de parques eólicos: eficiência energética e desafios topográficos. Revista FT. Disponível em: <https://revistaflorestal.com.br/topografia-parques-eolicos>. Acesso em: 18 jul. 2025.

[48] INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS

RENOVÁVEIS (Ibama). Ibama emite 1ª licença prévia para projeto eólico offshore no Brasil; projeto é do SENAI-RN. SENAI-RN, 23 jun. 2025. Disponível em: <<https://www.rn.senai.br/ibama-emite-1o-licenca-previa-para-projeto-eolico-offshore-no-brasil-projeto-e-senai-rn/>>. Acesso em: 18 jul. 2025. :

[49] SERVIÇO NACIONAL DE APRENDIZAGEM INDUSTRIAL DO RN (SENAI-RN). Evolução da planta-piloto do SENAI-RN para eólicas é apresentada no FWS South America Offshore Wind 2024. 20 set. 2024. Disponível em: <<https://www.rn.senai.br/evolucao-da-planta-piloto-senai-rn-para-eolicas-e-apresentada-no-fws-south-america-offshore-wind-2024/>>. Acesso em: 18 jul. 2025.

[50] TRIBUNA DO NORTE. Brasil avança na energia eólica offshore com 1º projeto licenciado no mar de Areia Branca (RN). 25 jun. 2025. Disponível em: <<https://cerne.org.br/brasil-avanca-na-energia-eolica-offshore-com-1o-projeto-licenciado-no-mar-de-areia-branca-rn/>>. Acesso em: 18 jul. 2025.

[51] FIERN/SENAI-RN. Em reunião do Conselho, SENAI-RN destaca conquista da 1ª licença do Brasil para projeto eólico offshore. 26 jun. 2025. Disponível em: <<https://www.fiern.org.br/em-reuniao-conselho-senai-rn-destaca-conquista-da-1a-licenca-brasil-para-projeto-eolico-offshore/>>. Acesso em: 18 jul. 2025.

[52] PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO (PUC-Rio). Laboratório de Sensores a Fibra Óptica – LSFO. Departamento de Engenharia Mecânica, 2022. Disponível em: <https://mec.puc-rio.br/2022/03/24/laboratorio-de-sensores-a-fibra-optica/>. Acesso em: 18 jul. 2025.

[53] PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO (PUC-Rio). CTC PUC-Rio – Laboratório de Sensores (LSFO). Centro Técnico Científico, [s.d.]. Disponível em: <https://www.ctc.puc-rio.br/laboratorios-mecanica>. Acesso em: 18 jul. 2025.

Envelhecimento e perda de performance de turbinas eólicas: proposta de modelo relacional

Lucas Leonardo Lopes Silva¹, Mario Orestes Aguirre González², Luana Pereira Nogueira³, Artur Oliveira Santos⁴, Lucas Thiago Gomes Soares de Araújo⁵

1,2,3,4,5 Creation – Grupo de pesquisa em Inovação de Produtos e Processos para Energias Renováveis e Power-to-X/UFRN; 4 Programa de Pós-graduação em Engenharia Mecânica/UFRN; 5 Programa de Pós-graduação em Engenharia de Produção/UFRN

lucassilvaufn2025@gmail.com¹, mario.gonzalez@ufrn.br², luanapereiranog@gmail.com³, arturooliver.eng@gmail.com⁴, lucasago28@gmail.com⁵

RESUMO

A renovação da matriz energética mundial é cada vez mais evidente com maior participação de fontes renováveis. Dentre elas, a energia eólica tem aumentado sua capacidade instalada global assim como ocorreu na tecnologia dos aerogeradores. Com o uso de novas tecnologias as turbinas eólicas melhoram sua eficiência e prolongam sua vida útil, entretanto, como toda máquina, elas estão sujeitas aos efeitos do tempo, à medida que o tempo passa, a atenção aumenta e os custos para manter operando também. O objetivo do estudo é propor um modelo relacional, que envolva os fatores ligados a perda de desempenho de aerogeradores no decorrer da sua vida útil. A pesquisa foi realizada em 4 etapas: a pesquisa teórica, desenvolvida nas etapas 1 e 2, construída por meio de uma revisão bibliográfica exploratória (1) e uma revisão bibliográfica sistemática (2), a construção de um modelo relacional, desenvolvido na etapa 3 e por fim, a sua validação, que contempla a etapa 4 do estudo. Com isso, o processo de validação mostrou que as hipóteses desenvolvidas para construção do modelo possuem coerência com a realidade das turbinas eólicas, reforçando os efeitos negativos do envelhecimento e destacando o impacto dos fatores climáticos e regionais no agravamento do envelhecimento e da perda de performance das turbinas.

Palavras-chaves:

Energia eólica; Turbina eólica; Modelo relacional; Envelhecimento.

ABSTRACT

The world energetic matrix renovation is clearer with more participation of renewable sources. Among them, the wind energy has constantly grown, expanding and upgrading their aerogenerators. With the use of new technologies, wind turbines upgrade their efficiency and extend their lifetime, however, like any machine, they are affected by the time effect, as time passes, more attention is required, and the operation costs too. The objective of this study is to propose a relational model that encompasses the factors associated with wind turbine performance loss over their lifetime. The research was conducted in four stages: the theoretical foundation, developed in stages 1 and 2, constructed through an exploratory literature review (1) and a systematic literature review (2); the construction of a relational model, developed in stage 3; and finally, its validation, which encompasses stage 4. Thus, the validation process demonstrated that the hypotheses developed to construct the model are consistent with the reality of wind turbines, reinforcing the negative effects of aging and highlighting the impact of climatic and regional factors on aging and turbine performance loss.


Keywords:

Wind energy; Wind turbine; Relational model; Aging.

1. INTRODUÇÃO

Nos últimos anos a indústria de energia eólica vem demonstrando um constante crescimento, 2024 foi considerado o melhor ano dos últimos 5, adicionando 117 GW de capacidade de geração a rede mundial, totalizando um balanço de 1.136 GW, um acréscimo de 11% comparado com 2023, assim explica o Gráfico 1 apresentado no Global Wind Report 2025 (GWEC, 2025).

Gráfico 1 - Novas instalações eólicas por ano em capacidade de geração



Todo esse crescimento pode ser justificado pela necessidade da diminuição do consumo de combustíveis fósseis, que além de serem finitos, acarretam diversos problemas, dentre os principais, poluição e efeito estufa. Entretanto, manter esse crescimento não é uma tarefa simples, os parques eólicos enfrentam diversos desafios que podem influenciar no seu desempenho, seja o técnico (capacidade das turbinas eólicas, disponibilidade, confiabilidade, manutenção e suporte) ou de sustentabilidade (relacionado aos impactos ambientais, sociais e econômicos) (MUSTAFA, 2021).

Responsáveis por transformar a energia cinética dos ventos em eletricidade, as turbinas eólicas sofrem com o problema do envelhecimento dos seus componentes, assim como mostram Staffell e Green (2014), que associam essa aceleração do envelhecimento a fatores climáticos, desgaste de componentes e efeito esteira das máquinas no parque eólico.

Dessa forma, apesar do envelhecimento já ser abordado por alguns estudiosos como Staffell e Green (2014), Hamilton *et al.*; (2020) e Astolfi, Byrne e Castellani (2020), ainda há uma lacuna na literatura em relação a análise de fatores agregados a esse fenômeno e na quantificação em termos numéricos assim como problemas dos componentes, fenômenos climáticos e outros.

Portanto, o presente estudo trabalhou com a ideia de esclarecer a seguinte problemática: **Como os fatores que causam a perda de desempenho durante o envelhecimento de turbinas eólicas se relacionam?** Para explorar e explicar essa problemática, foi realizada uma revisão Bibliográfica Sistemática da Literatura (RBS), com o intuito de mapear esses fatores, em seguida foi desenvolvido um modelo relacional e por fim, foi validado a partir da perspectiva da indústria.

A estrutura do artigo está dividida em 6 seções, iniciando pela introdução, que aborda uma breve


contextualização sobre o tema e a apresentação do objetivo do estudo, seguido da fundamentação teórica, onde são tratados os principais pontos que embasam o tema. Na terceira seção é detalhado a metodologia da pesquisa, bem como seus procedimentos. Em seguida, os resultados são discutidos, mostrando as contribuições dessa pesquisa para com o tema estudado. Na quinta seção foram alocados as principais considerações e conclusões. Por fim, na última seção, as referências usadas para construção do artigo.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 ENERGIA EÓLICA E MANUTENÇÃO DE PARQUE EÓLICOS

Advinda das massas de ar em movimento que circundam o planeta terra como visto na Figura 1, a energia eólica também conhecida como energia cinética dos ventos, pode ser captada por aerogeradores e convertida em energia elétrica, a eletricidade por sua vez, é uma das principais fontes de energia do mundo, sem ela a humanidade não teria evoluído e se estabelecido nos patamares tecnológicos e econômicos atuais (Gasch; Twele, 2012).

Figura 1 - Fluxo de ar na terra



Fonte: Silva (2016)

Considerada como uma energia limpa, a energia eólica vem se mostrando como uma ótima alternativa para suprir a demanda de energia global e combater a emissão de poluentes, entretanto, a demanda pelo desenvolvimento de pesquisas e utilização de novas tecnologias limpas visando compreender as melhores práticas para realização do abastecimento de maneira sustentável da crescente demanda mundial por energia, é um desafio a ser considerado (Gomes, 2018).

Manter esse crescimento constante não é simples, pois é necessário que os gestores dos parques eólicos estejam preparados para lidar com os mais diversos problemas de desempenho que podem vir a ocorrer com os aerogeradores, essas máquinas responsáveis pela transformação de energia, funcionam em grandes grupos, alocados em empreendimentos denominados de parques eólicos, esse podem funcionar tanto na terra (*onshore*), quanto no mar (*offshore*) (Beurskens, 2014).

Diversos são os fatores que podem influenciar no desempenho de um aerogerador, eles podem variar desde condições dos componentes internos da máquina, a fatores externos relacionados ao clima,

inclusive tendo forte relação com o gerenciamento da manutenção, tanto que, esse último ponto tem um grande impacto no desempenho de um parque eólico, visto que, quando estratégias de Operação e Manutenção (O&M) são bem implementadas, custos tendem a sofrer redução, entretanto antes de implementar uma estratégia é necessário conhecer e monitorar o estado real das turbinas Pfaffel, Faulstich e Rohrig (2017).

Dessa maneira, o desempenho é um dos indicadores chave para avaliar aerogeradores, podendo ser mensurado através de vários fatores e indicadores, como: aspectos da manutenção, produção de energia anual e capacidade de tomada de decisão em situações adversas Gonzalez *et al.* (2017).

2.2 ENVELHECIMENTO E PERDA DE PERFORMANCE DE TURBINAS EÓLICAS

A medição de performance de um aerogerador está atrelada a diversos fatores e pode ser feita a partir de várias perspectivas, do ponto de vista econômico é possível medir o quanto uma turbina eólica está gerando custos ou quanto está o valor do kilowatt de energia produzido por ela. Da parte da manutenção, é possível mensurar o tempo de máquina trabalhada ou o tempo médio entre falhas, tanto para a máquina como um todo, como para seus componentes. Por fim, do escopo ambiental, é possível medir o quanto aquela máquina está economizando na emissão de CO₂ na atmosfera ou o quanto o clima da região está afetando seu funcionamento (Byrne *et al.*, 2020; Rezamand *et al.*, 2020; Guo *et al.*, 2021).

A partir disso, é possível notar que a perda de performance de um aerogerador não está ligada diretamente a falhas, muitas vezes os componentes estão trabalhando sobre condições que permitem o seu funcionamento, porém, não estão entregando aquilo que deveriam, assim, os sistemas de monitoramento das máquinas devem ser capazes de prever de forma eficiente: alterações climáticas, funcionamento dos componentes, alterações de comportamentos e demais anomalias mecânicas, elétricas e hidráulicas (Jin, Xu, Qiao, 2021; Kokila, Isakki, 2016).

Além de fatores que possuem características fisicamente mapeáveis, existem outros fatores que trabalham como intensificadores de certos fenômenos, dentre eles merece destaque o envelhecimento. Como um dos trabalhos precursores desse estudo, Staffell e Green (2014), mapearam o envelhecimento como subproduto de outras ocorrências, ou seja, exemplos como: a negligência acerca das condições ambientais do local de instalação (fauna, flora e formação geológica) e a subperformance da manutenção (rotinas de manutenção, erros de medição e calibrações equivocadas) explicam como um fator pode ter relação com outro.

Dessa forma, outros estudos identificaram que o envelhecimento pode atuar diretamente como fator responsável pela perda de performance de um aerogerador. Hamilton *et al.* (2020) chegou à conclusão, depois de analisar 917 parques eólicos *onshore* dos EUA, que nos anos iniciais de funcionamento o fator de capacidade, que pode ser entendido como a taxa entre a energia produzida em um intervalo de tempo e a energia máxima que poderia ser produzida nesse mesmo período, sofria perdas de 0,17 ao ano, porém entre os anos 10 e 11, houve um aumento maior, cerca de 1,5 ao ano.

Em outra análise, Nuin *et al.* (2020) observaram que ao comparar o efeito de envelhecimento sobre as pás dos aerogeradores, os materiais desgastados causavam um aumento de deflexão da

estrutura, alterando assim as capacidades aerodinâmicas das pás e auxiliando na identificação de falhas de fabricação ou danos produzidos por fontes externas.

3. MÉTODO DO ESTUDO


Para o desenvolvimento deste estudo foi escolhido o método de pesquisa conhecido como Revisão Bibliográfica Sistemática (RBS), pois ele proporciona a produção de conhecimento sobre o tema estudado, identificando padrões, problemas e temas relevantes, além de auxiliar no mapeamento do estado da arte, permitindo replicabilidade e transparência na interpretação do estudo (Araújo, Alencar e Mota, 2017).

Essa pesquisa pode ser classificada de natureza aplicada, no tema de Operação e Manutenção (O&M) de parques eólicos, tendo como objeto de estudo a perda de desempenho dos aerogeradores com o passar do tempo, sobre seu objetivo ela se enquadra como descritiva, pois visa aprimorar o conhecimento científico sobre o tema (Diógenes *et al.*, 2020). Por fim, ela é classificada com a abordagem qualitativa-quantitativa, pois trata com a coleta de dados das duas abordagens (Gil, 2022).

O procedimento de pesquisa, além da RBS, teve também aplicação de uma pesquisa *survey*, que utilizou como ferramenta de pesquisa dois questionários, assim, a validação ocorreu em duas etapas, onde a primeira foi com a aplicação de um questionário qualitativo com 26 perguntas diretas e abertas, em uma entrevista semiestruturada. A segunda etapa foi desenvolvida através da aplicação de um questionário quantitativo, com 54 questões objetivas e dividido em 2 blocos, o primeiro refere-se a cada dimensão e seus fatores e o segundo bloco refere-se a uma análise geral sobre cada dimensão em si, esse questionário tem como objetivo quantificar o impacto dos fatores e das dimensões do *framework*.

Dessa forma, a pesquisa foi desenvolvida em 4 etapas sequenciais: etapa 1 - revisão bibliográfica exploratória, etapa 2 - Revisão Bibliográfica Sistemática, etapa 3 - construção do modelo relacional e etapa 4 - validação do modelo relacional, tal procedimento, foi resumido na Figura 2.

Figura 2 - Procedimento da pesquisa



Fonte: Autoria Própria (2025)

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1. MODELO RELACIONAL

Por meio da RBS foram identificados 47 fatores que com o tema e objeto de estudo dessa pesquisa, a análise desses fatores abrangeu diversas áreas e setores de um parque eólico, merecendo destaque o monitoramento e a manutenção, pois tiveram o maior número de fatores mapeados. Nesse processo de identificação dos fatores as metodologias: estudos de casos e simulações computacionais foram as mais usadas pelos trabalhos revisados.

Para uma melhor organização das informações coletadas, os fatores foram sistematizados em dimensões de acordo com características em comuns abordadas pelos autores. Um modelo relacional foi desenvolvido para identificar e estabelecer as hipóteses do estudo, de tal forma que fosse possível a compreensão dos impactos dos principais fatores encontrados e como é a relação entre as dimensões. Cinco dimensões foram modeladas, sendo elas: Eventos Climáticos, Geografia do local de instalação, Efetividade dos sistemas de previsão e monitoramento, Performance da Manutenção e Envelhecimento.

Inicialmente a dimensão de Envelhecimento, procede todas as outras, pois ela é vista como crucial para perda de performance das turbinas eólicas, além de que, todas as outras podem intensificar seu comportamento, de forma direta ou indireta. Antecedendo o Envelhecimento estão as dimensões: Efetividade dos sistemas de previsão e monitoramento e Performance da manutenção, que de acordo com a revisão dos estudos, possuem fatores que agravam diretamente o Envelhecimento.

Por fim, a Geografia do local de instalação antecede a Efetividade dos sistemas de previsão e monitoramento e como dimensão primária, têm-se os Eventos climáticos, responsáveis pelo comportamento da matéria prima para o funcionamento dos aerogeradores, o vento, sendo assim, toda e qualquer alteração acaba influenciando diretamente a performance da máquina como um todo.

4.2. PROCESSO DE VALIDAÇÃO DO MODELO

O processo de validação foi elaborado em 2 etapas, onde nelas são avaliados: o agrupamento dos fatores nas 5 grandes dimensões, o impacto dos 47 fatores identificados na RBS dentro de cada dimensão e o impacto de cada dimensão na perda de performance dos aerogeradores. A validação foi realizada com a colaboração de um gerente de um complexo eólico que opera na região Nordeste do Brasil, considerado para essa pesquisa como um especialista na área de O&M de parques eólicos, por possuir 12 anos de experiência na área.

A primeira etapa da validação ocorreu por meio de uma entrevista roteirizada semiestruturada, onde foi realizada uma breve apresentação dos fatores identificados na RBS e das relações entre as dimensões do modelo relacional. O entrevistado respondeu um questionário qualitativo, composto por 26 perguntas diretas, em um misto de abertas e fechadas. Esse primeiro processo levou cerca de 2h30 para ser concluído.

A segunda etapa da validação foi desenvolvida a partir da aplicação de um questionário quantitativo, composto por 53 proposições objetivas, divididas em 2 blocos. O primeiro bloco com 47 proposições, teve como objetivo quantificar o impacto de cada fator identificado em relação à dimensão ao qual pertencia, já o segundo bloco, com 6 proposições avaliou o impacto de cada dimensão em relação a perda de performance geral do aerogerador.

Para julgar as proposições apresentadas no questionário foi utilizada uma escala Likert de cinco pontos, onde cada ponto possuía 2 níveis de intensidade, totalizando então em 10 possibilidades para julgamento. Dessa forma, as opções disponíveis para avaliação de acordo com a escala utilizada foram: Nada importante (1 e 2), pouco importante (3 e 4), importante (5 e 6), muito importante (7 e 8) e extremamente importante (9 e 10), para o primeiro bloco de proposições.

No segundo bloco, a terminologia da escala precisou ser modificada para se adequar a nomenclatura dos itens avaliativos, de tal forma que o termo “importante” foi substituído por “relevância” ou “interferência”, dependendo da proposição analisada. Apesar da necessidade da modificação na nomenclatura dos termos o grau ou peso não foi invertido ou alterado, sendo assim, os valores de 1 a 4 representaram baixa importância, relevância ou interferência, os valores de 5 a 6 representaram uma neutralidade e por fim, os valores de 7 a 10 indicaram um alto peso aos itens avaliados. Esse segundo processo teve um tempo médio de execução de 12 minutos.

4.3. DISCUSSÃO DOS RESULTADOS

A perda de performance das turbinas eólicas à medida que envelhecem está atribuída a diversos fatores, cada fator impacta de uma forma diferente sobre a performance da máquina. Quando um conjunto de fatores com similaridades no seu perfil de atuação são agrupados, pode-se chamar esse grupo de dimensão.

Após validação, foi avaliado que os eventos climáticos são influenciados pela geografia do local de instalação, visto que são nos fatores da geografia (clima, fauna, flora e topografia) do local de instalação que estão alocadas as características referentes à localização e meio ambiente, pontos esses, que influenciam diretamente no comportamento do clima naquela região.

A avaliação condiz com o conteúdo mapeado na literatura, pois segundo Mercer e Dyer (2014), terrenos elevados e grandes concentrações de massas de calor podem gerar rajadas de ventos, que junto com o congelamento, analisado por Dierer, Oechslein e Cattin (2011), podem causar perdas na produção e fadiga nos componentes da turbina devido a cargas adicionais e problemas de calibração em componentes de orientação da nacelle, comprometendo assim a produtividade das turbinas.

Além disso, Dar e Von Bremen (2019), enfatizam a necessidade do uso de técnicas de previsão dos dados do vento para prever futuros efeitos esteiras, pois, no momento que a velocidade e direção do vento conseguem ser previstas, o impacto pelo efeito esteira na produção consegue ser amortizado. Por fim, a dimensão “Eventos climáticos” foi avaliada como a mais impactante na perda de performance das máquinas, contribuindo de forma assídua com o seu envelhecimento.

As dimensões que possuem relação direta com o clima foram consideradas como as mais contribuintes para o envelhecimento e consequentemente o declínio da performance das máquinas, elas também foram posicionadas no início do framework por influenciarem todas as outras dimensões, algumas de forma direta e outras indiretamente.

No entanto, as dimensões Efetividade dos sistemas de previsão e monitoramento e Performance da manutenção, receberam na validação as menores notas de impacto na contribuição da perda de performance pelo envelhecimento, visto que os fatores mapeados na literatura não possuíam um peso significativo em comparação com os fatores das duas dimensões anteriores.

Entretanto, a partir da avaliação qualitativa observou-se que existe uma necessidade do uso

dessas ferramentas tanto para monitorar a perda de desempenho da máquina quanto para prever as condições climáticas atuais e futuras, visto que esses sistemas podem prever o comportamento do vento e com essa informação é possível tomar decisões acerca de atividades de manutenção, da eficiência energética e sobre clima. Logo, essa avaliação condiz com as informações extraídas da literatura.

Segundo Sim e Jung (2020), os sistemas de monitoramento de dados climáticos atuam veemente no fornecimento de dados para outros setores do parque eólico, previsões exatas curto alcance beneficiam tarefas de configuração e manutenção das turbinas, enquanto previsões de longo alcance favorecem mais o planejamento e agendamento tanto da configuração quanto da manutenção dos aerogeradores.


Dessa forma, manter a integridade e segurança dos dados bem como os sistemas otimizados se torna um ótimo benefício para a performance dos aerogeradores pois de acordo com Wu e Hong (2007), conseguir prever a variabilidade e incerteza dos ventos provê reduções em custos operacionais das turbinas.

Os custos relacionados com as rotinas de manutenção dos aerogeradores são um dos grandes problemas enfrentados pelos gestores dos parques eólicos, a fim de amenizá-los, são utilizadas estratégias de prevenção de possíveis falhas. A capacidade de monitorar a condição de diversos componentes das turbinas eólicas é algo bem trivial e comum nas turbinas atuais, pois boa parte dos aerogeradores já saem de fábrica com a ferramenta SCADA presente no seu sistema, com ela é possível reunir grandes quantidades de dados sobre temperatura, diagnóstico de falhas e até mesmo o estado global sobre a saúde da turbina por meio de sensores (BUTLE; RINGWOOD; O'CONNOR, 2013; TAUTZ-WEINERT; WATSON, 2016).

Além disso, componentes com idade avançada tendem a não render tanto quanto os novos, diminuindo a eficiência da máquina. Ademais, apesar de ainda não ser mensurado quantitativamente, o fator envelhecimento é considerado como importante nas rotinas de manutenção.

Por fim, após o processo de validação, o modelo conceitual foi alterado e ficou definido como apresentado na Figura 3.

Figura 3 - Modelo relacional dos fatores que influenciam o envelhecimento e perda de performance de turbinas eólicas



Fonte: Autoria própria (2025)

5. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

A partir das respostas obtidas no processo de validação do modelo relacional é possível concluir

que, nem todos os fatores identificados são comuns a todos os parques eólicos, pois variáveis como: região onde o parque está instalado; dimensões das máquinas; nível tecnológico utilizado na operação do parque e por fim, estratégias utilizadas para o controle do envelhecimento, afetam diretamente o impacto e inclusive na existência de cada fator em relação a perda de performance.

Ou seja, dependendo das características e decisões tomadas pelo gerenciamento do parque eólico, certos fatores podem ou não exercer influência sobre o fenômeno da perda de performance sobre o envelhecimento.

Apesar das dimensões Efetividade dos sistemas de previsão e monitoramento e Performance da manutenção terem recebido avaliações quantitativas de impacto mediano e/ou baixo, na avaliação qualitativa foi esclarecido que essas dimensões possuem grande importância para identificação de falhas e anomalias na performance.

De forma contrária ao cenário anteriormente explicado, as dimensões Efeitos climáticos e Geografia do local de instalação, foram avaliadas de forma impactante tanto na perspectiva quantitativa, onde seus fatores e as dimensões em si receberam avaliações de alto impacto/interferência na performance do aerogerador, quanto na qualitativa, onde foi esclarecido que ambas podem ser consideradas como intensificadoras da perda de performance pelo envelhecimento.

A síntese da validação sobre a dimensão Envelhecimento, mostra que este pode ser considerado como um fator crucial na perda de desempenho dos aerogeradores, visto que todas as outras dimensões já analisadas podem agravar seus efeitos. Quanto mais velho o aerogerador for, maior a chance de ocorrência de falhas inesperadas, necessitando assim um maior número de intervenções da manutenção.

Com isso, é possível concluir que o presente trabalho conseguiu responder a problemática proposta durante sua fase de maturação de ideias, **como os fatores que causam a perda de desempenho durante o envelhecimento de turbinas eólicas se relacionam?** Apresentando não só um modelo relacional, como também dimensões que englobam diversos fatores pertinentes ao funcionamento de um aerogerador, além disso o modelo foi validado, o que possibilitou uma comparação da realidade com os dados obtidos na literatura.

Por fim, como limitações do estudo, fica a percepção que o problema de envelhecimento não recebe o foco que deveria, pois mesmo que ele não possa ser evitado, ele pode ser controlado e entender os principais fatores que afetam esse fenômeno, foi uma hipótese considerada como fundamental para o entendimento do problema.

Os estudos mapeados, pouco quantificavam a performance perdida devido a esse problema e quando o faziam era de forma a componentes específicos, ou seja, não existia uma interconexão entre os fatores, muito menos uma divisão em dimensões que envolvessem esses fatores. Além disso, foi perceptível a dificuldade de conexão entre a academia e a indústria, processo esse que é de vital importância para comparação de estudos, dados e construção de novas informações.

REFERÊNCIAS

ARAÚJO, M. C. B; ALENCAR, L. H; MOTA, C, M, M. Project procurement management: A structured literature review. **International Journal of Project Management**, v. 35, p. 353 – 377. 28 jan. 2017. <http://dx.doi.org/10.1016/j.ijproman.2017.01.008>.

BEURSKENS, J. **Understanding Wind Power technology theory, deployment and optimization**. Wiley, 2014, p. 1-43.

BUTLE, S. RINGWOOD, J. O'CONNOR, F. Exploiting SCADA System Data for Wind Turbine Performance Monitoring. In: **Conference on Control and Fault-Tolerant Systems**. France. 9 oct. 2013. <http://dx.doi.org/978-1-4799-2855-2/13/>.

BYRNE, R.; ASTOLFI, D.; CASTELLANI, F.; HEWITT, N, J. A Study of Wind Turbine Performance Decline with Age through Operation Data Analysis. **Energies**, [S.L.], v. 13, n. 8, p. 2086, 21 abr. 2020. MDPI AG. <http://dx.doi.org/10.3390/en13082086>.

DAR, A. S; VON BREMEN, L. Short-Term Forecasting of Wake-Induced Fluctuations in Offshore Wind Farms. **Energies**, v. 12, n. 14, p. 2833, 23 jul. 2019. DOI 10.3390/en12142833. Disponível em: <https://www.mdpi.com/1996-1073/12/14/2833>.

DIERER, S.; OECHSLIN, R.; CATTIN, R. Wind turbines in icing conditions: performance and prediction. **Advances In Science and Research**, [S.L.], v. 6, n. 1, p. 245-250, 6 set. 2011. Copernicus GmbH. <http://dx.doi.org/10.5194/asr-6-245-2011>.

DIÓGENES, J. R. F.; CLARO, J.; RODRIGUES, J. C.; LOUREIRO, M. V. Barriers to onshore wind energy implementation: a systematic review. **Energy Research & Social Science**, [S.L.], v. 60, p. 1-2, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.erss.2019.101337>

GASCH, R.; TWELE, J. **Wind Power Plants: Fundamentals, Design, Construction and Operation**. 2. ed. Berlin: Springer, 2012.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2022.

GLOBAL WIND ENERGY COUNCIL (GWEC) (org.). **Global Wind Report 2025**. Disponível em: GWEC Global Wind Report 2025.pdf. Acesso em: 10 Jul. 2025.

GOMES, M. S. S. **Proposta de uma metodologia para utilização de energia eólica offshore no litoral sudeste do Brasil**. Dissertação. Universidade Federal de São Carlos. Sorocaba, 2018.

GONZALEZ, E; NANOS, E, M; SEYR, H; VALLDECABRES, L; YÜRÜSEN, N, Y; SMOLKA, U; MUSKULUS, M; MELERO, J, J. Key Performance Indicators for Wind Farm Operation and Maintenance. **Energy Procedia**, [S.L.], v. 137, p. 559-570, out. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.egypro.2017.10.385>.

GUO, N.; ZHANG, M.; LI, B.; CHENG, Y. Influence of atmospheric stability on wind farm layout optimization based on an improved Gaussian wake model. **Journal Of Wind Engineering and Industrial Aerodynamics**, [S.L.], v. 211, p. 104548, abr. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.jweia.2021.104548>.

HAMILTON, S. D.; MILLSTEIN, D.; BOLINGER, M.; WISER, R.; JEONG, S. **How Does Wind Project Performance Change with Age in the United States?** Joule, [S.L.], v. 4, n. 5, p. 1004-1020, Maio 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.joule.2020.04.005>

JIN. X., XU. Z., QIAO W. Condition Monitoring of Wind Turbine Generators Using SCADA Data Analysis. In: **IEEE Transactions on Sustainable Energy**, vol. 12, no. 1, pp. 202-210, Jan. 2021, doi: 10.1109/TSTE.2020.2989220.

KOKILA, M.; ISAKKI, P. A survey of wind turbine control monitoring and fault detection on wind energy. In: 2016 **International Conference on Computing Technologies and Intelligent Data Engineering** (Icctide'16), [S.L.], jan. 2016. IEEE. <http://dx.doi.org/10.1109/icctide.2016.7725341>.

MERCER, A.; DYER, J. A New Scheme for Daily Peak Wind Gust Prediction Using Machine Learning. **Procedia Computer Science**, Philadelphia, v. 36, p. 593-598, 2014.

MUSTAFA, A. M.; BARABADI, A.; MARKESSET, T.; NASERI, M. An overall performance index for wind farms: a case study in Norway Arctic region. **International Journal of System Assurance Engineering and Management**, v. 12, n. 5, p. 938–950, out. 2021. DOI 10.1007/s13198-021-01165-0

NUIN, I.; FARIÑAS, A. B.; RIO, M.; MURILLO, I.; LANDABURU, I.; SAENZ, E. Study of ageing of laminates and its effects on wind turbine blade deflection. **Wind Energy**, [S.L.], v. 23, n. 4, p. 939-952, abr. 2020. Wiley. <http://dx.doi.org/10.1002/we.2465>.

PFAFFEL, S.; FAULSTICH, S.; ROHRIG, K. Performance and Reliability of Wind Turbines: a review. **Energies**, [S.L.], v. 10, n. 11, p. 1904, 19 nov. 2017. MDPI AG. <http://dx.doi.org/10.3390/en10111904>.

REZAMAND. M, KORDESTANI .M, CARRIVEAU. R, TING D. S. -K., ORCHARD M. E.; SAIF M. Critical Wind Turbine Components Prognostics: A Comprehensive Review. In: **IEEE Transactions on Instrumentation and Measurement**, vol. 69, no. 12, pp. 9306-9328, Dec. 2020, doi: 10.1109/TIM.2020.3030165.

SILVA, L. L. L. **Análise comparativa entre o uso das energias eólicas e solar (fotovoltaica) para geração de energia elétrica de pequeno porte residencial**. 50f. Monografia (Graduação) – Curso de Ciências e Tecnologias, Universidade Federal Rural do Semi Árido, Rio Grande do Norte, 2016.

SIM, M. K., JUNG, J. Y. 2020. A short review on predictions for wind power generation – its limitation and future directions. **ICIC Express Letters, Part B: Applications**, 11(10), 995-1000. <https://doi.org/10.24507/icicelb.11.10.995>

STAFFELL, I.; GREEN, R. How does wind farm performance decline with age? **Renewable Energy**, [S.L.], v. 66, p. 775-786, jun. 2014. Elsevier BV.

TAUTZ-WEINERT, J.; WATSON, S. J. Using SCADA data for wind turbine condition monitoring – a review. **IET Renewable Power Generation**, [S.L.], v. 11, n. 4, p. 382-394, dez. 2016. Institution of Engineering and Technology (IET). <http://dx.doi.org/10.1049/iet-rpg.2016.0248>.

WU, Y; HONG, J. A literature review of wind forecasting technology in the world. 2007 **IEEE Lausanne Power Tech**, 2007, pp. 504-509, doi: 10.1109/PCT.2007.4538368.

APRENDIZADO DE MÁQUINA PARA IDENTIFICAÇÃO DO ÍNDICE DE SAÚDE NO SISTEMA DE REFRIGERAÇÃO DE AEROGERADORES

Draylon Vieira Lopes¹, Lucas Gonçalves Brach², Rafael Stubs Parpinelli³, Emerson Cassiano da Silva⁴, Peterson Gonçalves Alano⁵

Universidade do Estado de Santa Catarina – Centro de Ciências Tecnológicas e WEG.

draylon.vl@edu.udesc.br, lucas.gb@edu.udesc.br, rafael.parpinelli@udesc.br, emersona@weg.net,
peterson1@weg.net

RESUMO

A crescente demanda por eficiência na geração de energia eólica impõe desafios significativos aos custos de Operação e Manutenção (O&M), onde falhas não planejadas, especialmente no sistema de refrigeração de aerogeradores, geram perdas financeiras substanciais. Este artigo apresenta um framework híbrido de inteligência artificial para a predição da Vida Útil Remanescente (RUL) deste sistema crítico. Utilizando dados de SCADA, a metodologia emprega um modelo de imputação baseado em auto-atenção (SAITS) para tratamento de dados faltantes, seguido por um LSTM-Autoencoder para construir um Índice de Saúde (Health Index - HI) a partir do erro de reconstrução do modelo. Subsequentemente, um algoritmo k-Nearest Neighbors (kNN) compara a trajetória do HI atual com um histórico de curvas de degradação para estimar o RUL por similaridade. Os resultados, validados com dados operacionais, demonstram a capacidade do framework em detectar padrões de degradação incipientes com antecedência significativa, fornecendo estimativas de RUL acionáveis para as equipes de O&M. A abordagem proposta constitui uma ferramenta robusta para a transição de uma manutenção reativa para uma estratégia preditiva, oferecendo um potencial expressivo para a redução de custos e o aumento da disponibilidade de ativos no setor eólico brasileiro.

Palavras-chaves:

Manutenção Preditiva; Vida Útil Remanescente; Aerogeradores; Dados SCADA; Inteligência Artificial Híbrida; LSTM-Autoencoder.

ABSTRACT

The increasing demand for efficiency in wind power generation poses significant challenges to Operation & Maintenance (O&M) costs, where unplanned failures, particularly in the generator cooling system, lead to substantial financial losses. This paper introduces a hybrid artificial intelligence framework for predicting the Remaining Useful Life (RUL) of this critical system. Using SCADA data, the methodology employs a self-attention-based imputation model (SAITS) to handle missing data, followed by an LSTM-Autoencoder to construct a Health Index (HI) from the model's reconstruction error. Subsequently, a k-Nearest Neighbors

(kNN) algorithm estimates RUL by comparing the current HI trajectory to a library of historical degradation curves based on similarity. The results, validated with operational data, demonstrate the framework's ability to detect incipient degradation patterns with significant advance notice, providing actionable RUL estimates for O&M teams. The proposed approach provides a robust tool for transitioning from a reactive to a predictive maintenance strategy, offering significant potential for cost reduction and increased asset availability in the Brazilian wind sector.

Keywords:

Predictive Maintenance; Remaining Useful Life; Wind Turbine; SCADA Data; Hybrid Artificial Intelligence; LSTM-Autoencoder

1. INTRODUÇÃO

A energia eólica consolidou-se como um pilar da transição energética no Brasil, possuindo participação fundamental na matriz de oferta interna de energia elétrica e desempenhando um papel crucial na busca por um futuro mais sustentável (EPE, 2025). Com a contínua expansão da capacidade instalada, a otimização da performance e a garantia da disponibilidade dos ativos tornam-se imperativas para a competitividade do setor. Neste cenário, a viabilidade econômica dos parques eólicos é diretamente impactada pelos custos de Operação e Manutenção (O&M), que, segundo análises recentes, podem compor uma parcela significativa do Custo Nivelado de Energia (LCOE), aproximando-se de 30% para projetos *onshore* (WYSZOMIERSKI et al., 2025).

Dentre os múltiplos subsistemas de um aerogerador, o sistema de refrigeração do gerador é de criticidade ímpar. Embora as falhas no gerador não sejam as mais frequentes em comparação com outros componentes, seu impacto é desproporcionalmente severo. Análises financeiras recentes demonstram que as falhas no gerador são responsáveis por cerca de 21% dos custos totais de falhas ao longo da vida útil da turbina (CARROLL et al., 2024), além de corresponderem a 37% de todo o tempo de parada (*downtime*) por avarias (LEE; LEE, 2024). A principal causa de tais falhas está atrelada ao estresse térmico; a falha no sistema de refrigeração leva ao superaquecimento, que acelera a degradação do isolamento dos enrolamentos e pode culminar em uma falha catastrófica (ALI et al., 2025). Isso demonstra a necessidade crítica de um sistema de monitoramento para a detecção precoce de anomalias.

O artigo aborda o uso de Aprendizado de Máquina (Machine Learning - ML) para previsão e diagnóstico em séries temporais multivariadas, com foco em manutenção preditiva industrial. O problema envolve modelar dependências temporais e relações entre variáveis sensoriais (como temperatura e vibração) para detectar padrões de degradação, prever falhas e estimar a Vida Útil Remanescente (RUL). O desafio inclui lidar com dados sequenciais ruidosos e incompletos, tratando tanto de tarefas supervisionadas (RUL) quanto não supervisionadas, ou anomalias.

A estrutura do artigo inclui: fundamentos teóricos e revisão de literatura; descrição de materiais, bases de dados e protocolo experimental; detalhamento das técnicas de pré-processamento, imputação, modelagem e avaliação, com destaque para LSTM, Autoencoders e algoritmos de similaridade; e, por fim, a análise dos resultados e as conclusões finais.

2. FUNDAMENTAÇÃO TEÓRICA

A predição de falhas em sistemas industriais complexos evoluiu significativamente nas últimas décadas, impulsionada pelo avanço das técnicas de ML e DL. Tradicionalmente, abordagens de manutenção se baseavam em inspeções periódicas ou em modelos físicos, mas o crescimento do volume

de dados sensoriais e a disponibilidade de poder computacional viabilizaram o desenvolvimento de métodos baseados em dados, capazes de extrair padrões e prever falhas de maneira mais eficiente (RUSSELL; NORVIG, 2010; MITCHELL, 1997).

2.1. Prognóstico de Falhas e RUL

O prognóstico de saúde de máquinas, especialmente a estimativa de RUL, constitui tema central em manutenção preditiva. (LEI et al., 2018) apresentam uma revisão sistemática abrangente do ciclo completo, desde a aquisição de dados, extração de características e construção do HI, até a predição de RUL por métodos estatísticos e de ML. Entre os principais desafios estão o tratamento de dados ausentes, a variabilidade operacional dos ativos e a necessidade de modelos adaptativos que consigam generalizar em diferentes cenários.

Os HI emergem como representações sintéticas do estado de saúde de um equipamento, facilitando o monitoramento contínuo e servindo como insumo fundamental para algoritmos de predição de falha e estimativa de RUL (LEI et al., 2018). A literatura apresenta diferentes estratégias para a construção do HI, abrangendo desde técnicas baseadas em estatística tradicional até abordagens modernas de aprendizado profundo, capazes de extrair automaticamente representações relevantes a partir de grandes volumes de dados brutos (GOODFELLOW et al., 2016; LECUN et al., 2015).

O processo de prognóstico de falhas com base em HI e RUL envolve múltiplas etapas integradas. Inicialmente, exige-se a coleta de séries temporais multivariadas, frequentemente marcadas por ruídos, dados faltantes e variações operacionais anômalas ou anormais. Métodos robustos de imputação, como o *Self-Attention-based Imputation for Time Series* (SAITS), tornam-se indispensáveis para recuperar trajetórias confiáveis de dados. Em seguida, modelos como LSTM-Autoencoder (LSTM-AE) são empregados para gerar um HI sensível a degradações incipientes, traduzindo desvios no comportamento do sistema em métricas quantificáveis de saúde. Finalmente, algoritmos de comparação por similaridade, como o kNN, utilizam o histórico de trajetórias de HI para estimar o RUL com base em padrões já observados em falhas anteriores. Essa abordagem integrada, embora poderosa, requer rigor no tratamento dos dados, validação cruzada cuidadosa e monitoramento contínuo, dada a alta complexidade e variabilidade dos ambientes industriais modernos (DU et al., 2023; ZHANG et al., 2019; MALHOTRA et al., 2015).

2.2. Machine Learning, Deep Learning e Modelos para Séries Temporais

O ML consolidou-se como o paradigma dominante para análise de dados complexos e não-lineares, permitindo que algoritmos aprendam padrões diretamente dos dados, sem a necessidade de modelagem explícita por especialistas (MITCHELL, 1997). O surgimento do DL, caracterizado pelo uso de múltiplas camadas não-lineares para aprendizado de representação, impulsionou avanços expressivos em tarefas como classificação, detecção de anomalias e previsão de séries temporais (GOODFELLOW et al., 2016; LECUN et al., 2015; BENGIO et al., 2013).

A literatura destaca o aprendizado de representação como um elemento central para o sucesso dessas abordagens. Bengio et al. (BENGIO et al., 2013) definem aprendizado de representação como a capacidade dos modelos de extrair automaticamente características relevantes e informativas dos dados brutos, o que é crucial para aplicações em diagnóstico e prognóstico de sistemas industriais. Autoencoders (AE), por exemplo, são amplamente utilizados para compressão, reconstrução e detecção de padrões anômalos em dados multivariados, ao aprenderem codificações eficientes e sem supervisão.


No contexto de séries temporais industriais, como aquelas provenientes de sistemas SCADA (*Supervisory Control and Data Acquisition*), modelos baseados em Redes Neurais Recorrentes (RNNs), especialmente as LSTM (*Long Short-Term Memory*), destacam-se por sua habilidade de capturar dependências temporais de longo prazo, filtrando ruído e ressaltando tendências relevantes para a detecção de falhas incipientes (HOCHREITER; SCHMIDHUBER, 1997; ZHANG et al., 2019). As LSTM

vêm sendo amplamente empregadas para modelar processos de degradação, detectar anomalias e compor indicadores de saúde (HI) a partir de séries históricas multivariadas (MALHOTRA et al., 2015; ZHANG et al., 2020).

Além disso, a integração de *Autoencoders* com LSTM, formando modelos híbridos como o LSTM-AE, tem se mostrado eficaz em aplicações industriais, permitindo tanto a extração de representações comprimidas quanto a modelagem explícita da dinâmica temporal dos dados. Tais arquiteturas híbridas ampliam a capacidade de identificar padrões incipientes de degradação, antecipar falhas e auxiliar na estimativa da vida útil remanescente (RUL), constituindo o estado da arte em prognóstico de ativos industriais.

Uma linha de pesquisa relevante associa *Autoencoders* e LSTM para detecção de anomalias, conforme demonstrado em trabalhos como (MALHOTRA et al., 2015; PARK et al., 2018). O LSTM-AE é treinado para reconstruir sequências consideradas normais, de modo que o erro de reconstrução serve como alerta para comportamentos anômalos, sendo amplamente empregado na geração de Health Index para predição de RUL em motores, rolamentos e outros sistemas industriais (PARK et al., 2018; XU et al., 2021). A Figura 1 ilustra o funcionamento do LSTM-AE aprendendo uma codificação eficiente das séries temporais (*encoder*), comprimindo-as em um espaço de baixa dimensão (*bottleneck*), e então reconstruindo-as (*decoder*). Esta arquitetura é especialmente poderosa para detecção de anomalias e extração de características relevantes em tarefas de manutenção preditiva, devido à sua capacidade de lidar com dependências temporais longas e não-lineares.

Figura 1. Long Short-Term Memory Autoencoder




2.3. Imputação de Dados e k-Nearest Neighbors

O tratamento de dados faltantes é desafio recorrente em aplicações industriais. Modelos recentes, baseados em autoatenção, como SAITS, vêm superando métodos tradicionais ao considerar dependências temporais e estruturais nos dados (LEI et al., 2018). Já o algoritmo k-Nearest Neighbors (kNN), originalmente proposto por (COVER; HART, 1967), é frequentemente utilizado para estimar o RUL por similaridade, comparando a trajetória atual de degradação com um histórico de curvas observadas, método simples, porém robusto para ambientes com múltiplos cenários de falha (XU et al., 2021).

A Figura 2 ilustra a abordagem de comparação por similaridade entre trajetórias do HI ao longo do tempo, estratégia fundamental para realizar estimativa de falhas com uso do algoritmo kNN. O eixo vertical representa os valores do HI, que normalmente variam de 1 (indicando condição saudável) até 0 (indicando iminência de falha), enquanto o eixo horizontal corresponde ao tempo de operação dos equipamentos. A curva mostrada em verde, representa o HI da máquina atualmente monitorada, enquanto as demais curvas (em azul e cinza) correspondem a trajetórias históricas de HI de outras máquinas ou de ciclos completos de operação já observados anteriormente. Essas trajetórias históricas formam a base de comparação para análise de similaridade.

O procedimento consiste em, a partir do ponto atual da curva monitorada, identificar no histórico as trajetórias que apresentam maior semelhança em seus padrões recentes de degradação, ilustradas por "similar trajectories". O trecho mais atual do HI da máquina em análise é comparado com os trechos equivalentes dessas trajetórias similares. A partir dessa comparação, calcula-se quanto tempo foi necessário para cada uma dessas trajetórias semelhantes evoluir do ponto de comparação até o momento de falha (ou seja, até o HI atingir valores próximos a zero).

Figura 2. Comparação por Similaridade



3. TRABALHOS RELACIONADOS

Nos últimos cinco anos, diversas pesquisas vêm destacando abordagens integradas para prognóstico de falhas industriais, especialmente aquelas que exploram autoencoders, LSTM, SAITS e kNN. Du et al. (DU et al., 2023) demonstraram a eficácia de SAITS na imputação de séries temporais com múltiplas variáveis ausentes, superando métodos tradicionais em diversos benchmarks industriais. Trabalhos recentes como Zhao et al. (ZHANG et al., 2024) e Dong et al. (DONG et al., 2022) exploraram AEs e LSTM-AE para extração automática de características relevantes e detecção antecipada de falhas em equipamentos críticos.

Além disso, a utilização de *kNN* para comparação de trajetórias de Health Index (HI) e predição de RUL mostrou-se simples, eficiente e interpretável em ambientes industriais reais, conforme apontado por (LI et al., 2021). A literatura recente corrobora que a sinergia entre métodos de imputação por atenção, aprendizado profundo e algoritmos de similaridade compõe o estado da arte para manutenção preditiva baseada em dados.


4. MÉTODO DO ESTUDO

A metodologia deste trabalho consiste no desenvolvimento de uma solução baseada em ML para a detecção de anomalias em séries temporais, com o objetivo de estimar o tempo restante até a ocorrência de falhas em dispositivos industriais. A abordagem é fundamentada na utilização de LSTM-Autoencoder (LSTM-AE) como gerador de um índice de saúde dos dispositivos, denominado "termômetro", capaz de capturar o surgimento de comportamentos anômalos a partir do erro de reconstrução.

O processo metodológico é dividido em 6 etapas: 1) Coleta de dados históricos, compreendendo todos os registros capturados pelos dispositivos até o momento de uma falha; 2) Recuperação de dados; 3) Análise dos dados em andamento, correspondente aos dados coletados desde a última falha até o instante atual de operação; 4) Cálculo do HI; 5) Calcular Estimativas com base no HI; 6) Visualizar as comparações em larga escala.

A solução desenvolvida emprega um modelo (LSTM-AE) para extrair, a partir dos dados de múltiplas variáveis ao longo do tempo, uma representação única que sintetiza a qualidade das correlações entre elas. Em situações de funcionamento normal, observam-se fortes associações entre as variáveis. Entretanto, à medida que se aproxima uma falha, essas correlações se deterioram, o que leva ao aumento do erro de reconstrução do modelo, que por sua vez é interpretado como um declínio no índice de saúde. O algoritmo, portanto, utiliza a trajetória cumulativa dessa degradação para inferir a iminência de falhas, fenômeno já documentado na literatura como "trajetória de degradação". O processo descrito pode ser visualizado na Figura 3.

Figura 3. Metodologia



O modelo LSTM-AE utilizado consiste em um *Autoencoder* baseado em redes neurais recorrentes do tipo LSTM (*Long Short-Term Memory*), capaz de capturar dependências temporais de longo prazo presentes em séries temporais. O *Autoencoder* compreende duas partes principais: um codificador, responsável por comprimir a informação, e um decodificador, que tenta reconstruir a entrada original a partir da representação comprimida. Essa estrutura permite identificar padrões relevantes, eliminar ruídos e reduzir a dimensionalidade dos dados, otimizando a detecção de comportamentos anômalos e a construção do índice de saúde.

4.1. Dados Processados no Modelo

Os dados históricos empregados neste estudo compreendem séries temporais multivariadas, contendo 12 variáveis monitoradas continuamente ao longo do tempo em intervalos fixos e com natureza diversificada, como temperaturas, potências, velocidades e estados. Os registros abrangeram diferentes períodos operacionais, totalizando centenas de milhões de valores processados, distribuídos em diversos eventos de falha documentados nos equipamentos analisados.

Cada falha registrada delimitou um novo segmento temporal, de modo que os dados foram organizados em trechos definidos pelo intervalo entre falhas consecutivas. Dessa forma, obtiveram-se milhares de segmentos individuais, cada um representando um ciclo operacional completo entre dois eventos de falha. Tipicamente, cada segmento continha milhares de amostras, dependendo do tempo até a próxima falha.

Cada segmento é processado pelo LSTM-AE, que tenta reconstruir os dados originais. Observa-se que, à medida que os dados se aproximam de uma nova falha, o erro de reconstrução gerado pelo modelo tende a aumentar. Este erro, denominado aqui como "termômetro de falha", é utilizado como métrica para quantificar o grau de anomalia presente em cada trecho temporal.

Para incorporar a dimensão temporal ao processo de detecção, são utilizadas técnicas de comparação de sequências, tais como o algoritmo *k-Nearest Neighbors* (kNN) ou métricas de distância entre sequências. O "termômetro" dos dados em andamento é comparado aos segmentos históricos, identificando quais períodos do histórico apresentam comportamento mais semelhante ao atual. Dessa

forma, torna-se possível inferir o tempo restante até a potencial falha, com base na duração dos segmentos históricos mais próximos.

4.2. Pré-Processamento dos Dados

O processo inicia-se com a aquisição de dados históricos e em andamento, provenientes dos dispositivos monitorados. Como etapas iniciais, realiza-se a verificação de consistência dos dados e o preenchimento de valores ausentes. Para tal, emprega-se a técnica SAITS, disponibilizada na biblioteca PyPOTS (DU et al., 2023), reconhecida por sua robustez na imputação faltantes em séries temporais. Em seguida, todas as variáveis de entrada são normalizadas, garantindo que estejam na mesma escala para o correto funcionamento dos algoritmos de ML.

Adicionalmente, são realizadas análises de correlação entre as variáveis disponíveis e os eventos de falha, permitindo a seleção dos conjuntos de variáveis mais adequados para cada um dos três problemas abordados neste trabalho. Cada problema possui conjuntos de variáveis que, apesar de se entrelaçarem parcialmente, não são idênticos. Os dados históricos são segmentados em trechos delimitados por falhas consecutivas, sendo a "falha" definida a partir de um rótulo explícito nos dados, representando a interrupção do funcionamento normal do dispositivo. Este rótulo também é utilizado como referência para avaliar a precisão da solução proposta. Os segmentos resultantes abrangem toda a janela de funcionamento desde o reinício do dispositivo até a ocorrência da falha.

4.3. Geração do Índice de Saúde com LSTM-AE

Para cada segmento temporal, o modelo LSTM-AE é treinado majoritariamente com dados distantes de falhas (considerados saudáveis), buscando reconstruir as séries originais. O erro de reconstrução resultante é acumulado ao longo do tempo, formando a trajetória de degradação do HI. A degradação do HI sinaliza a intensificação de anomalias à medida que a falha se aproxima.

4.4. Comparação Temporal e Estimativa de Falha

A comparação entre os segmentos históricos e os dados em andamento é realizada com o auxílio do algoritmo kNN, utilizando distância euclidiana entre as sequências de índices de saúde e considerando dez vizinhos. Essa comparação permite identificar quais períodos históricos apresentam comportamento mais similar ao atual, fornecendo uma estimativa do tempo restante até a falha com base na duração dos segmentos históricos mais próximos.

4.5. Estimativa de Tempo de Vida Remanescente

Duas estratégias são consideradas para a estimativa do RUL: (i) comparação por similaridade de trajetórias de HI e (ii) uso de limiar (*threshold*) do HI. Neste trabalho, adota-se a abordagem baseada em similaridade, empregando o algoritmo *k-Nearest Neighbors* (kNN) para comparar diretamente as trajetórias de HI entre segmentos históricos e dados em andamento. A métrica de distância utilizada é a Euclidiana, com $k = 10$ vizinhos mais próximos.

Cada trajetória histórica é representada como um vetor no espaço de características, e o kNN avalia a similaridade entre trajetórias pela proximidade desses pontos. O resultado permite inferir, para uma trajetória em andamento, o tempo remanescente esperado até a falha, com base nas durações dos históricos mais similares.

O KNN apresenta vantagens de simplicidade e interpretabilidade, embora seu desempenho possa ser impactado por alta dimensionalidade dos dados — contexto em que o pré-processamento, a normalização e a compressão dos dados via LSTM-AE são essenciais para garantir comparações eficientes e significativas.

4.6. Frameworks e Fluxo Operacional

O desenvolvimento e a implementação da solução fazem uso dos principais frameworks de ciência de dados, incluindo SKLearn (PEDREGOSA et al., 2011), PyTorch (PASZKE et al., 2019), Keras (CHOLLET, 2015), PyPOTS (DU et al., 2023) e pandas (REBACK et al., 2020). O fluxo operacional do sistema pode ser resumido nos seguintes passos:

- Buscar e agregar novos dados provenientes dos dispositivos;
- Verificar e imputar valores ausentes utilizando o método SAITS;
- Normalizar os dados de entrada;
- Aplicar o LSTM-Autoencoder para produzir o índice de saúde;
- Realizar a comparação dos índices com os históricos, por meio do kNN, para estimar o tempo restante até a falha.

5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Os experimentos realizados permitiram avaliar o desempenho do método proposto em múltiplos cenários, utilizando diferentes conjuntos de dados históricos e em andamento, extraídos de dispositivos monitorados ao longo de períodos extensos. A avaliação visa determinar a efetividade dos métodos empregados e como podem caracterizar adequadamente o problema. A seguir, apresentam-se os principais resultados associados a cada etapa da metodologia.


5.1. Correções de Dados Faltantes

A utilização do modelo SAITS para tratamento de dados faltantes mostrou-se um ponto-chave para a qualidade dos experimentos. O dataset original apresentou percentuais significativos de dados ausentes, tanto devido a falhas de sensoriamento quanto a interrupções operacionais. O SAITS demonstrou desempenho superior aos métodos tradicionais de imputação, sendo capaz de reconstruir grandes lacunas temporais e reduzir substancialmente a perda de amostras. Como resultado, foi possível ampliar a quantidade de janelas de dados completas, elevando a representatividade estatística das trajetórias analisadas e garantindo maior robustez às etapas subsequentes do pipeline.

Durante o treinamento do modelo SAITS, foram utilizadas diferentes divisões de conjuntos de dados, a fim de validar a robustez do algoritmo frente à variabilidade operacional e à presença de grandes lacunas de dados.


O processo de treinamento foi monitorado por métricas quantitativas de desempenho e convergência. A Figura 4 demonstra a curva de perda (*loss curve*) ao longo das épocas de treinamento, exibindo a média da função de perda acompanhada do intervalo correspondente ao desvio padrão (média + desvio, média - desvio) entre as diferentes execuções do treinamento. Essa representação evidencia tanto a estabilidade da convergência quanto a dispersão dos resultados ao longo dos experimentos, reforçando a consistência do SAITS para o conjunto de dados avaliado.

Figura 4. Saits Loss - Iterações de Treino



Já a Figura 5 apresenta três casos de estudo, cada um representado por um cenário de máquina e falha distintos, além dos valores de erro absoluto médio (MAE) e de erro quadrático médio (RMSE); observa-se baixa dispersão e valores reduzidos de MAE, indicando alta precisão na reconstrução dos dados faltantes, enquanto o RMSE corrobora esses resultados e reforça a capacidade do SAITS de imputar valores próximos aos reais mesmo em situações de maior complexidade temporal; essa robustez no tratamento foi fundamental para viabilizar a etapa subsequente de análise de degradação e previsão de falhas.

Figura 5. SAITS - Erro Médio Absoluto & Raiz do Erro Quadrático Médio




5.2. Uso de TCN para estimativa de RUL

Em busca de alternativas para previsão direta de RUL, foi avaliada a aplicação de redes convolucionais temporais (TCN - *Temporal Convolutional Network*). O TCN foi treinado utilizando trajetórias completas, visando estimar diretamente a quantidade de ciclos restantes até a ocorrência de falha. Entretanto, os resultados obtidos demonstraram acurácia insatisfatória para os requisitos do problema, especialmente em cenários com alta variabilidade operacional e múltiplos padrões de degradação. Observou-se que o TCN apresentava dificuldade em capturar as nuances e as heterogeneidades típicas das séries temporais reais, gerando previsões dispersas e baixa confiabilidade para uso prático no contexto industrial. Esta limitação reforçou a busca por abordagens mais sensíveis à dinâmica temporal das variáveis.

5.3. Avaliação do LSTM-Autoencoder

O modelo LSTM-Autoencoder foi avaliado quanto à sua capacidade de reconstruir as séries temporais em condições normais e em proximidade de falhas. Observou-se que o erro de reconstrução permanece baixo durante o funcionamento saudável dos dispositivos, apresentando elevação significativa à medida que o sistema se aproxima de uma falha, vide Figura 7.

Figura 6. Evolução do erro de reconstrução do LSTM-AE ao longo do tempo.



A evolução do índice de saúde HI gerado pelo LSTM-AE ao longo do tempo mostra-se consistente com os eventos de falha registrados, permitindo utilizar o HI como preditor confiável do estado de degradação do dispositivo.

5.4. Estimativa do Tempo de Vida Remanescente

A abordagem de similaridade adotada, baseada em *kNN*, mostrou-se eficiente para inferir o tempo de vida remanescente. Para cada segmento em andamento, foram identificados os $k = 10$ históricos mais similares em termos de trajetória do HI, permitindo estimar o tempo restante até a falha com base nos padrões observados anteriormente.

A Tabela 1 apresenta os resultados obtidos a partir da aplicação do algoritmo *kNN* para previsão de falhas em quatro dispositivos distintos. Para cada dispositivo, são exibidas as seguintes informações: o valor de confiabilidade do prognóstico, o tempo restante até a falha em dias e horas, a data prevista para ocorrência do evento de falha, o valor do índice de falha estimado, e a data real em que a falha foi confirmada.

Tabela 1 — Tabela de resultados de comparação dos HI.

MÁQUINA	Dispositivo 1	Dispositivo 2	Dispositivo 3	Dispositivo 4
CONFIABILIDADE	79%	78%	75%	74%
TEMPO RESTANTE	21 DIAS e 4 HORAS	15 DIAS e 10 HORAS	15 DIAS e 16 HORAS	8 DIAS e 23 HORAS

DATA PREVISTA	21/03/2025 04:00	15/03/2025 10:00	15/03/2025 16:00	08/03/2025 23:00
FALHA	01	03	03	01
CONFIRMAÇÃO	19/03/2025 22:53	16/03/2025 03:05	13/03/2025 20:37	07/03/2025 10:02

Observa-se que a confiabilidade das previsões variou entre 74% e 79% entre os dispositivos, indicando um bom desempenho do método de similaridade para identificar padrões de degradação. O tempo restante até a falha previsto pelo kNN variou de aproximadamente 9 a 21 dias, refletindo diferentes estágios de degradação entre os dispositivos monitorados. As datas previstas para falha mostraram-se próximas das datas de confirmação real, evidenciando a capacidade do modelo de antecipar eventos críticos com boa precisão temporal. Por exemplo, para o Dispositivo 1, a previsão foi de 21/03/2025 às 04:00, enquanto a confirmação real ocorreu em 19/03/2025 às 22:53, com diferença inferior a dois dias. Resultados semelhantes são observados para os demais dispositivos.

6. AMBIENTES DE DESENVOLVIMENTO E DEPENDÊNCIAS

A Tabela 2 apresenta o resumo dos principais equipamentos utilizados nas etapas de desenvolvimento, experimentação e produção deste projeto.

Tabela 2 — Configuração de hardware.

Ambiente	Processador	GPU	Memória RAM
Lab – Server	Intel i9-9900k	NVIDIA Titan V	64
Lab – <i>Workstation 1</i>	Ryzen 9 7900X	NVIDIA Quadro RTX A5000	64
Lab – <i>Workstation 2</i>	Ryzen 7 2700X	NVIDIA RTX 2060 SUPER	16
<i>Production PC</i>	Intel i7 10th Gen	NVIDIA RTX 4090	16
<i>Develop PC</i>	Intel i5-10400F	NVIDIA RTX 4070 Super	16

O ambiente de desenvolvimento adotou o sistema operacional Ubuntu 22.04 LTS (64 bits), com Python 3.10 como linguagem principal para scripts e prototipagem de modelos. As principais bibliotecas Python empregadas foram:

- **NumPy** (Harris et al., 2020) e **Pandas** (Reback et al., 2020): para manipulação, análise e pré-processamento de dados;
- **scikit-learn** (Pedregosa et al., 2011): para modelagem tradicional, kNN, normalização e avaliação;
- **PyTorch** (Paszke et al., 2019) e **TensorFlow/Keras** (Chollet et al., 2015): para desenvolvimento e treinamento dos modelos LSTM, autoencoder e SAITS;

- **matplotlib** (Hunter, 2007) e **Seaborn**: para visualização gráfica dos resultados;
- **PyPOTS** (Du et al., 2023): para imputação de dados em séries temporais utilizando SAITS;
- **Ferramentas de integração com bancos de dados relacionais**: para consultas seguras e automatizadas

Os dados utilizados neste estudo foram obtidos por meio de integração com um banco de dados relacional gerenciado em nuvem, o que possibilitou consultas seguras aos históricos operacionais dos aerogeradores. O acesso foi realizado por meio de consultas automatizadas seguras, garantindo eficiência e integridade durante a extração dos dados relevantes para as análises. Todos os experimentos foram controlados por versionamento em Git, assegurando rastreabilidade e integridade dos resultados.

7. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

Os resultados apresentados neste trabalho demonstram que o *framework* híbrido proposto, combinando imputação de dados via SAITS, extração de índice de saúde com LSTM-AE e estimativa do tempo de vida remanescente por meio do algoritmo kNN, é eficaz para o monitoramento preditivo do sistema de refrigeração de aerogeradores. O sistema apresentou capacidade de detectar padrões de degradação e antecipar falhas, atingindo confiabilidade de até 79%, mesmo em cenários com dados faltantes e variabilidade operacional significativa. O uso integrado dessas técnicas viabilizou a transição de uma abordagem de manutenção reativa para uma estratégia preditiva, com potencial para redução de custos operacionais e aumento da disponibilidade dos ativos.

Como próximos passos, sugerem-se as seguintes linhas de pesquisa:

- **Otimização dos modelos**: Investigar ajustes de hiper-parâmetros e arquiteturas de redes neurais, buscando aprimorar o desempenho do sistema em diferentes cenários operacionais.
- **Aprimoramento da confiabilidade**: Realizar uma comparação sistemática entre o SAITS e outros métodos de imputação de dados, como *KNN Imputer*, MICE ou modelos baseados em GANs, visando identificar abordagens que aumentem a precisão e robustez do *framework*.
- **Análise de impacto econômico**: Conduzir estudos para quantificar os benefícios em termos de redução de custos de O&M e aumento da disponibilidade dos ativos.

REFERÊNCIAS

- BENGIO, Yoshua; COURVILLE, Aaron; VINCENT, Pascal. Representation learning: a review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 35, n. 8, p. 1798–1828, 2013.
- CHOLLET, François; et al. Keras. Disponível em: <https://keras.io>. Acesso em: 15 set. 2025.
- COVER, Thomas; HART, Peter. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, v. 13, n. 1, p. 21–27, 1967.
- DONG, Yunliang; LI, Yan; HE, Zhengjia. LSTM-based deep learning models for remaining useful life prediction of rotating machinery: a review. *Mechanical Systems and Signal Processing*, v. 165, p. 108299, 2022. DOI: 10.1016/j.ymssp.2021.108299.
- DU, Mengyang; et al. PyPOTS: a Python toolbox for medical time series imputation. *Computer Methods and Programs in Biomedicine*, v. 233, p. 107505, 2023.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep Learning*. Cambridge, MA: MIT Press, 2016.
- HARRIS, Charles R.; et al. Array programming with NumPy. *Nature*, v. 585, n. 7825, p. 357–362, 2020.
- HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997.
- HUNTER, John D. Matplotlib: a 2D graphics environment. *Computing in Science & Engineering*, v. 9, n. 3, p. 90–95, 2007.
- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015.
- LEI, Yaguo; et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, v. 104, p. 799–834, 2018.
- LI, Yan; HE, Zhengjia; WU, Tianyuan. Hybrid data-driven methods for RUL prediction: a review. *Reliability Engineering & System Safety*, v. 215, p. 107830, 2021. DOI: 10.1016/j.ress.2021.107830.
- MALHOTRA, Pankaj; et al. Long short term memory networks for anomaly detection in time series. In: *Proceedings of the 23rd European Symposium on Artificial Neural Networks (ESANN 2015)*. Bruges, Belgium: i6doc.com, 2015. p. 89–94.
- MITCHELL, Tom M. *Machine Learning*. New York: McGraw-Hill, 1997.
- PARK, S.; KIM, S.; LEE, J. LSTM-Autoencoder based anomaly detection for indoor air quality time series data. *Sensors*, v. 18, n. 10, p. 3470, 2018.
- PASZKE, Adam; et al. PyTorch: an imperative style, high-performance deep learning library. In: *Advances in Neural Information Processing Systems (NeurIPS 2019)*. Red Hook, NY: Curran Associates, Inc., 2019. v. 32, p. 8026–8037.
- PEDREGOSA, F.; et al. Scikit-learn: machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.
- REBACK, Jeff; et al. pandas-dev/pandas: Pandas. Zenodo, 2020. Disponível em: <https://doi.org/10.5281/zenodo.3509134>. Acesso em: 15 set. 2025.
- RUSSELL, Stuart; NORVIG, Peter. *Artificial Intelligence: A Modern Approach*. 3. ed. [S.l.]: Prentice Hall, 2010.
- WYSZOMIERSKI, Rafał; et al. The cost-effectiveness of renewable energy sources in the European Union's ecological economic framework. *Sustainability*, v. 17, n. 10, p. 4715, 2025. DOI:

10.3390/su17104715.

XU, X.; WANG, J.; DENG, W. Attention-based LSTM networks for remaining useful life prediction of rotating machinery. *Reliability Engineering & System Safety*, v. 210, p. 107504, 2021.

ZHANG, Bin; ZHANG, Sheng; LI, Weiliang. Bearing performance degradation assessment using long short-term memory recurrent network. *Computers in Industry*, v. 106, p. 14–29, 2019.

ZHANG, Y.; CHEN, L.; WANG, X. LSTM-Autoencoder deep learning model for anomaly detection in electric motor. *IEEE Access*, v. 8, p. 212230–212238, 2020.

ZHANG, Yanjun; CHEN, Lin; WANG, Xiaoyu. LSTM-Autoencoder deep learning model for anomaly detection in electric motor. *Energies*, v. 17, n. 10, p. 2340, 2024

Cálculo de disponibilidade de Aerogeradores através de múltiplas fontes de dados, utilizando dados estruturados e não estruturados.

Joaquim Modesto Pereira Araujo

Alupar - Engenharia de Planejamento de Manutenção da Geração

jpereira@alupar.com.br

RESUMO

A elevação da precisão no controle das atividades de manutenção e na apuração da disponibilidade de Aerogeradores é uma prioridade para os empreendimentos eólicos. Seus resultados impactam na confiabilidade dos dados, as responsabilidades contratuais e os pontos de melhoria a serem contemplados no planejamento de manutenção e operação. Assim, este estudo demonstra o desenvolvimento e aplicação de uma solução de inteligência artificial supervisionada para apuração de disponibilidade técnica de Aerogeradores e controle de manutenção.

A solução baseia-se na análise descritiva e diagnóstica de dados estruturados e não estruturados de múltiplas fontes, com o intuito de identificar desvios de atividades, comportamento dos ativos e indisponibilidades reportadas.

Palavras-chaves:

Manutenção de Aerogeradores; Qualidade de Manutenção; Disponibilidade Técnica; Eficiência de Processos.

ABSTRACT

Increasing precision in controlling maintenance activities and determining the availability of wind turbines is a priority for wind farms.

Its results impact data fidelity, contractual responsibilities and the points of evolution to be considered in maintenance and operation planning.

Thus, this study demonstrates the development and application of a supervised artificial intelligence solution for determining the technical availability of wind turbines and maintenance control.

The solution is based on a descriptive and diagnostic analysis of structured and unstructured data from multiple sources, with the aim of identifying activity deviations, asset behavior and reported unavailability.

Keywords:

Wind turbine maintenance; Maintenance Quality; Technical Availability; Process Efficiency.

1. INTRODUÇÃO

A utilização de métricas de disponibilidade para a medição do desempenho dos empreendimentos eólicos é um dos principais pilares para acompanhamento do seu desempenho técnico e financeiro.

Tendo em vista que no Brasil a geração eólica está em expansão e demonstra a existência de ativos eólicos em diversos períodos de operação, contendo ativos com tempo de operação superiores a 20 anos, o mercado demonstra interesse em métodos e ações para extensão da vida útil e melhor controle dos ativos (EPE, 2021).

Nos empreendimentos podemos encontrar diversos métodos de organização e gestão de manutenção, cuja qualidade e eficácia, em concordância com a Gestão da Qualidade Total e a Manutenção Total Produtiva, pode ser medida através da disponibilidade técnica dos ativos, seja ela executada pela entidade proprietária ou fabricante.

Normativamente o cálculo de disponibilidade é obtido pela IEC 61400-26-1 (IEC 61400-26-1, 2019).

Devido à necessidade e dificuldade de validação dos status dos ativos, bem como o mapeamento eficiente dos tipos de atividades executadas ao longo do tempo, houve o estudo de métodos, lógicas e percepções que juntos oferecessem a exatidão esperada para o processo de análise.

Com o volume de dados e a busca por eficiência, a utilização de ferramentas da ciência de dados se mostra benéfica para o objetivo proposto.

A ciência de dados é o uso de diversas tecnologias, modelos e metodologias para capturar, armazenar e processar informações, gerando valor a um negócio (FIA, 2024).

Segundo CAO, esta ciência tem o objetivo de desenvolver técnicas e tecnologias para o processamento de dados para possibilitar a tomada de decisão e ganho de valor sobre a informação (CAO, 2016).

Através da ciência de dados foram correlacionados os dados e conceitos obtidos dos estudos, de modo a estabelecer o desenvolvimento de um método para aumento da precisão dos dados de disponibilidade técnica e de registros de manutenção em Aerogeradores.

No presente trabalho, é apresentado o desenvolvimento e aplicação de um processo de ciência de dados para análise de disponibilidade técnica de Aerogeradores, utilizando métodos em complemento à IEC 61400-26-1, com foco na utilização de múltiplos dados de diversas fontes estruturadas e não estruturadas, evidenciando a veracidade da apuração e da exatidão do processo estabelecido.

2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

2.1 MANUTENÇÃO E DISPONIBILIDADE

A Disponibilidade é definida pela capacidade de um ativo ou componente de desempenhar sua função em um período de tempo determinado (NBR-5462, 1994). Para o aspecto da geração eólica, a disponibilidade técnica demonstra a confiabilidade do empreendimento e a qualidade dos serviços executados para avaliação contratual e de planejado com base no investimento. A manutenção centrada em confiabilidade de parques eólicos é uma abordagem de gestão de manutenção identificada no setor (FUENTES, 2006). Neste contexto, a fidelidade dos dados para o controle de manutenção é uma característica para o funcionamento da gestão de manutenção e efetividade das medidas tomadas, minimizando distorções nas apurações de dados e na tomada de decisão.

IEC 61400-26-1: Time based availability for wind turbines

Esta normativa visa a organização de informações e cálculos sobre indicadores de desempenho para interesses no setor de geração de energia eólica. Sua divisão consiste em duas modalidades de disponibilidade, a operacional e a técnica (IEC 61400-26-1, 2019). A disponibilidade operacional é definida

pela fração de tempo em um período, no qual o ativo se manteve efetivamente produzindo energia (IEC 61400-26-1, 2019). A disponibilidade técnica é definida pela fração de tempo em um período específico, no qual o ativo está operando de acordo com as condições de projeto (IEC 61400-26-1, 2019). Para o tema deste estudo será abordada a modalidade de disponibilidade técnica.

Gestão da Qualidade Total (GQT ou TQM)

Esta filosofia consiste em demonstrar ideias de melhoria do processo e da qualidade com objetivo de proporcionar uma maior eficiência da organização face ao cliente (ARNOLD, 2006). A gestão da qualidade total é entendida resumidamente pelas premissas que consistem no envolvimento de todos da organização no processo, aplicação da padronização em busca de um produto perfeito, o estabelecimento e aplicação de estratégias para atingimento das etapas planejadas e foco no gerenciamento do negócio (KAUR et al., 2018).

Manutenção Produtiva Total (TPM)

É o comprometimento de todos os membros da empresa, através de um gerenciamento organizado e determinado para o equipamento, com foco em monitoramento e execução da manutenção produtiva nos equipamentos da unidade de produção (TAKAHASHI; OSADA, 1993). Os pilares tomados para direcionar os esforços da organização perante a Manutenção Produtiva Total consistem na manutenção autônoma, melhorias específicas, manutenção planejada, educação/treinamento, manutenção da qualidade, controle inicial, segurança, saúde, meio ambiente e áreas administrativas (CARRIJO, 2008).

Segundo BOATENG, os propósitos da Gestão da Qualidade Total e da Manutenção Produtiva Total apresentam métodos e procedimentos com objetivo de elevar a disponibilidade e qualidade dos equipamentos, resultando na excelência de performance (BOATENG et al., 2016). Neste contexto, a disponibilidade se torna um dos índices de controle mais efetivos na geração Eólica, para o sucesso do empreendimento com base na Gestão da Qualidade Total e na Manutenção Produtiva Total.

2.2 CIÊNCIA DE DADOS

Colaborando com o tema, a ciência de dados executa a combinação da programação especializada, análise avançada, estatística, Machine Learning e inteligência artificial (IA) com os conhecimentos próprios dos assuntos de maneira a obter análises e comportamentos de difícil detecção, possibilitando a otimização de processos e o aparecimento de oportunidades de melhorias (IBM). Um dos algoritmos de Machine Learning utilizados na inteligência artificial (IA) é o da árvore de decisão que são utilizados para a regressão e classificação de dados (BALAKRISHNA, 2019).

2.3 ÁRVORE DE DECISÃO

A árvore de decisão é a técnica que consiste em separar problemas de alta complexibilidade em vários problemas menores, até o atingimento da etapa final do processo de apuração. Esta metodologia corresponde a um mecanismo de aprendizado de máquina supervisionado não paramétrico (FACELI et al., 2011). Sua construção é realizada através da adoção de nós de decisão, que obedecem a regras parametrizadas e preestabelecidas para a classificação ou discriminação dos dados. Este ciclo, denominado regra de classificação, ocorre até o atingimento dos terminais do processo.

Ao atingir o terminal do processo, o dado obtido será o resultado da regra inserida.




Figura 1: Exemplo de árvore de decisão. Fonte: O próprio autor, 2024.

As árvores de decisão podem ser empregadas para diversas análises, como para localização de anormalidades em linhas de transmissão e análise de saúde de transformadores de potência (BAGHERI, 2018; BELL, 2015).

3. MÉTODO DO ESTUDO

O propósito deste estudo tem como objetivo demonstrar um sistema de análise de disponibilidade técnica de Aerogeradores, utilizando métodos de inteligência artificial para a avaliação de seu desempenho em comparação com os resultados obtidos pelos métodos convencionais de disponibilidade técnica.

Trata-se de uma pesquisa do tipo aplicada e abordagem quantitativa, com o intuito de demonstrar a criação e a aplicação de um método destinado a elevação da eficácia e rastreabilidade de análise.

3.1 BASE DE DADOS

Os dados utilizados para este estudo foram subdivididos em dois tipos, de acordo com a formatação obtida, sendo os estruturados e os não estruturados.

Os dados não estruturados utilizados são obtidos dos relés do sistema de proteção e controle do respectivo parque, registros de manutenção de equipamentos da subestação e redes de média tensão, registros de restrições de geração do ONS, limitação de equipamento e relatórios de manutenção dos Aerogeradores.

Os dados estruturados aplicados são os dados coletados dos Aerogeradores através do sistema SCADA (Supervisory Control and Data Acquisition) e da base de falhas/alarmes dos Aerogeradores.

3.2 ESTUDO E ELABORAÇÃO DO MODELO

Para elaboração do modelo houve o estudo das variáveis dos respectivos sistemas do Aerogerador, como exemplo dados do Yaw, Sistema Meteorológico, Conversor, Gerador, Pitch, etc., que combinados ou não representassem um modelo para obtenção da disponibilidade ou indisponibilidade, tendo como base os valores medidos digitais e analógicos.

Este modelo também contempla a análise dos comportamentos dos Relés de Proteção do BoP (Balance of Plant), atividades de manutenção executadas, falhas ocorridas e informações adicionais específicas, resultando em um algoritmo robusto para a definição de um modelo secundário de definição de status do equipamento.

A medida que novos comportamentos são detectados o modelo é revisitado e ajustado, visando o processo de melhoria contínua.

As concepções advindas deste estudo são organizadas e priorizadas, aplicando o processo de classificação presente na estrutura do método de árvore de decisão, utilizado para a elaboração deste algoritmo de Machine Learning.

Estes comportamentos se balizam dentro das configurações e filosofias de projeto dos equipamentos, buscando avaliar qual seria o status deste, face às variáveis colhidas a cada instante de apuração.

Na figura 2 é demonstrado o fluxo do estudo e elaboração do modelo.




Figura 2: fluxo do estudo e elaboração do modelo. Fonte: O próprio autor, 2024.

3.3 FLUXO DO PROCESSO DE APURAÇÃO DE DISPONIBILIDADE TÉCNICA

Após a elaboração do modelo é iniciado o processo de execução de análise de disponibilidade, onde são confrontados os valores obtidos através da aplicação da metodologia conforme a IEC 61400-26-1 e o valor obtido pelo modelo de Machine Learning.




Figura 3: Fluxo do processo de apuração de disponibilidade técnica. Fonte: O próprio autor, 2024.

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

A implantação do modelo de Machine Learning no fluxo de validação de disponibilidade técnica proporciona uma métrica importante, pois oferece recursos para contrapor a veracidade dos dados registrados durante o período de apuração de maneira sistemática e rápida, face a execução de múltiplas indisponibilidades e ao grande volume de dados analisados para uma apuração eficaz e eficiente, identificando pontos de melhorias no processo, metodologias e em equipamentos.

A resposta positiva sobre este modelo foi a detecção de indisponibilidades não justificadas ou não registradas, causadas pelos itens apresentados abaixo:

- Anormalidades em lógicas de controle e ou monitoramento do Aerogerador.
- Ausência de registros de atividades de manutenção ou inspeção.
- Existência de eventos de indisponibilidade contabilizados em duplicidade, que representam apenas um intervalo de indisponibilidade efetivamente.
- Existência de eventos em paralelo, para o mesmo ativo no tempo, que representam apenas um intervalo de indisponibilidade efetivamente.
- Detecção de atrasos ou postergação de retorno de Aerogeradores após normalização do BoP, em casos de eventos de rede.
- Monitoramento de perdas de comunicação / dados.

Outro aspecto observado foi o ganho de eficiência no tratamento das responsabilidades para cada indisponibilidade, através da adição ao modelo de um sistema de julgamento que identifica a origem de cada evento, seja ela de origem do BoP, Aerogerador, externa ou específica (força maior, etc.).

No gráfico 1, é demonstrado o resultado da aplicação do modelo através do delta entre a disponibilidade técnica obtida pela aplicação da IEC 61400-26-1 (inicial) e o valor obtido pelo modelo de dados do estudo.




Gráfico 1: Delta entre o resultado do modelo e o cálculo inicial de disponibilidade técnica. Fonte: O próprio autor, 2024.

Conforme demonstrado no gráfico 1, é possível detectar o aprendizado dos envolvidos no processo, através da utilização do modelo, pois a partir da detecção das anomalias, que anteriormente não eram detectadas ou entendidas, medidas foram aplicadas para a melhoria dos processos, resultando em um ciclo evolutivo de melhoria.

Este efeito é observado pela aproximação do delta entre os métodos a partir do 13º mês de apuração deste estudo, conforme ilustrado nos gráficos 1 e 2.

Após os ajustes dos dados em cada mês de apuração é obtido o valor de disponibilidade técnica revisada.

No gráfico 2 é demonstrado o valor do delta entre o valor obtido pelo modelo e o valor revisado da disponibilidade técnica, conforme a IEC 61400-26-1.




Gráfico 2: Delta entre o resultado do modelo e o cálculo revisado de disponibilidade técnica. Fonte: O próprio autor, 2024.

Verifica-se que após o 13 mês de apuração, onde houve o início de aplicação dos métodos de cálculo e de melhoria, houve a redução do delta entre o método desenvolvido e o resultado de disponibilidade técnica revisada, comprovando a eficácia do modelo em monitorar os desvios da apuração e a eficácia das recomendações desenvolvidas e observadas durante o ciclo de apuração contemplado.

No gráfico 3 apresenta o delta entre o resultado do modelo e o cálculo revisado de disponibilidade técnica nos últimos 12 meses do estudo, representando assertividade superiores à 99%, face ao cenário obtido no estudo.




Gráfico 3: Delta entre o resultado do modelo e o cálculo revisado de disponibilidade técnica. Fonte: O próprio autor, 2024.

6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

A ciência de dados é uma área que apresenta grande potencial de evolução no mercado eólico, considerando o volume de dados coletados e o alto número de ativos em operação.

As filosofias de Gestão da Qualidade Total e Manutenção Produtiva Total comprovam que ambos os métodos destacam direta e indiretamente a relevância da disponibilidade do ativo como um pilar para o sucesso, demonstrando a necessidade de qualidade e acuracidade em seu cálculo.

Com a abordagem aplicada neste estudo, é evidente que a utilização de Inteligência Artificial para a execução de análises de múltiplos dados e suas correlações é uma alternativa muito atraente com base em seus resultados.

Em destaque ao resultado obtido, com a acurácia da disponibilidade e de suas responsabilidades, por se tratar de um parâmetro de entrada para outros cálculos, todos os produtos a partir desta análise se beneficiarão por ganhos reais na transparência e exatidão dos dados.

Através da utilização destas técnicas juntamente com os conhecimentos específicos sobre os equipamentos, foi possível desenvolver um sistema que permite o ganho de eficiência e eficácia na apuração da disponibilidade técnica de Aerogeradores, visando a redução do tempo de trabalho aplicado, a definição padronizada e lógica das responsabilidades, a confiabilidade dos dados e a rastreabilidade do processo.

REFERÊNCIAS

- NBR 5462: 1994. **Confiabilidade e Manutenibilidade**. Rio de Janeiro: Associação Brasileira De Normas Técnicas ABNT, 1994.
- EPE Empresa de Pesquisa Energética, **Empreendimentos eólicos ao fim da vida útil: Situação Atual e Alternativas Futuras**. N° EPE-DEE-NT-012/2021-r0. Brasília, DF, 2021.
- FIA Fundação Instituto de Administração, **O que é ciência de dados, o que faz o profissional e mercado de trabalho**, 2024. Disponível em: < <https://fia.com.br/blog/ciencia-de-dados-data-science/>>. Acesso em: 02/07/2024.
- CAO, L. **Data science and analytics: a new era**. International Journal of Data Science and Analytics, v. 1, n. 1, p. 1-2, 2016. Disponível em: <<https://link.springer.com/article/10.1007/s41060-016-0006-1>>. Acesso em: 05/07/2024.
- FUENTES, F. E. **Metodologia para inovação da gestão de manutenção industrial**. Florianópolis. Tese (Doutorado em Engenharia Mecânica), Universidade Federal de Santa Catarina, Florianópolis, 2006.
- IEC INTERNATIONAL ELECTROTECHNICAL COMMISSION. **61400-26-1 Technical Specification Wind Turbines**, p. 26-1: Time based availability for wind turbines, ed. 1, 2019.
- ARNOLD, J. R. T. **Administração de Materiais**. p. 528. ed. 1. São Paulo: Atlas. 2006.
- KAUR H., SINGH C., SINGH R., **Impingement of TPM and TQM on manufacturing performance**. Munich: BookRix GmbH & Co. KG, 2018.
- TAKAHASHI, Y; OSADA, T. **TPM/MPT – Manutenção Produtiva Total**. São Paulo: IMAM, 1993.
- CARRIJO, J.R.S. **Adaptações do modelo de referência do Total Productive Maintenance para empresas brasileiras**. Tese de doutorado. Universidade Metodista de Piracicaba. Piracicaba, SP, 2008.
- BOATENG, K.; AMISSAH M.; BOATENG, O. **Integrating total productive maintenance & total quality management: case study in pavement block industry**. International Journal of Research in Engineering and Technology, v. 5, p. 295-300, 2016.
- IBM International Business Machines Corporation. **O que é ciência de dados?**. s.d. Disponível em: <<https://www.ibm.com/br-pt/topics/data-science>>. Acesso em: 05/07/2024.
- BALAKRISHNA, S; THIRUMARAN, M; SOLANKI, V. **A Handbook of Internet of Things in Biomedical and Cyber Physical System: IoT Sensor Data Integration in Healthcare using Semantics and Machine Learning Approaches**, Intelligent Systems Reference Library, p. 275- 300, v. 165. Springer, Cham, 2019.
- FACELI, K. et al. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. p. 16-34 Rio de Janeiro: LTC, 2011.
- BELL, J. **Machine Learning: Hands-On For Developers and Technical Professionals**, Indianapolis: John Wiley & Sons Inc., 2015.
- BAGHERI, S; GHAREHPETIAN, G. B. **Classification and Discrimination Among Winding Mechanical Defects, Internal and External Electrical Faults, and Inrush Current of Transformer**, IEEE Transactions on Industrial Informatics, v. 14, n. 2, p. 484-493, 2018.

DEVELOPMENT OF A CLUSTERING METHODOLOGY FOR FLEET-WISE ANALYSIS IN WIND FARMS

Eugênio Pozzobon¹, Humberto Pinheiro¹,
Claiton Moro Franchi¹, Frederico Menine Schaf¹

¹Universidade Federal de Santa Maria (UFSM)

eugenio.pozzobon@acad.ufsm.br, humberto@ufsm.br, claiton@ufsm.br, frederico.schaf@ufsm.br

ABSTRACT

This paper presents a methodology for clustering turbines in a wind farm, providing a robust and interpretable tool for segregating turbines during fleet-wide performance monitoring, fault detection, and wake analysis. This methodology applies a hierarchical clustering algorithm to Supervisory Control and Data Acquisition (SCADA) data on a sector-specific and atmospheric stability basis. Sequentially, it computes statistical features from variables like wind speed and turbulence to represent the wind inflow behavior at each turbine. The results demonstrate that this method identifies physically meaningful and dynamic turbine clusters that directly correspond to aerodynamic interactions, such as wind shear and wake effects.

Keywords:

Wind Farm, Fleet-Wise Analysis, Clustering Algorithms

1. INTRODUCTION

The global shift towards renewable energy has established wind power as a critical component of sustainable energy systems [1]. As the number and size of wind farms increase, so does the complexity of their operation and the volume of data generated by their SCADA systems. In this context, maximizing energy yield and ensuring the longevity of these assets requires efficient management with data analysis.

In general, analyzing wind farms typically involves a fleet-wide comparison. However, large wind farms present challenges due to the extensive data involved. Complex terrain, intricate aerodynamic interactions between turbines, wake effects, and the unique microclimate experienced by each turbine further complicate these analyses.

To address these issues, data-driven approaches, particularly unsupervised machine learning algorithms, are recommended. Clustering algorithms are powerful tools that offer a robust method to group wind turbines that experience similar operational or environmental conditions. Identifying these homogeneous groups makes it easier to carry out targeted and meaningful performance analyses or fault detection, allowing for the identification of turbines that underperform compared to their peers [2].

Gaussian Mixture Models (GMMs) have been applied to create turbine clusters based on wind speed, particularly for the imputation of missing wind speed values [5]. The probabilistic nature of GMMs also makes them useful for modeling the distribution of wind resources across a wind farm, considering the

vertical variation of wind speed and direction with height [2]. Affinity Propagation has been used to discover turbine "neighbors" based on similarities in operational data, which can be valuable for tasks such as filling missing data or comparing the performance of neighboring turbines [4].

Additionally, hierarchical clustering was employed in [3] to extract wind turbine operation behavior patterns, facilitating a deeper understanding of turbine operation status and the identification of similar turbines. Additionally, research has demonstrated that wind forecasting based on clustered turbines yielded better accuracy compared to forecasts using a single representative turbine for the entire wind farm [4].

This paper presents a comprehensive methodology for wind farm clustering, identifying turbines with similar wind inflow conditions by applying hierarchical clustering to SCADA data, segmented by wind direction sectors and atmospheric stability. The methodology results are validated using geospatial data through a Digital Surface Model (DSM) and pywake simulations.

The remaining part of the paper is organized as follows. Section 2 details the SCADA and DSM data employed in this study. Section 3 provides a comparison of clustering techniques, justifying the use of the hierarchical approach. Section 4 outlines the complete methodology, from data pre-processing and feature selection to the application of the clustering algorithm. Finally, Sections 5 and 6 present the results and discuss conclusions and perspectives for future work.

2. WIND FARM DATA

The analysis presented in this paper is based on two primary sources of data: (i) operational data from the wind farm's SCADA system; and (ii) a DSM of the site and its surroundings. The integration of these datasets provides a comprehensive view of both the operational behavior of the turbines and the geospatial context in which they operate. In the following subsections, these two topics are addressed in detail.

2.1. SCADA Data

A wind turbine's SCADA system is an integrated hardware and software architecture designed for monitoring and control, forming the digital nervous system of the wind farm. These systems continuously collect and archive a wide array of parameters, which can be broadly categorized into environmental conditions, operational parameters, component-specific health parameters, and status logs [6].

The operational data for this study were collected from the Kelmarsh Wind Farm, which consists of six Senvion MM92 wind turbines. These turbines have a rated power of 2050 kW and a rotor diameter of 92 meters. The Wind Farm is located in the UK, and the dataset comprises 10-minute statistical intervals recorded over seven years (2016-2022) [7]. The key variables utilized from the SCADA records include:

- Environmental: Wind speed and Vane position, from multiple nacelle-mounted sensors.
- Operational: Active power, rotor speed, blade pitch angle, and temperature in multiple internal points, like: gearbox, generator, and transformer.
- Status: Operational status codes of each wind turbine.

2.2. Digital Surface Model

The Digital Surface Model provides a topographical model of the Earth's surface that includes the height of terrain as well as natural and man-made features such as vegetation and buildings [8]. A DSM was developed for the Kelmarsh farm to account for the influence of local topography and vegetation on wind flow.

The DSM was constructed by combining two distinct data sources. First, terrain elevation data was acquired from Mapbox Terrainium tiles, which encode global elevation data in RGB format. Second, canopy height data were obtained from a global canopy height model available on [9]. The final surface elevation model shown in Figure 1 was then produced by adding the canopy height layer of Figure 2 to the terrain elevation layer.




Figure 1: Kelmarsh Digital Surface Model with the Six Turbine Locations.




Figure 2: Canopy Height on the Site.

3. HIERARCHICAL CLUSTERING ALGORITHM

There are a variety of clustering algorithms that can be employed to group wind turbines based on similarities in their operational behavior, including K-means, DBSCAN, Gaussian Mixture Models (GMM), and Hierarchical Clustering.

One of the most common, K-means, is widely used due to its computational efficiency and interpretability. However, it requires the number of clusters to be specified beforehand and struggles with non-convex cluster shapes and varying densities, which can have limitations when analyzing complex wind farm data. Other methods, like DBSCAN, can identify arbitrarily shaped clusters and are robust to outliers, but are highly sensitive to model parameters that are difficult to determine for dynamic datasets. GMMs, on the other hand, are useful to understand the uncertainty of the results; however, they assume that the data follow Gaussian distributions, which may not always be the case, and do not work well on high-dimensional datasets [10]. Given these trade-offs, a hierarchical clustering approach was selected.

Hierarchical clustering builds a hierarchy of clusters without requiring a pre-defined number of groups, making it particularly suitable for exploratory data analysis. The methodology can be implemented using two main approaches: agglomerative (bottom-up) or divisive (top-down) [11]. This work uses the agglomerative approach, which begins by considering each turbine as a single cluster. Then, in successive steps, the two closest clusters are merged based on a defined similarity metric and linkage criterion until only a single cluster, containing all turbines, remains.

The choice of linkage criterion is critical as it defines how the distance between clusters is measured. This study employs Ward's method, a variance-minimizing approach. At each step, Ward's method merges the pair of clusters that leads to the minimum increase in the total within-cluster variance. This process naturally creates a tree-like structure known as a dendrogram, which visually represents the hierarchy of clusters and the order in which they are merged [11], as shown in Figure 2.




Figure 2 - Dendrogram example that identifies two clusters, where the orange contains D and E items, while the second cluster contains C, A, and B.

The primary advantage of hierarchical clustering for this application is that it does not necessitate an a priori decision on the number of clusters, and provides a simple and understandable output with the dendrogram [10]. This is crucial for analyzing wind farm performance, where the optimal number of turbine groups can change significantly with wind direction and atmospheric conditions. While computationally more intensive than K-means and sensitive to noise, its ability to reveal the inherent structure of the data makes it a superior choice for this analytical objective.

4. WIND FARM CLUSTERING METHODOLOGY

This methodology aims to identify and analyze clusters of wind turbines that demonstrate comparable wind inflow conditions. This is achieved by segregating data based on two key factors: wind direction sector and atmospheric stability.

Initially, using discrete 15-degree wind direction sectors enables a dynamic, direction-dependent analysis of turbine inter-relationships and wake effects. Secondly, recognizing the potential impact of wind shear and veer on wind turbine inflow conditions [12], data segmentation by atmospheric stability is also incorporated.

However, accurate identification of atmospheric conditions needs specific data, which was unavailable in the considered dataset. While computing the wind shear coefficient from a met mast with multiple height anemometers is a potential solution, its reliability is compromised under certain conditions, such as low-level jets. Furthermore, many wind farms, including Kelmarsh, lack met masts. To overcome this, the hierarchical clustering algorithm was applied separately to the daytime and nighttime portions of the dataset for each wind direction sector. This approach accounts for the strong correlation between the sun path and atmospheric stability, as the atmospheric boundary layer is primarily influenced by the magnitude and duration of solar radiation, varying with season [13].

In this way, two steps need to be addressed: how to pre-process the data and how to select the clustering features. These steps are detailed in the following subsections.

4.1. Data Pre-Processing

A robust and systematic data pre-processing pipeline is essential for a successful SCADA data analysis project. This process converts raw data into a clean, structured format, thereby ensuring the validity of the final results. For this study, the pre-processing steps, depicted in Figure 3, are tailored to isolate environmental conditions and filter out undesirable data.




Figure 3 - Pipeline to process the SCADA data before clustering the wind turbines.

As illustrated in the flowchart, the initial phase involves distinguishing between daytime and nighttime intervals. This was accomplished by employing Python's 'PVlib' library [14] to compute the solar position based on the wind farm's geographical coordinates. Furthermore, timestamps where any turbine was unavailable or under curtailment were excluded, as these states cause the wind farm's operational dynamics to deviate from normal.

Given that the nacelle sensors may malfunction or necessitate calibrations, leading to deviations in SCADA data, a yearly segmentation of the data can be employed. A yearly period is optimal once it enables the algorithm to cluster the farm while accommodating seasonal patterns.

After the filtering stages, the dataset underwent segmentation. The data is partitioned into 24 sectors, each encompassing 15 degrees and covering the entire 360-degree range. Further segmentation is applied based on day/night cycles and by year, yielding 48 datasets per year and 336 datasets for the entire farm data period.

4.2. Feature Selection

Wind features, which characterize the wind inflow at each turbine, are computed for each segmented dataset. These features are derived from time-series data of nacelle wind speed and turbulence intensity. Turbulence intensity (TI) is calculated using Equation (1), based on the mean (U) and standard deviation of 10-minute SCADA wind speed data.

$$TI = \frac{\sigma U}{U} \quad (1)$$

To transform the time-series data within each sector into a static representation suitable for clustering, a set of statistical metrics is calculated for each of the base features for every turbine. These metrics are the 25th (Q1), 50th (median), and 75th (Q3) percentiles.

This approach captures the wind speed and turbulence distribution, providing a more comprehensive signature of each turbine's wind inflow condition. These metrics are computed for each wind turbine in the dataset.

4.3. Final steps

Before applying the clustering algorithm, the resulting feature matrix undergoes a scaling step [15]. This is essential to prevent features with naturally larger magnitudes from disproportionately influencing the distance calculations in the clustering algorithm. The final output of this stage is a scaled feature matrix, which serves as the direct input for the hierarchical clustering algorithm.

5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

A PyWake simulation was used to validate the clustering results. PyWake is an open-source wind farm simulation tool that can compute flow fields. In this tool, turbines were set up with their hub height considering each turbine's elevation. However, PyWake does not account for terrain data, only turbine positions on a flat terrain. While this limitation restricts the analysis, it still enables visual verification of each sector's wake.

In this section, the results presented encompass the 48 clusters built within the 2018 period. Among these clusters, the clustering algorithm effectively distinguishes downstream and upstream turbines in simple cases, such as Sector 1 shown in Figure 4, where the wind direction is between 0 and 15 degrees.




Figure 4 - Sector 1: (a) PyWake simulation result with the wind direction of 7 degrees and (b) cluster methodology result with two separated clusters, where the blue one has just turbine T4, while the orange one aggregates all turbines, which are not behind any obstacle.

Furthermore, more complex scenarios, influenced by terrain, vegetation, and atmospheric stability, are challenging to analyze solely through Pywake simulations, although they remain plausible. Figure 6 illustrates sector 4 (45 to 60 degrees), where turbines T4 and T6 form a single cluster, as shown in the daily and nightly period dendrogram on Figure 5-b.




Figure 5 - Sector 4: (a) PyWake simulation result with the wind direction of 52 degrees and (b) Same cluster results for the daily dataset and the nightly dataset, where the cluster with T4 and T6 aggregates upstream and downstream turbines.

As illustrated in Figure 5-b, the disparity in the correlation between T6 and T4 is notably more pronounced during nocturnal hours compared to daytime periods. This aligns with expectations, as wind speeds at T6 are typically lower than at T4 due to the generally more aggressive wind shear prevalent under stable nighttime conditions. Conversely, during the day, convective regimes and heightened turbulence lead to a reduced difference in wind speed measurements between T6 and T4. Furthermore, while wake effects might influence T4, the differing hub heights of T4 and T6 can mitigate this impact. Therefore, although wind shear suggests higher wind speeds at T4 compared to T6, the wake effect provides a counterbalance. Additionally, vegetation positioned in front of T6 in this sector may influence turbulence intensity. Consequently, while T4 is anticipated to exhibit higher turbulence, T6 may also experience turbulent wind conditions due to near-surface roughness.

On the other hand, it is important to note that turbines T2 and T1 are very close to being directly downstream of turbines T3 and T5, respectively. However, the current clustering methodology does not capture this. A possible reason for this oversight is that the methodology relies solely on nacelle anemometer data, which does not accurately represent the wind conditions across the entire rotor area.

Finally, a notable wake scenario arises from two downstream turbines positioned behind a single upstream turbine. Specifically, in Sector 21 shown in Figure 5, turbine T4 is situated downstream of T1, which is itself downstream of T2. Similarly, T6 is positioned downstream of T5, which is downstream of T3. It is noteworthy that both clustered T5 and T6 differ from the others in the nightly dendrogram.




Figure 5 - Sector 21: (a) PyWake simulation result with the wind direction of 307 degrees and (b) results that are different based on the day and nightly datasets.

In this case, the clustering algorithm was unable to identify meaningful groups. However, such issues can be dynamically detected using the Silhouette Index and the Cophenetic Correlation Coefficient (CCI). The Silhouette Index assesses the separation between clusters, with values above 0.5 indicating well-defined groupings. The CCI evaluates how accurately hierarchical clustering reflects the original pairwise distances, with values below 0.7 suggesting a poor fit [17]. Table 1 presents these metrics for the clusters discussed in this section, highlighting that both indices indicate issues with the clustering of sector 21. Out of the 48 clusters generated from the 2018 dataset, only five showed suboptimal performance based on these criteria.

Table 1 - índices to evaluate the cluster results.

Sector	Period	Silhouette	CCI
1: [0°, 15°)	Day	0.64	0.99
1: [0°, 15°)	Night	0.75	0.99
4: [45°, 60°)	Day	0.75	0.95
4: [45°, 60°)	Night	0.73	0.92
21: [300°, 315°)	Day	0.50	0.69
21: [300°, 315°)	Night	0.44	0.67

6. CONCLUSION

This paper has presented a promising data-driven methodology for clustering wind farm turbines into small fleets, providing robustness to fleet-wide performance analysis. The core innovation of this approach lies in its sector-specific analysis, where turbines are clustered independently for discrete wind direction intervals. By extracting features that represent the statistical distribution of wind inflow, using variables such as wind speed and turbulence for each turbine, the methodology efficiently condenses complex time-series data into a representative signature for clustering.

The results indicate that the proposed approach effectively identifies physically meaningful turbine groupings that align with aerodynamic interactions, such as wake effects. However, while the methodology accounts for atmospheric stability conditions and terrain influences, further validation is necessary to confirm its robustness.

Therefore, this framework offers multiple possibilities for future work and enhancement. First, the impact of terrain effects could be validated by comparing results with simulation tools such as WAsP, which can also be integrated with PyWake simulations.

Additionally, for larger and more complex wind farms, especially those with significant variations in topography, the current feature set could be augmented by including explicit geospatial data such as turbine hub height, latitude, and longitude. While operational data similarity is a powerful proxy for grouping, the inclusion of fixed geographical features could help the algorithm better distinguish clusters in vast arrays where atmospheric conditions may not be uniform, providing a more robust analysis for huge wind farms.

Finally, this clustering method provides a contextualized, direction-specific baseline for various SCADA-based algorithms. It enables sensor error detection and performance analysis by comparing turbines within their respective peers. Essentially, this sector-specific hierarchical clustering offers a nuanced and interpretable framework for understanding wind farm turbine relationships, serving as a granular, actionable tool for operators to detect anomalies and enhance wind farm efficiency and reliability.

REFERENCES

- [1] MA, K. et al. Research on Evaluation Method of Wind Farm Wake Energy Efficiency Loss Based on SCADA Data Analysis. **Sustainability**, Basel, v. 16, n. 5, p. 1813, 2024. Disponível em: <https://doi.org/10.3390/su16051813>. Acesso em: 15 set. 2025.
- [2] SALCEDO-SANZ, S. et al. Clustering of Wind Speed Time Series as a Tool for Wind Farm Diagnosis. **Eng**, Basel, v. 2, n. 4, p. 556-571, 2021. Disponível em: <https://doi.org/10.3390/eng2040035>. Acesso em: 14 abr. 2025.
- [3] MARTI-PUIG, P.; NÚÑEZ-VILAPLANA, C. Dynamic Clustering of Wind Turbines Using SCADA Signal Analysis. **Energies**, Basel, v. 17, n. 11, p. 2514, 2024. Disponível em: <https://doi.org/10.3390/en17112514>. Acesso em: 15 set. 2025.
- [4] LIU, Y. et al. Clustering methods of wind turbines and its application in short-term wind power forecasts. **Journal of Renewable and Sustainable Energy**, Melville, NY, v. 6, n. 5, p. 053133, 2014. Disponível em: <https://doi.org/10.1063/1.4898361>. Acesso em: 15 set. 2025.
- [5] WU, W. et al. Analysis of Wind Turbine Operation Behavior Based on Clustering Algorithm. *In*: INTERNATIONAL CONFERENCE ON POWER, ENERGY AND ELECTRICAL ENGINEERING (PEEE), 2., 2024, Wuhan. **Proceedings [...]**. Singapura: Springer, 2024.
- [6] MEYER, A. SCADA-based fault detection in wind turbines. *In*: YE, Z.-S.; LIU, W.-M. (ed.). **Wind Turbine Fault Diagnosis**. Amsterdam: Elsevier, 2023. p. 45-70.
- [7] PLUMLEY, C. **Kelmarsh wind farm data (0.0.3)**. [S. l.]: Zenodo, 2022. Dataset. Disponível em: <https://doi.org/10.5281/zenodo.5841834>. Acesso em: 15 set. 2025.
- [8] ZHOU, Q. Digital elevation model and digital surface model. *In*: RICHARDSON, D. et al. (ed.). **International encyclopedia of geography: People, the earth, environment and technology**. Malden, MA: Wiley-Blackwell, 2017. p. 1-17.
- [9] META; WORLD RESOURCES INSTITUTE. **High Resolution Canopy Height Maps (CHM)**. 2024. Disponível em: <https://registry.opendata.aws/dataforgood-fb-forests>. Acesso em: 15 set. 2025.
- [10] GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. Sebastopol: O'Reilly Media, Inc., 2022.
- [11] MURTAGH, F.; CONTRERAS, P. Algorithms for hierarchical clustering: an overview, II. **WIREs Data Mining and Knowledge Discovery**, Hoboken, v. 7, n. 6, p. e1219, 2017. Disponível em: <https://doi.org/10.1002/widm.1219>. Acesso em: 15 set. 2025.

- [12] LUNDQUIST, J. K. Wind shear and wind veer effects on wind turbines. *In*: HANSEN, M. O. L. (ed.). **Handbook of wind energy aerodynamics**. Cham: Springer International Publishing, 2022. p. 1-22.
- [13] WAGNER, R. **Accounting for the speed shear in wind turbine power performance measurement**. 2010. Tese (Doutorado) – Risø National Laboratory for Sustainable Energy, Technical University of Denmark, Roskilde, 2010.
- [14] ANDERSON, K. et al. pvlib python: 2023 project update. **Journal of Open Source Software**, v. 8, n. 92, p. 5994, 2023. Disponível em: <https://doi.org/10.21105/joss.05994>. Acesso em: 15 set. 2025.
- [15] PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **The Journal of Machine Learning Research**, Cambridge, MA, v. 12, p. 2825-2830, 2011.
- [16] PEDERSEN, M. M. et al. **PyWake 2.5.0: An open-source wind farm simulation tool**. Roskilde: DTU Wind, Technical University of Denmark, 2023.
- [17] SOKAL, R. R.; ROHLF, F. J. The comparison of dendrograms by objective methods. **Taxon**, Utrecht, v. 11, n. 2, p. 33–40, 1962.

Inspeção automatizada de torres eólicas: voos automatizados e inteligência artificial na detecção de anomalias

Karem Marcomini, Pablo L. Lima, Carlos Dietrich, Fabio Grubert, Guilherme S. Lacerda, Juliano Souza, Leonardo Menezes, Luciane Calabria, Marcelo B. Capeletti, Pablo Barcellos, Ronald M. Sampaio

Pix Force

luciane.calabria@pixforce.ai

RESUMO

A energia eólica representa uma fonte renovável promissora, mas a operação em ambientes adversos e com altas cargas operacionais pode causar danos aos aerogeradores, comprometendo a eficiência do sistema. O monitoramento periódico é essencial, mas as inspeções tradicionais exigem parada das turbinas, gerando custos elevados. Neste contexto, os drones emergem como alternativa, reduzindo o tempo de inatividade. Embora os drones capturem dados de alta resolução, o grande volume de imagens representa um desafio para o processamento manual. Por isso, redes neurais artificiais têm sido utilizadas para automatizar esse processo. Este trabalho propõe a análise da viabilidade técnica da inspeção automatizada de torres eólicas utilizando voos automatizados e inteligência artificial para a detecção de anomalias. Os resultados, utilizando a YOLO11N mostram-se promissores na classificação de defeitos, principalmente para a detecção de erosão na borda de ataque e corrosão. As métricas de avaliação - acurácia, precisão, recall e F1-Score - para os melhores cenários variaram entre 86,4% e 89,6%. A viabilidade técnica da solução proposta foi comprovada, destacando-se a importância da qualidade e consistência das anotações do dataset para o sucesso do modelo de detecção.

Palavras-chaves:

Inspeção automatizada; Drones; Inteligência artificial; Visão computacional.

ABSTRACT

Wind energy represents a promising renewable source; however, operation in adverse environments with high operational loads can cause damage to wind turbines, compromising system efficiency. Periodic monitoring is essential, but traditional inspections require turbine shutdown, generating high costs. In this context, drones emerge as an alternative, reducing downtime. Although drones capture high-resolution data, the large volume of images represents a challenge for manual processing. Therefore, artificial neural networks have been used to automate this process. This work proposes analyzing the technical feasibility of automated wind tower inspection using automated flights and artificial intelligence for anomaly detection. The results, using YOLO11N, show promise in defect classification, particularly for detecting leading-edge erosion and corrosion. The evaluation metrics - accuracy, precision, recall, and F1-Score - for the best scenarios ranged between 86.4% and 89.6%. The technical feasibility of the proposed solution was demonstrated, highlighting the importance of dataset annotation quality and consistency for the successful operation of the detection model.

Keywords:

Automated inspection; Drones; Artificial intelligence; Computer vision.

1. INTRODUÇÃO

A energia eólica é uma forte concorrente entre as fontes de energia renovável. Para aumentar a capacidade de geração de energia elétrica, as turbinas eólicas e as estruturas de sustentação têm se tornado fisicamente maiores. Como consequência, aumentam os riscos de danos e a necessidade de atenção constante aos custos de operação e manutenção (O&M) (Reddy et al., 2019).

As turbinas eólicas geralmente operam em ambientes adversos, expostas por longos períodos ao vento, frio extremo, areia, névoa salina e outras intempéries. Além disso, as pás estão sujeitas a altas cargas operacionais que, somadas às condições ambientais críticas, tornam-as mais suscetíveis a falhas (Zhang; Wen; Liu, 2020). Como resultado, pode-se ter danos às camadas de fibra, perda da pintura e do revestimento, aparecimento de rachaduras e buracos, corrosão e oxidação das superfícies, etc. Tais problemas podem afetar severamente a estrutura e, consequentemente, a eficiência das turbinas eólicas, implicando em desafios significativos para a sua manutenção (Yu et al., 2025).

Para realizar o planejamento adequado das atividades de O&M, é essencial monitorar periodicamente as condições das turbinas, a fim de verificar possíveis mudanças nas características de suas superfícies ao longo do tempo. Assim que um dano é identificado, os reparos devem ser realizados o quanto antes, visando evitar seu agravamento e danos adicionais (Sheiati et al, 2024). No entanto, o processo de inspeção das turbinas costuma estar associado a custos extras, especialmente porque elas precisam ser paradas durante a verificação, interrompendo a geração de energia elétrica. Por isso, a inspeção de danos em pás de aerogeradores sem interromper sua operação normal possui elevado valor econômico (Chen, 2023).

A detecção e análise pontuais de defeitos nas pás das turbinas aumenta sua vida útil e a confiabilidade do sistema, uma vez que repara os danos antes que estes se agravem. Além disso, a realização da manutenção preventiva adequada permite minimizar o tempo de inatividade da turbina. Recentemente, drones equipados com câmeras e sensores têm sido utilizados para a inspeção das pás, o que pode reduzir drasticamente o tempo de inatividade da turbina de 1,5 h (com escaladores e telescópio) para cerca de 20 minutos (Rizvi; Jamil; Huang, 2024).

A inspeção das pás com o uso de drones é um processo automático (ou semi-automático) para capturar dados de alta resolução (principalmente sequências de imagens) (Rizvi; Jamil; Huang, 2024). No entanto, a grande quantidade de imagens e dados gerados representa um desafio para o processamento manual, levando a resultados lentos e potencialmente imprecisos. Vários estudos na área de monitoramento estrutural, particularmente para pás de turbinas eólicas, têm automatizado com sucesso o processo de inspeção utilizando redes neurais artificiais, combinadas com inspeções reais realizadas por drones ou condições que simulam essas inspeções (Sheiati et al, 2024).

Neste contexto, o objetivo deste trabalho é analisar a viabilidade técnica da inspeção das torres eólicas, utilizando voos automatizados e inteligência artificial para a detecção de anomalias nas superfícies dos aerogeradores.

2. METODOLOGIA

Para realizar a inspeção automatizada das torres eólicas, criou-se um dataset com imagens próprias (obtidas em visita a um parque eólico) e datasets públicos (Yang et al., 2023, Nikolov; Madsen, 2020, Nikolov et al. 2020, Yu et al. 2017, Shihavuddin et al., 2019, Shihavuddin et al., 2020, Shihavuddin; Chen, 2018, Wang et al., 2019, Zhang; Cosma; Watkins, 2021, Denhof et al., 2019, Yang et al., 2021, Wang, Zhang, 2017, Xu; Wen; Liu, 2019, Zhang; Wen; Liu, 2020, Reddy et al., 2019). As imagens foram anotadas, indicando as classes de interesse: dano no revestimento, corrosão, trinca/rachadura, erosão na borda, queimado e vazamento de óleo. O dataset anotado foi utilizado para o treinamento da rede neural profunda YOLOv11.

2.1. DATASET

A criação do dataset envolveu a coleta de vídeos e imagens em um parque eólico *onshore* no Brasil e dados disponíveis em datasets públicos (Yang et al., 2023, Nikolov; Madsen, 2020, Nikolov et al. 2020, Yu et al. 2017, Shihavuddin et al., 2019, Shihavuddin et al., 2020, Shihavuddin; Chen, 2018, Wang et al., 2019, Zhang; Cosma; Watkins, 2021, Denhof et al., 2019, Yang et al., 2021, Wang, Zhang, 2017, Xu; Wen; Liu, 2019, Zhang; Wen; Liu, 2020, Reddy et al., 2019). Foram utilizadas 783 imagens próprias e 1568 imagens provenientes dos datasets públicos, totalizando 2351 imagens no dataset.


O drone DJI Mavic 3T, equipado com três tipos de câmeras (RGB, termal e teleobjetiva com zoom de 7x) foi utilizado para a aquisição das imagens e vídeos. A inspeção das torres foi realizada com as turbinas desligadas, a fim de garantir a qualidade das imagens capturadas (Figura 1).

Figura 1 - Posição de parada das pás para realização de inspeção.



Os voos aconteceram a uma distância de aproximadamente 14 m das torres, utilizando o aplicativo Pix Flight para a determinação de rotas automatizadas e padronizadas. Desta forma, não há necessidade de interferência humana, aumentando a segurança do processo. A Figura 2 apresenta a visão do aplicativo durante a inspeção de uma pá do aerogerador.


Figura 2 - Demonstração de parte da inspeção de uma pá do aerogerador.



Durante a inspeção, o drone seguiu uma rota padronizada ao longo de toda a extensão de cada uma das três pás dos aerogeradores. Com isso, foram coletadas imagens de alta qualidade de cada uma das faces das pás (Figura 3), que são:

- Bordo de Ataque (*Leading Edge*): Parte frontal da pá, onde o fluxo de ar é interceptado, ou seja, o escoamento do ar através da pá se inicia nesse ponto;
- Bordo de Fuga (*Trailing Edge*): Toda parte traseira da pá. É onde o fluxo de ar se desprende, ou seja, o escoamento do ar através da pá termina nesse ponto;
- Intradorso: Face interna da pá, também conhecida como lado de pressão por concentrar maior pressão estática durante o escoamento de fluidos;
- Extradorso: Face externa da pá (mais próxima da torre), também conhecida como lado de sucção, devido à menor pressão estática (e maior pressão dinâmica) durante o escoamento de fluidos.

Figura 3 - Faces de uma pá eólica.



2.2. CLASSIFICAÇÃO DE DEFEITOS

As imagens capturadas e obtidas nos datasets públicos foram analisadas em busca de anomalias e anotadas conforme o tipo de defeito encontrado (exemplos na Figura 4). Foram determinadas seis classes de interesse: *burnt* (queimado), *coating damage* (dano no revestimento), *corrosion* (corrosão), *crack* (trinca/rachadura), *leading edge erosion* (erosão na borda de ataque) e *oil leakage* (vazamento de óleo).

Figura 4 - Imagens provenientes dos datasets públicos com anotações das classes “*coating damage*” e “*crack*”.



O modelo de redes neurais profundas YOLOv11 foi utilizado para realizar a análise de classificação, usando 80% do dataset para treinamento e 20% para validação. Foram testados diferentes tamanhos de rede: nano (N), pequeno (S), médio (M), grande (L) e extra grande (X). A análise procedeu em duas etapas. A primeira etapa aconteceu com o uso do dataset original. Em seguida, o dataset foi modificado, corrigindo a anotação de algumas imagens. A Tabela 1 mostra a quantidade de ocorrências de cada classe nos dois datasets.

Tabela 1 - Quantidade de anotações por classe nos dois datasets.

Classe	Dataset original	Dataset modificado
<i>burnt</i>	75	76
<i>coating damage</i>	49	26
<i>corrosion</i>	106	95
<i>crack</i>	78	62
<i>leading edge erosion</i>	64	111
<i>oil leakage</i>	45	49
Total de anotações	417	419


3. RESULTADOS

A rede neural apresentou bom desempenho geral, sendo capaz de identificar anomalias nas imagens do dataset de validação. No entanto, entre os tamanhos de rede estudados, o modelo YOLO11N apresentou métricas de desempenho superiores para os testes com os dois datasets, conforme mostra a Tabela 2.

Tabela 2 - Resultado dos testes com a YOLO para os dois datasets.

Dataset original					
Modelo	Acurácia	Precisão	Recall	F1-Score	Tempo de inferência
YOLO11N	0,895	0,896	0,895	0,895	0,76ms
YOLO11S	0,895	0,896	0,895	0,895	0,71ms
YOLO11M	0,871	0,875	0,871	0,871	2,06ms
YOLO11L	0,885	0,891	0,885	0,885	2,67ms
YOLO11X	0,875	0,878	0,875	0,875	5,62ms
Dataset modificado					
YOLO11N	0,864	0,869	0,864	0,864	0,29ms
YOLO11S	0,857	0,860	0,857	0,858	0,71ms
YOLO11M	0,845	0,848	0,845	0,846	1,96ms
YOLO11L	0,852	0,852	0,852	0,852	2,43ms
YOLO11X	0,857	0,860	0,857	0,858	5,14ms


Na Figura 5, é possível observar alguns resultados de detecção feitos pela YOLO11N. Em a e b, respectivamente, a rede identificou a presença de danos no revestimento e trincas/rachaduras. Em c, múltiplas anomalias foram detectadas.

Figura 5 - Detecção das classes (a) *coating damage*, (b) *crack*, (c) *oil leakage*, *corrosion* e *burnt* pela YOLO11N.


Além de vazamentos de óleo e queimadura, a rede identificou (na Figura 5) como corrosão um caso típico de "corrosão por arraste" ou "contaminação superficial". Neste caso, não há corrosão propriamente dita na superfície externa, mas sim um resíduo proveniente do interior do sistema (óleo, água contaminada, partículas metálicas) que escorre e deixa marcas com aspecto visual semelhante à corrosão.


A Figura 6 mostra a matriz de confusão referente ao uso da YOLO11N com o dataset original. As linhas da matriz representam a classificação correta, enquanto as colunas indicam a predição feita pelo modelo. É possível observar o bom desempenho do modelo em relação às classes "corrosion" (101 classificações corretas, 6 falsos positivos e 5 falsos negativos) e "leading edge erosion" (62 classificações corretas, 2 falsos positivos e 2 falsos negativos). No entanto, houveram equívocos principalmente com as classes "coating damage" e "oil leakage", com 11 amostras de "coating damage" classificadas como "crack" e 6 amostras de "oil leakage" classificadas como "corrosion".

Figura 6 - Matriz de confusão dos resultados da YOLO11N com o dataset original.




O resultado da matriz de confusão usando o dataset modificado pode ser visto na Figura 7. A classificação de "leading edge erosion" apresentou o melhor resultado, com 104 classificações corretas e 7 falsos negativos. A classe "corrosion" apresentou bom desempenho, com 85 amostras corretamente classificadas, mas houve a ocorrência de 10 amostras classificadas erroneamente como "oil leakage". A classe "burnt" teve 64 classificações corretas, mas apresentou alguma confusão com outras classes, especialmente com a classe "crack" (6 dos 12 falsos negativos). Similarmente, a classe "crack" apresentou confusão notável com 7 amostras classificadas como "leading edge erosion" e 4 como "burnt".

Figura 7 - Matriz de confusão dos resultados da YOLO11N com o dataset modificado.




Na Figura 8, é possível observar a taxa de erro por classe para cada um dos datasets. Nos dois casos, a classe com maior ocorrência de erros foi “*coating damage*”. Verifica-se que, mesmo com a correção das anotações, a taxa de erro por classe foi maior no dataset modificado, com exceção da classe “*oil leakage*”.

Figura 8 - Comparação da taxa de erro por classe nos datasets.



De forma semelhante, a confusão mútua entre pares (Figura 9) aumentou com o uso do dataset modificado, com exceção do par “*coating damage*” e “*crack*”, que diminuiu significativamente. Este pode ser um indicativo de que houveram erros no processo de anotação, confundindo o modelo. Além disso, defeitos visualmente semelhantes, como “*corrosion*” e “*oil leakage*” podem não ser identificados pela rede apenas com a foto RGB. Neste caso, seria necessário utilizar imagens térmicas, pois a análise RGB não permite distinguir óleo contaminado (que pode ter um brilho característico) de corrosão real, que teria uma superfície rugosa oxidada.

Figura 9 - Confusão mútua entre pares de classes nos dois datasets.



4. CONSIDERAÇÕES FINAIS

Este trabalho apresentou os resultados da inspeção automatizada de torres eólicas, utilizando inteligência artificial para a detecção de anomalias nas superfícies dos aerogeradores. Foram utilizados dados coletados em campo e datasets públicos para a criação do banco de imagens. Após serem anotadas com as classes de interesse (*coating damage*, *burnt*, *oil leakage*, *crack*, *corrosion* e *leading edge erosion*), as imagens foram usadas para o treinamento e validação de uma rede neural.

A rede YOLOv11 foi selecionada para a classificação das imagens, e foram realizados testes com diferentes tamanhos da rede. De forma geral, a rede apresentou bom desempenho, mas a versão YOLO11N atingiu melhores resultados. No teste realizado com o dataset original, as métricas de avaliação (acurácia, precisão, recall e F1-Score) foram de 89,5%, com tempo de inferência de 0,79 ms. O segundo teste, realizado com o dataset modificado, apresentou métricas de avaliação ligeiramente menores (86,4%), mas com tempo de inferência reduzido para 0,29 ms. Com base nesses resultados, conclui-se que a YOLO11N é a versão mais indicada para aplicações práticas de inspeção de torres eólicas devido à sua combinação de boa acurácia e baixa latência, permitindo implementação em cenários de análise em tempo real. Contudo, a ocorrência de confusões entre classes visualmente semelhantes reforça a importância de: ampliar e balancear o dataset, melhorar a qualidade das anotações e considerar abordagens de pré ou pós-processamento para melhor distinção de defeitos com padrões visuais próximos.

A pesquisa demonstra que a inspeção automatizada por drones é viável tecnicamente, mas a qualidade e a consistência das anotações do dataset são fatores críticos para o sucesso do modelo de detecção. Neste sentido, a continuidade da pesquisa se dará com o refinamento do processo de anotação, a fim de que os

resultados sejam ainda mais promissores, contribuindo para a otimização do processo de manutenção dos parques eólicos.

Agradecimentos

Este trabalho foi financiado pela Financiadora de Estudos e Projetos (FINEP).

REFERÊNCIAS

CHEN, X. Drone-based optical and thermal videos of rotor blades taken in normal wind turbine operation. **IEEE Data Port**, 2023.

DENHOF, Dimitri; STAAR, Benjamin; LÜTJEN, Michael; FREITAG, Michael, Automatic optical surface inspection of wind turbine rotor blades using convolutional neural networks. **Procedia CIRP**, v. 81, p. 1166-1170, 2019.

NIKOLOV, Ivan; MADSEN, Claus, "Wind Turbine Blade SfM Image Capturing Setups", **Mendeley Data**, V1, 2020. doi: 10.17632/fptxw8cynv.1

NIKOLOV, Ivan; NIELSEN, Mikkel; GARNÆS, Jørgen; MADSEN, Claus, "Wind Turbine Blade Surfaces Dataset", **Mendeley Data**, V1, 2020. doi: 10.17632/jrmm82m4mv.1

REDDY, Abhishek; INDRAGANDHI, V.; RAVI, Logesh; SUBRAMANIASWAMY, V., Detection of Cracks and damage in wind turbine blades using artificial intelligence-based image analytics. **Measurement**, v. 147, p. 106823, 2019.

RIZVI, Syed Zeeshan; JAMIL, Mohsin; HUANG, Weimin. Enhanced defect detection on wind turbine blades using binary segmentation masks and YOLO. **Computers and Electrical Engineering**, v. 120, p. 109615, 2024.

SHEIATI, Shohreh; JIA, Xiaodong; MCGUGAN, Malcolm; BRANNER, Kim; CHEN, Xiao, Artificial intelligence-based blade identification in operational wind turbines through similarity analysis aided drone inspection. **Engineering Applications of Artificial Intelligence**, v. 137, p. 109234, 2024.

SHIHAVUDDIN, A. S. M.; CHEN, Xiao, "DTU - Drone inspection images of wind turbine", **Mendeley Data**, V2, 2018, doi: 10.17632/hd96prn3nc.2.

SHIHAVUDDIN, A. S. M.; CHEN, Xiao; FEDOROV, Vladimir; CHRISTENSEN, Anders N.; RIIS, Nicolai A. B.; BRANNER, Kim; DAHL, Anders B.; PAULSEN, Rasmus R. Wind turbine surface damage detection by deep learning aided drone inspection analysis. **Energies**, v. 12, n. 4, p. 676, 2019.

SHIHAVUDDIN, A. S. M.; RASHID, Mohammad Rifat Ahmmad; CHEN, Xiao; MARUF, Md Hasan; HAQ, Mohammad Asif UL; HASAN, Muhammad Abul; MANSUR, Ahmed Al, Replication Data for Remote Damage Detection of Power Plants using Deep Learning based drone image analysis, **Harvard Dataverse**, V1, 2020,

WANG, Yinan, YOSHIHASHI, Ryota; KAWAKAMI, Rei; YOU, Shaodi; HARANO, Tohru; ITO, Masahiko, KOMAGOME, Katsura; Iida, Makoto; NAEMURA, Takeshi, Unsupervised anomaly detection with compact deep features for wind turbine blade images taken by a drone. **IPSN Transactions on Computer Vision and Applications**, v. 11, n. 1, p. 3, 2019.

WANG, Long; ZHANG, Zijun. Automatic detection of wind turbine blade surface cracks based on UAV-taken images. **IEEE Transactions on Industrial Electronics**, v. 64, n. 9, p. 7293-7303, 2017.

XU, Donghua; WEN, Chuanbo; LIU, Jihui. Wind turbine blade surface inspection based on deep learning and UAV-taken images. **Journal of Renewable and Sustainable Energy**, v. 11, n. 5, 2019.

YU, Xiaoyan; YAN, Peng; ZHENG, Shaokai; DU, Qinghan; WANG, Daolei, YOLOv8-WTDD: multi-scale defect detection algorithm for wind turbines. **The Journal of Supercomputing**, v. 81, n. 1, p. 32, 2025.

YANG, Cong; LIU, Xun; ZHOU, Hua; KE, Yan; SEE, John, Towards accurate image stitching for drone-based wind turbine blade inspection. **Renewable Energy**, v. 203, p. 267-279, 2023.

YANG, Xiyun; ZHANG, Yanfeng; LV, Wei; WANG, Dong, Image recognition of wind turbine blade damage based on a deep learning model with transfer learning and an ensemble learning classifier. **Renewable Energy**, v. 163, p. 386-397, 2021.

YU, Yajie; CAO, Hui; LIU, Shang; YANG, Shuo; BAI, Ruixian, Image-based damage recognition of wind turbine blades. In: **2017 2nd International Conference on Advanced Robotics and Mechatronics (ICARM)**. IEEE, 2017. p. 161-166.

ZHANG, Chao; WEN, Chuanbo; LIU, Jihui. Mask-MRNet: A deep neural network for wind turbine blade fault detection. **Journal of Renewable and Sustainable Energy**, v. 12, n. 5, 2020.

ZHANG, Jiajun; COSMA, Georgina; WATKINS, Jason. Image enhanced mask R-CNN: A deep learning pipeline with new evaluation measures for wind turbine blade defect detection and classification. **Journal of Imaging**, v. 7, n. 3, p. 46, 2021.

Análise do Desempenho do Sistema de Guinada em Aerogeradores via SCADA: Impactos Energéticos e Metodologia de Detecção

*Sâmia D. F. Sampaio, Isabele S. Oliveira, Letícia X. Viana, Nathianne M. Andrade, Arnold A. Lima Jr.,
Giovanni M. Aguiar Jr, Renata Y. Takeshita*

Delfos Energy

samia.dantas@delfos.energy, isabele.oliveira@delfos.energy, leticia.xavier@delfos.energy,
nathianne.andrade@delfos.energy, giovanni.aguiar@delfos.energy, arnold.junior@delfos.energy,
renata.takeshita@delfos.energy

RESUMO

O acelerado crescimento da energia eólica no Brasil, especialmente no Nordeste, impõe novos desafios operacionais que exigem estratégias de monitoramento mais refinadas para garantir a eficiência dos aerogeradores e mitigar perdas. Entre os subsistemas críticos, destaca-se o sistema de guinada, responsável por alinhar a nacelle à direção predominante do vento. Contudo, devido à operação intermitente e à faixa de tolerância angular (*deadband*), desalinhamentos sutis podem passar despercebidos por sistemas SCADA convencionais, resultando em degradação acumulada de desempenho.

Este estudo apresenta uma metodologia orientada por dados para diagnosticar subdesempenho no sistema de guinada de aerogeradores a partir da análise de dados SCADA. A abordagem combina a análise estatística da variável Wind Deviation, com ênfase no Intervalo Interquartil (IQR), com a avaliação da curva de potência e a estimativa da Produção Anual de Energia (AEP), conforme a norma IEC 61400-12-1. A metodologia foi implementada na plataforma Delfos Energy e validada em estudo de caso com uma turbina Vestas V150 de 4,2 MW, no Nordeste brasileiro.

Os resultados demonstraram que a metodologia identificou precocemente desalinhamentos operacionais e perdas energéticas, que chegaram a 13,4% de redução no AEP durante o período de falha. Após a manutenção corretiva, observou-se melhora significativa na estabilidade do alinhamento de guinada e na potência gerada.

Esses achados ressaltam a importância de análises avançadas aplicadas aos dados SCADA para aumentar a confiabilidade e o rendimento energético em parques eólicos. Como continuidade, propõe-se aplicar a metodologia a dados de maior resolução temporal (inferior a 10 minutos) e incorporar indicadores adicionais, como torque do motor de guinada e métricas de vibração, para viabilizar manutenção preditiva e otimização em tempo real.

Palavras-chave:

Energia eólica; Sistema de guinada; Desalinhamento; Baixo desempenho; Monitoramento inteligente; Curvas de potência.

ABSTRACT

The accelerated growth of wind energy in Brazil, especially in the Northeast, imposes new operational challenges that require more refined monitoring strategies to ensure wind turbine efficiency and mitigate losses. Among the critical subsystems, the yaw system stands out as it is responsible for aligning the nacelle with the predominant wind direction. However, due to its intermittent operation and the presence of an angular tolerance range (deadband), subtle misalignments may go unnoticed by conventional SCADA systems, resulting in accumulated performance degradation.

This study presents a data-driven methodology for diagnosing underperformance in the yaw system of wind turbines through SCADA data analysis. The approach combines the statistical analysis of the Wind Deviation variable, with emphasis on the Interquartile Range (IQR), with the evaluation of the power curve and the estimation of Annual Energy Production (AEP), in accordance with IEC 61400-12-1. The methodology was implemented on the Delfos Energy platform and validated through a case study on a Vestas V150 4.2 MW wind turbine located in Northeast Brazil.

The results showed that the methodology was able to identify operational misalignments and the corresponding energy losses at an early stage, with a reduction of 13.4% in AEP during the failure period. After corrective maintenance, a significant improvement was observed in yaw alignment stability and generated power.

These findings highlight the importance of advanced analyses applied to SCADA data as a tool to increase reliability and energy yield in wind farms. As a continuation, the methodology is proposed to be applied to higher temporal resolution data (below 10 minutes) and to incorporate additional indicators, such as yaw motor torque and vibration metrics, in order to enable predictive maintenance and real-time performance optimization.

Keywords:

Wind energy; Yaw system; Misalignment; Underperformance; Smart monitoring; Power curves.

1. INTRODUÇÃO

A energia eólica já é a segunda maior fonte renovável da matriz elétrica brasileira. Hoje, responde por cerca de 14% da capacidade instalada do país, com destaque para o Nordeste, que concentra a maior parte dos parques (EPE, 2025). Esse crescimento reflete a abundância do recurso, mas também a evolução tecnológica do setor e o papel da fonte eólica para a descarbonização da matriz (GWEC, 2024). No entanto, a expansão do setor traz desafios operacionais complexos, exigindo soluções de monitoramento e manutenção que assegurem o desempenho dos aerogeradores e reduzam perdas energéticas.

Dentre os sistemas críticos ao funcionamento de uma turbina eólica, destaca-se o sistema de guinada (yaw), responsável por manter a nacela orientada na direção do vento predominante. Destaca-se que esse sistema não opera de forma contínua; sua lógica de controle incorpora um intervalo de tolerância angular, conhecido como deadband, dentro do qual pequenos desalinhamentos são intencionalmente ignorados.

Esse intervalo visa evitar acionamentos excessivos e desnecessários do mecanismo de guinada, os quais poderiam acelerar o desgaste dos componentes mecânicos, aumentar o consumo

energético associado aos motores de guinada e reduzir a vida útil do sistema. Assim, o sistema permanece inativo enquanto o ângulo de desalinhamento entre a nacele e a direção do vento permanecer dentro desse limite predefinido — geralmente entre 5° e 10°, a depender do fabricante e do modelo da turbina. Somente quando o desalinhamento excede o limite estabelecido é que o sistema é acionado para reposicionar a nacele e restabelecer o alinhamento ótimo com o vento. Quando esse alinhamento não acontece, mesmo de forma sutil, a turbina perde eficiência. Um desalinhamento aparentemente pequeno, de 15 graus, pode causar até 6% de perda na produção anual (Emerson, 2013; Gao e Hong, 2021).


O monitoramento do desempenho das turbinas eólicas é realizado, em grande parte, por sistemas SCADA (*Supervisory Control and Data Acquisition*), que registram dados operacionais em tempo real. Apesar de essenciais, esses sistemas apresentam limitações: muitas vezes não identificam comportamentos sutis de subdesempenho, como desalinhamentos de guinada de baixa magnitude ou de ocorrência esporádica (Astolfi *et al.*, 2024). Anomalias operacionais desse tipo podem passar despercebidas, prolongando-se por longos períodos e acumulando perdas energéticas que poderiam ser evitadas com análises mais refinadas.

Diante desse cenário, torna-se fundamental avançar em metodologias capazes de extrair maior valor dos dados SCADA e de traduzir essas informações em diagnósticos claros e acionáveis. Este estudo aplica uma abordagem em aerogeradores no Nordeste brasileiro, buscando monitorar o comportamento do sistema de guinada e estimar o impacto energético de situações de baixo desempenho. Mais do que propor uma técnica específica, reforça-se a necessidade de investir em sistemas que analisem de forma inteligente os dados disponíveis e em estratégias de monitoramento de indicadores que permitam detectar falhas sutis, corrigir desalinhamentos e, assim, aumentar a confiabilidade dos ativos e reduzir perdas.

2. REVISÃO BIBLIOGRÁFICA

Para o desempenho aerodinâmico e a segurança operacional de turbinas eólicas, é essencial que a nacele esteja alinhada com a direção do vento. Esta tarefa é realizada por meio de um sistema de guinada, cuja estrutura exige precisão mecânica e estabilidade em situações de carga variável. De acordo com Han *et al.* (2023), esse sistema é formado por dois subsistemas principais: um de controle, composto pelo controlador de guinada, sensor de direção do vento e contador angular; e outro de execução, abrangendo motor, redutor e freio. Esses componentes influenciam uma engrenagem de dentes internos, transmitindo o torque necessário para reposicionar a nacele. O diagrama de um exemplo de possível estrutura do subsistema de execução de guinada pode ser observado na Figura 1.

Figura 1 - Diagrama de estrutura do subsistema de execução de guinada



Fonte: Han *et al.* (2023)

Embora desempenhe uma função crucial, o sistema de guinada está propenso a falhas mecânicas recorrentes, principalmente devido ao seu acionamento frequente. Sun *et al.* (2023) indicam que a movimentação de *Yaw* contínua gera tensões cíclicas nos dentes das engrenagens, no eixo de acionamento e nos freios, podendo ocasionar desgaste acelerado, imprecisão no acoplamento e maior probabilidade de falha estrutural.

Outrossim, uma parte essencial no acompanhamento de desempenho de turbinas é a análise da aderência à curva de potência da máquina. De acordo com Sohoni e Gupta (2019), a curva de potência é uma métrica fundamental utilizada para o monitoramento do desempenho de turbinas eólicas, representando a relação entre a potência de saída e a velocidade do vento na altura da nacele. Essa correlação só é satisfatória sob boas condições de operação e manutenção da turbina, calibração adequada dos sensores e, principalmente, alinhamento correto da guinada.

Segundo Astolfi *et al.* (2020), como a turbina regula a velocidade de rotação do rotor com base no torque aplicado sobre ele, variações significativas no ângulo entre a direção da nacele e a incidência real do vento comprometem esse torque. Isso resulta em alterações na rotação do rotor e, consequentemente, em uma redução na eficiência de aproveitamento da energia eólica incidente.

Assim, a literatura evidencia a importância do correto alinhamento da nacele para garantir o desempenho ideal da turbina, destacando a necessidade de métodos avançados de diagnóstico capazes de identificar desalinhamentos que, embora sutis, impactam significativamente a produção energética.

3. OBJETIVO

Este trabalho tem como objetivo propor uma metodologia de fácil aplicação, baseada em dados do sistema SCADA de aerogeradores, para identificar subdesempenho relacionado ao sistema de guinada e estimar seu impacto na produção energética ao longo do tempo.

4. MATERIAIS E MÉTODOS

4.1. MATERIAIS

Este estudo baseou-se na utilização de dados brutos com resolução de 10 minutos, provenientes de sistemas SCADA instalados em parques eólicos. As etapas de agregação, visualização e análise dos dados foram conduzidas por meio da plataforma Delfos Energy, a qual atua como uma camada adicional de processamento e interpretação de dados SCADA ("*second layer*"). A partir dessa plataforma, foi possível realizar a avaliação do impacto nas curvas de potência em distintos intervalos temporais, considerando diferentes comportamentos operacionais do sistema de guinada. Para isso, foi empregada a metodologia de avaliação de desempenho baseada na norma IEC 61400-12-1, previamente implementada na referida plataforma.

4.2. MÉTODOS

4.2.1. INDICADOR DE MONITORAMENTO DO SISTEMA DE GUINADA

Para avaliar o desalinhamento de guinada, utiliza-se a variável *Wind Deviation*, a qual é definida como a diferença entre a direção do vento medida pelo anemômetro da nacele e a posição da nacele. Considerando que o sistema de guinada opera de forma intermitente, ou seja, não permanece continuamente ativo, optou-se por uma abordagem estatística para a identificação de padrões de comportamento anômalos entre diferentes aerogeradores. Para isso, foi adotada a métrica de intervalo interquartil (IQR) aplicada ao canal de *Wind Deviation*, reconhecida por sua robustez na detecção de variações e valores atípicos em séries temporais.

Dessa forma, a análise foi realizada com base em janelas móveis de 30 dias, nas quais os dados brutos operacionais do sistema de guinada foram previamente processados por meio de uma metodologia de agregação previamente implementada na plataforma Delfos Energy. Essa metodologia permite o tratamento e a organização dos dados SCADA com granularidade adequada para análises estatísticas, assegurando consistência temporal e espacial entre as turbinas analisadas.

Adicionalmente, a plataforma emprega critérios rigorosos de filtragem da base de dados operacionais, excluindo automaticamente registros que não atendem aos requisitos de representatividade estabelecidos pela norma IEC 61400-12-1. Este processo de curadoria dos dados assegura a qualidade e confiabilidade das informações utilizadas nas análises subsequentes.

A aplicação do IQR em cada janela de 30 dias teve como objetivo quantificar a dispersão do comportamento do sistema de guinada em cada aerogerador, possibilitando a comparação entre diferentes unidades. Com isso, tornou-se possível identificar máquinas cujo padrão de atuação da guinada se desviava significativamente da maioria, sugerindo potenciais situações de subdesempenho ou falhas operacionais sutis.

4.2.2. INDICADOR DE DESEMPENHO DE CURVA DE POTÊNCIA

Com o objetivo de quantificar as perdas energéticas associadas ao desalinhamento do sistema de guinada em turbinas eólicas, foi desenvolvida uma metodologia fundamentada na métrica de

Produção Anual Esperada (AEP, do inglês *Annual Energy Production*). De acordo com a norma IEC 61400-12-1, o AEP representa a quantidade de energia que uma turbina eólica pode produzir anualmente sob condições normalizadas de vento, considerando a curva de potência medida e uma distribuição de frequência de velocidade do vento representativa do local.

Neste estudo, utilizou-se o indicador de AEP disponibilizado pela plataforma Delfos Energy para estimar as perdas energéticas em termos de geração anual. A análise foi conduzida por meio da comparação dos valores de AEP durante o período de ocorrência do desalinhamento e após a implementação das ações corretivas, possibilitando uma avaliação quantitativa e longitudinal dos impactos do desalinhamento na produtividade energética da unidade geradora.

4.3. ESTUDO DE CASO REPRESENTATIVO

O presente estudo de caso foi desenvolvido com base na turbina eólica AEG01, modelo Vestas V150 de 4,2 MW de potência nominal. A metodologia empregada baseou-se na análise comparativa de dados operacionais extraídos da plataforma Delfos Energy, abrangendo dois períodos críticos para a investigação: o primeiro durante a ocorrência do desalinhamento das turbinas, e o segundo subsequente à implementação das medidas corretivas necessárias.

A identificação e caracterização das falhas operacionais foram realizadas por meio da aplicação de técnicas estatísticas avançadas, com destaque para a análise do Intervalo Interquartil (IQR), apresentada na Seção 4.2.1, e a avaliação sistemática dos desvios na curva de potência característica de cada equipamento, descrita na Seção 4.2.2, ambas implementadas por meio da plataforma Delfos Energy.

Para a análise comparativa, foram utilizadas as turbinas denominadas Vizinha 1 e Vizinha 2 como referência, por não apresentarem falhas ou anomalias no mesmo período da turbina investigada. Essa abordagem metodológica, integrada à plataforma, possibilitou a detecção precisa de anomalias operacionais, além de uma avaliação quantitativa da eficácia das ações corretivas adotadas com base na análise dos dados.

5. RESULTADOS E DISCUSSÕES

Neste tópico, são apresentados os resultados dos desvios identificados nos parâmetros de IQR e da curva de potência, a partir da comparação entre as séries temporais dos indicadores da turbina analisada durante e após o comportamento de desalinhamento. Além disso, realizou-se a comparação da energia frustrada de acordo com os métodos apresentados na Seção 4.2.2.


5.1. AEG01: DESVIO DO INDICADOR IQR E CURVA DE POTÊNCIA

A turbina AEG01 apresentou comportamentos distintos em ambos os indicadores desalinhamento operacional durante o primeiro semestre de 2024, em comparação com as turbinas vizinhas do mesmo parque eólico, que mantiveram desempenho normal e não registraram variações

significativas nos parâmetros de desvio de direção do vento durante o período investigado. A análise dos dados revelou que, além dos desvios no indicador de Intervalo Interquartil (IQR), a turbina apresentou anomalias significativas no indicador de Expectativa de Produção Anual (AEP), expressa em kW.

Quando comparada às turbinas vizinhas do mesmo subparque, que mantiveram desempenho estável sem desvios expressivos, a turbina em questão demonstrou comportamento anômalo consistente. Esta diferenciação no comportamento operacional foi evidenciada através da série temporal dos indicadores de IQR e de AEP geradas pela plataforma Delfos Energy, conforme ilustrado na Figura 2.

Figura 2: Série temporal do (1) Indicador de Diferença Interquartil (IQR) (%) e da (2) Expectativa Anual de Produção (AEP) (kW) durante o período analisado




Fonte: Delfos Energy.

Ambas as métricas evidenciam a evolução anômala do comportamento da turbina AEG01 ao longo do período analisado. O item (1) da Figura 2, "Wind Deviation Time Series", demonstra o desempenho deteriorado da turbina em análise (laranja) comparativamente às turbinas vizinhas e à mediana (em preto) do subparque para o indicador interquartil da variável de desvio de vento. Similarmente, o item (2), "Contractual Power Curve Time Series", revela uma variação mais acentuada e inferior do AEP para a mesma turbina em relação às demais unidades do subparque.

Conforme evidenciado na Figura 2, o monitoramento temporal identificou que as anomalias iniciaram-se no final de 2023, intensificando-se significativamente durante o período compreendido entre 27 de abril e 28 de maio de 2024, quando os desvios atingiram sua maior magnitude.

Figura 3: Diferença dos boxplot durante (1) e depois o desalinhamento (2)



Fonte: Delfos Energy.


A intervenção técnica, realizada em agosto de 2024, compreendeu a inspeção do sensor de vibração do sistema de guinada (*yaw system*) e a substituição do sensor de vento sônico - componentes fundamentais para o alinhamento adequado da turbina com a direção predominante do vento. O período pós-correção foi estabelecido a partir de outubro de 2024, permitindo dois meses para estabilização completa dos sistemas e garantindo a confiabilidade dos dados coletados para análise comparativa.

Ao avaliar o período de IQR mais alto (28/04/2024 - 27/05/2024), aqui chamado de período de desalinhamento, e o pós-intervenção do sistema de sensoriamento (01/10/2024 - 31/10/2024) da turbina AEG01, evidenciam-se melhorias significativas na estabilidade operacional. Durante o desalinhamento, representado na Condição 1 da Figura 3, o *Wind Deviation Boxplot* apresentou alta variabilidade com amplitude interquartil de 2,46°.

Após a correção, verificada na Figura 3, condição 2, a distribuição do conjunto de dados concentrou-se substancialmente, com amplitude interquartil reduzida para 1,51°, representando diminuição de 39% na variabilidade e confirmando a eficácia da intervenção na estabilização do alinhamento da turbina.

A análise das curvas de potência complementou os achados estatísticos, demonstrando melhorias operacionais significativas observadas na Figura 4.

Figura 4: Comparação das curvas de potência durante (1) e depois do desalinhamento (2)



Fonte: Delfos Energy.

Durante o desalinhamento, de acordo com a Curva 1 apresentada na Figura 4, observou-se maior dispersão dos pontos de dados em relação à curva contratual (*Base Power Curve*), especialmente na região de transição entre 6 e 12 m/s de velocidade normalizada do vento. Esta dispersão indicou perdas de eficiência energética causadas pelo posicionamento inadequado da turbina.

Após a correção, conforme ilustrado pela Curva 2 na Figura 4, verifica-se a convergência notável dos dados operacionais para a curva de referência, com redução substancial da dispersão e melhor aderência à *Fitted Power Curve*, evidenciando restauração da eficiência nominal e eliminação das perdas associadas ao desalinhamento.

5.2. DESVIO DO INDICADOR DE EXPECTATIVA ANUAL DE PRODUÇÃO DURANTE O DESALINHAMENTO

A análise do desempenho energético da turbina AEG01 evidenciou variações significativas na eficiência de geração ao longo do período estudado, demonstrando o impacto direto do desalinhamento no desempenho operacional da máquina.

Conforme demonstrado na Figura 2, no ponto de maior desvio operacional, o AEP da turbina atingiu aproximadamente 2480 kW, representando uma deficiência de cerca de 400 kW em relação às turbinas vizinhas. Após a intervenção, a turbina superou o desempenho das unidades adjacentes, alcançando valores superiores a 2800 kW, resultando em um ganho de aproximadamente 330 kW no indicador de AEP, o que significa um aumento de produção bruta de 13,4% ou 2908,3 MWh em um ano.

Esta redução de desempenho persistiu durante a maior parte de 2024, sendo revertida exclusivamente após a execução da manutenção corretiva. Destaca-se que este comportamento anômalo foi isolado à turbina AEG01, uma vez que as turbinas vizinhas mantiveram operação regular sem indícios de desalinhamento, confirmando a natureza específica da falha no sistema de guinada.

6. CONCLUSÕES

Este estudo demonstrou a eficácia de uma metodologia baseada em dados SCADA para o monitoramento e diagnóstico do sistema de guinada de turbinas eólicas, com foco na detecção precoce de desalinhamentos e na quantificação de seus impactos energéticos. A utilização de indicadores estatísticos como o Intervalo Interquartil (IQR) aplicado à variável Wind Deviation, associada à análise da curva de potência e à estimativa da Produção Anual Esperada (AEP), mostrou-se capaz de identificar padrões de comportamento anômalo, mesmo em situações de subdesempenho sutil e intermitente.

Os resultados obtidos por meio da análise de caso da turbina AEG01 evidenciaram perdas significativas de eficiência energética associadas a desvios no sistema de guinada, os quais não foram detectados pelos sistemas SCADA convencionais. A correção da falha, por sua vez, resultou em clara melhoria nos indicadores de desempenho, confirmando a relevância de abordagens analíticas mais refinadas para o acompanhamento da operação de ativos eólicos.

Além de contribuir com uma ferramenta prática para diagnósticos mais precisos, a metodologia apresentada reforça a importância da aplicação de inteligência analítica sobre dados operacionais historicamente disponíveis, promovendo maior confiabilidade, disponibilidade e rendimento energético nos parques eólicos.

Como desdobramento desta pesquisa, propõe-se a ampliação da metodologia com a aplicação da métrica IQR a dados de maior resolução temporal, como séries com intervalos inferiores a 10 minutos. Tal abordagem poderá aumentar a sensibilidade da detecção de eventos transitórios e oferecer diagnósticos ainda mais precisos sobre o comportamento dinâmico do sistema de guinada. Além disso, estudos futuros podem explorar a combinação de múltiplos indicadores, como aceleração angular, torque do motor de guinada e consumo energético do sistema, visando a construção de

modelos preditivos multivariados para manutenção preditiva e otimização de desempenho em tempo real.

REFERÊNCIAS

ASTOLFI, Davide *et al.* **Wind turbine systematic yaw error: Operation data analysis techniques for detecting it and assessing its performance impact.** *Energies*, v. 13, n. 9, p. 2351, 2020. Disponível em: <https://doi.org/10.3390/en13092351>. Acesso em: 28 jul. 2025.

EMERSON. **Optimising annual energy production with apt handling of yaw misalignment.** White Paper, Emerson Automation Solutions, 2013.

EPE – EMPRESA DE PESQUISA ENERGÉTICA. **Brazilian Energy Balance 2025 – Summary Report.** Rio de Janeiro, 2025.

GAO, J.; HONG, J. **Data-driven yaw misalignment correction for utility-scale wind turbines.** *Journal of Renewable and Sustainable Energy*, v. 13, n. 6, art. 063302, 2021. DOI: <https://doi.org/10.1063/5.0063302>. Disponível em: <https://arxiv.org/abs/2109.08998> ou J. Renew. Sustain. Energy 13, 063302 (2021). Acesso em: 28 jul. 2025.

GWEC – GLOBAL WIND ENERGY COUNCIL. **Global Wind Report 2024.** Bruxelas, 2024.

HAN, Jialu *et al.* **Yaw system restart strategy optimization of wind turbines in mountain wind farms based on operational data mining and multi-objective optimization.** *Engineering Applications of Artificial Intelligence*, [S.l.], v. 126, Part C, p. 107036, 2023. ISSN 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2023.107036>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197623012204>. Acesso em: 26 jul. 2025.

SOHONI, S. C.; GUPTA, R. K. N. V. **A critical review on wind turbine power curve modelling techniques and their applications in wind based energy systems.** *Hindawi Publishing Corporation*, 2019.

SONG, D. *et al.* **Deep optimization of model predictive control performance for wind turbine yaw system based on intelligent fuzzy deduction.** *Expert Systems with Applications*, [S.l.], v. 221, p. 119705, 2023. ISSN 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2023.119705>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417423002063>. Acesso em: 26 jul. 2025.

Importância do monitoramento e manutenção do fluido hidráulico em aerogeradores para sua preservação

Autores: Fábio Alves, Guilherme Cornelli Souza, Marcel Magre, Rodrigo Artur Soares Novaes, Anderson Pan e Israel dos Santos Pavani.

HYDAC e Greylogix

f.alves@greylogix.com.br, g.cornelli@greylogix.com.br, marcel.magre@hydac.com,
r.novaes@greylogix.com.br, anderson.pan@hydac.com, israelpavani@gmail.com

RESUMO

Este trabalho, desenvolvido em um parque eólico de grande porte, visa demonstrar a aplicação de monitoramento contínuo de fluidos hidráulicos utilizando sensores e IIoT com Inteligência Artificial num contexto de manutenção preditiva, possibilitando a identificação precoce de contaminação e degradação dos fluidos presentes em aerogeradores. Essa abordagem transforma a manutenção corretiva em preditiva, reduzindo custos de paradas não planejadas e aumentando a disponibilidade de equipamentos críticos, além de prolongar a vida útil deles. O artigo traz à tona o potencial técnico desse formato de manutenção para elevar a confiabilidade e reduzir custos.

Palavras-chaves:

manutenção preditiva; fluidos hidráulicos; aerogeradores; contaminação de fluidos; IIoT; IA.

ABSTRACT

This work, conducted in a large-scale wind farm, presents the application of continuous monitoring of hydraulic fluids using sensors and Industrial Internet of Things (IIoT) technologies combined with Artificial Intelligence within a predictive maintenance framework. The proposed approach enables early detection of fluid contamination and degradation in wind turbines. By shifting from corrective to predictive maintenance, it reduces the costs associated with unplanned downtime and increases the availability of critical equipment, while also extending its operational lifespan. The article highlights the technical potential of this maintenance strategy to enhance system reliability and reduce operational costs.

Keywords:

predictive maintenance; hydraulic fluids; wind turbines; fluid contamination; IIoT; IA.

1. INTRODUÇÃO

O crescimento da capacidade global de energia eólica, apesar de abaixo das expectativas, é positivo e o Brasil entrou no top 5 países geradores, sendo o segundo maior mercado [1]. Para manter a atratividade do setor eólico, é essencial comprovar a rentabilidade dos investimentos. Isso exige estratégias de operação e manutenção (O&M) eficientes, capazes de reduzir custos e assegurar os retornos financeiros projetados. Para o mercado onshore, estudos convergem que O&M costuma consumir em torno de 20 – 25% do custo total nivelado da eletricidade gerada por um parque eólico, ou seja, todos os investimentos divididos pela geração prevista para o parque [2]. Visando ampliar as alternativas de ganhos em estatísticas de manutenção, ou seja, reduzir esta taxa de 20 – 25%, este artigo apresenta uma solução de monitoramento online 24/7 para diagnóstico precoce de anomalias de fluidos hidráulicos em turbinas eólicas, viabilizando uma atuação preditiva eficaz. Adicionalmente, são discutidas estratégias complementares, como filtragem off-line e redimensionamento de elementos filtrantes, que contribuem para manter o fluido em condições ideais. A combinação entre monitoramento inteligente e tratamento ativo do fluido configura uma estratégia robusta para preservar o desempenho e a confiabilidade do sistema eólico.

Como os parques eólicos sempre buscam reduzir seus custos – considerados altos de O&M, a motivação do artigo é provar que é possível aumentar o tempo de vida útil de aerogeradores e ampliar o tempo de preparação da logística das manutenções preditivas. Os componentes hidráulicos sem monitoramento constante podem levar a falhas onerosas, e por isso qualquer melhoria na preservação dos fluidos traz impacto financeiro positivo. Por isso, este trabalho realizou uma prova de conceito (PoC) em campo para comprovação, e trouxe resultados reais.

Com tecnologias de sensoriamento inteligente e IIoT (Industrial Intelligent Internet of Things) é possível monitorar em tempo real as condições de fluidos hidráulicos de aerogeradores, e com tecnologias de filtragem, é possível melhorar a capacidade atual de cuidados dos fluidos existentes nas máquinas. O impacto dessa abordagem agiliza as tomadas de decisões, logística de manutenções preditivas e respectivamente seus custos, além de aumentar o tempo de vida útil prático das turbinas eólicas.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Desafios na Manutenção de Turbinas Eólicas e o Papel dos Fluidos Hidráulicos

Em parques eólicos, os planos de manutenção costumam priorizar o acompanhamento de componentes como o *gearbox*, por meio de sensores de vibração e temperatura, com o objetivo de minimizar os custos totais por unidade de energia gerada durante a vida útil do empreendimento. Embora eficazes, essas tecnologias geralmente identificam alguns tipos de problemas apenas em estágios avançados, quando os danos já são críticos, caracterizando uma abordagem predominantemente reativa e de cobertura limitada.

Nesse cenário, o acompanhamento do fluido hidráulico, do sistema de lubrificação e dos subsistemas hidráulicos torna-se cada vez mais relevante, pois atua de forma preventiva na redução de ocorrências e na elevação da disponibilidade operacional das turbinas. Estudos recentes indicam que até 20% dos eventos de indisponibilidade estão associados a problemas hidromecânicos [3]. No contexto da manutenção preditiva, a análise de óleo evoluiu das coletas laboratoriais esporádicas para soluções com sensores *on-line*, capazes de alimentar algoritmos de aprendizado de máquina. Este trabalho propõe uma estratégia baseada nessa evolução tecnológica: monitoramento contínuo aliado a processos de filtragem eficiente, como ferramenta preditiva para preservar componentes, aumentar a confiabilidade e reduzir paradas não programadas.

2.2. Sistemas Hidráulicos em Turbinas Eólicas

O fluido hidráulico exerce função essencial em aerogeradores, atuando não apenas na transmissão de potência, mas também em sistemas críticos como controle do pitch, frenagem e refrigeração. A saúde do fluido hidráulico é crucial para o funcionamento contínuo e eficiente desses sistemas, ou seja, operando sob condições severas, esses subsistemas tornam o fluido suscetível à degradação e contaminação por partículas sólidas, água e ar, comprometendo a eficiência e a confiabilidade dos equipamentos [4]. Outras fontes da literatura e em demais pesquisas sobre a confiabilidade das turbinas eólicas, encontra-se que os componentes que estão entre as maiores causas de falhas advêm dos sistemas elétricos, de controle e sensores (Figura 1.1). Porém, em um número menor, mas não menos importante, as falhas em geradores, pás, caixas multiplicadoras podem causar indisponibilidade prolongada para geração de energia (Figura 1.2). E todos esses componentes possuem envolvimento com os sistemas / fluidos hidráulicos.




Figura 1 – Participação dos principais componentes do número total de falhas e frequência de falhas e tempos de inatividade de componentes [5].

2.3. Mecanismos de Degradação dos Fluidos Hidráulicos

O fluido hidráulico, ao longo do tempo de operação, está sujeito a diversos processos de degradação que comprometem suas propriedades físico-químicas e sua capacidade de proteger os componentes do sistema. Os principais agentes de degradação incluem contaminação por partículas sólidas, presença de água, incorporação de gases e variações excessivas de temperatura.

As partículas sólidas, sejam ferrosas ou não ferrosas, têm origem no desgaste interno dos componentes ou na entrada externa por vedação deficiente. Quando acumuladas acima dos limites recomendados (como exemplo na Tabela 1, seguindo norma ISO 4406 [6]), provocam abrasão, entupimento e aumento do atrito em superfícies, acelerando o desgaste de bombas, válvulas e atuadores.

A presença de água pode ocorrer em três formas: dissolvida, emulsionada ou livre. Mesmo em pequenas concentrações, a água reduz a viscosidade do óleo, interfere na formação do filme lubrificante, acelera processos oxidativos e causa degradação dos aditivos. Esses efeitos reduzem a vida útil do fluido e dos componentes, especialmente rolamentos e engrenagens. Segundo a norma AGMA 6006-B03, a presença de água acima de 300 ppm pode reduzir significativamente a vida útil dos mancais, implicando em falhas precoces [7]. A entrada de ar ou outros gases no sistema causa formação de microbolhas, que podem colapsar sob pressão e gerar cavitação — um fenômeno destrutivo que provoca erosão localizada e falhas prematuras.

Por fim, a elevação da temperatura além da faixa ideal (por exemplo, entre 50 °C e 60 °C para óleos ISO VG 68) altera a viscosidade, acelera a oxidação e degrada os aditivos. A operação contínua sob calor excessivo reduz drasticamente a estabilidade térmica do fluido e compromete sua função de proteção e

transmissão. A compreensão detalhada desses fatores é essencial para garantir a performance dos sistemas hidráulicos e a durabilidade dos componentes mecânicos em aerogeradores.

Norma	ISO 4406:1999	NAS 1638	SAE AS 4059
Campo de aplicação	Fluidos hidráulicos, óleos lubrificantes	Fluidos hidráulicos, óleos lubrificantes	Fluidos hidráulicos, óleos lubrificantes
Parâmetro	Quantidade de partículas > 4 µm (c) > 6 µm (c) > 14 µm (c)	Quantidade de partículas 5 – 15 µm 15 – 25 µm 25 – 50 µm 50 – 100 µm > 100 µm	Quantidade de partículas > 4 µm (c) > 6 µm (c) > 14 µm (c) > 21 µm (c) > 38 µm (c) > 70 µm (c)

Tabela 1 – Classe de contaminação [8].

2.4. Tratamento do Fluido – Filtragem

Bem como os fluidos se degradam devido às diversas condições, também existem diversas técnicas e estratégias a serem aplicadas com objetivo da remoção dos diferentes tipos de contaminantes (sólidos, líquidos, gasosos e produtos de envelhecimento do óleo). As principais para o mercado eólico são:

- **Filtração:** remover partículas de tamanhos variados, sólidas suspensas, como metais de desgaste, óxidos e fibras. Sistemas portáteis e/ou off-line permitem a limpeza contínua do óleo, sem parar a operação, reduzindo desgaste abrasivo e falhas.
- **Desidratação:** remover água do fluido é necessário para evitar corrosão, formação de lodo e envelhecimento precoce. Métodos como evaporação controlada da água e o choque de massa (separação por diferença de densidade). Sistemas a vácuo garantem níveis ideais de umidade no óleo.
- **Aplicações Químicas:** Para tratar os produtos que ocorrem devido o envelhecimento do óleo e vernizes, são aplicados processos químicos de neutralização e remoção destes contaminantes. Com essas aplicações evita-se a formação de materiais que obstruem filtros, válvulas e aumentam o atrito dentro do sistema.
- **Sistemas Off-line:** São sistemas que atuam em paralelo com a operação e que promovem a filtragem contínua do fluido, sem necessidade de interromper o funcionamento do equipamento. Esses sistemas garantem a manutenção constante da qualidade do óleo e prolonga sua vida útil.

Combinar essas técnicas com uma estratégia integrada melhora a eficiência do sistema e reduz custos. Definir o momento certo de utilização é um desafio de O&M, por isso o artigo propõe o uso de monitoramento contínuo.

2.5. Monitoramento Contínuo e Prevenção da Degradação

A Indústria 4.0 trouxe automação e conectividade para parques eólicos, com destaque para o Internet das Coisas no ambiente Industrial (IIoT), que coleta dados em tempo real de sensores, permitindo o monitoramento online de variáveis críticas ao sistema. Esses dados alimentam sistemas com algoritmos de Machine Learning (ML) e Inteligências Artificiais (IA's), que apoiam a manutenção preditiva ao prever falhas, identificar anomalias e auxiliar diagnósticos [9]. Um fundamento essencial para a manutenção preditiva é a Curva PF, que mostra o intervalo entre os primeiros sinais de falha – falha potencial (P) e a falha funcional (F). Dentro dessa janela, é possível identificar problemas, desde o começo por meio de análises de óleo, seguidos por vibração e ruído, até uma parada não planejada, como mostra a Figura 2. Por isso, agir nesse período reduz paradas, prolonga a vida útil e aumenta a confiabilidade dos equipamentos.




Figura 2 – Diagrama de curva PF. Adaptado de [10].

2.5.1. Monitoramento e Antecipação de Condição

Com a ideia de “ganhar tempo” nas logísticas de O&M dos parques eólicos, o monitoramento de condição é uma técnica de manutenção preditiva que permite o acompanhamento contínuo do estado de componentes por meio da análise de parâmetros físicos e químicos e que ajuda a melhorar os índices de preditiva. Em comparação ao monitoramento por vibração, a análise do fluido pode antecipar falhas com maior margem de tempo [11]. Segundo estudo da empresa Schaeffler/Meindl, os sintomas das falhas se iniciam com mudanças na química do fluido e contagem de particulados, seguindo por vibração, ruído e temperatura. A metodologia do monitoramento contínuo de condição envolve sensores instalados diretamente nos componentes críticos das máquinas, gerando dados que são transmitidos a sistemas de processamento ou algoritmos inteligentes, capazes de detectar padrões e anomalias, além de estatísticas e outras análises. Esse acompanhamento online oferece diagnósticos em tempo contínuo, o que reduz o tempo de resposta frente a falhas repentinas e aumenta a confiabilidade operacional [12]. Em máquinas hidráulicas, o monitoramento de condição contínuo é relevante, dado o alto risco de falhas por desgaste, contaminação ou superaquecimento. Variáveis como pressão, temperatura e saturação do fluido, além de nível e presença de contaminantes (como partículas sólidas) são parâmetros críticos que, ao serem acompanhados de forma contínua, possibilitam a detecção precoce de funcionamento fora do padrão. Seguindo essas propriedades, neste estudo, são utilizadas as seguintes categorias de sensores:

- Pressão: monitoramento de pressão por meio de princípios piezo-resistivos ou deformativos a fim de manter a pressão estável e evitar picos, desgaste excessivo, por exemplo.
- Temperatura e Umidade: para controlar e evitar possíveis problemas mais ligados à qualidade do fluido, como corrosão, oxidação e verniz, são monitoradas principalmente a temperatura e saturação do óleo.
- Saturação de filtro: usada para monitorar e evitar falhas no processo de filtragem, indicando falhas, desgaste ou contaminação súbita.
- Contaminação: usando normas de referência para contaminação de fluidos, como a norma ISO4406, e princípios ópticos, o monitoramento de contaminação é capaz de definir a classe de limpeza do fluido.
- Contagem de particulados: de forma similar e por princípios magnéticos, é feita a contagem de partículas ferrosas e não ferrosas, indicando, por exemplo, um desgaste excessivo dos componentes.
- Nível de tanque: usando o princípio de flutuação, mede-se o nível do fluido do reservatório, a fim de manter um volume adequado e verificar possível vazamento, por exemplo.

A adoção do monitoramento de condição em sistemas hidráulicos tem se mostrado eficiente na redução de falhas catastróficas, aumento da vida útil dos componentes e redução dos custos de manutenção, tornando-se uma prática recomendada para ambientes industriais que exigem alta disponibilidade e segurança operacional [13]. Além do monitoramento de condição, o presente estudo aplica esses dados

em conjunto com ML e IA's para antecipar a manutenção em meses. Usando uma prova de conceito em um aerogerador e por meio de algoritmos de previsão de séries temporais foram obtidos os comportamentos e tendências das falhas de forma antecipada.

Nos dados coletados foram identificadas fortes sazonalidades e não linearidades, por isso se optou por utilizar modelos de previsão de decomposição de séries [14]:

$$y_t = T_t + S_t + F_t + e_t$$

onde:

- y_t é a série temporal alvo de previsão, como as medições dos sensores;
- T_t é o componente de tendência que modela variações não periódicas de y_t , como variações de pressão não lineares que saturam de acordo com a produção de energia da turbina determinada pelo aproveitamento eólico;
- S_t é o componente de sazonalidade que modela variações periódicas de y_t , como as estações/períodos/horas do ano influenciam na disponibilidade de funcionamento das turbinas e suas cargas, de acordo com os ventos;
- F_t é a representação de efeitos de eventos sobre y_t , como paradas programadas ou não programadas;
- E e_t o termo de erro que representa variações peculiares, assumido como normalmente distribuído.

O artigo não entra em detalhes profundos matemáticos dos modelos utilizados, apenas colabora que as séries temporais coletadas que representam as medições relacionadas à fluidos hidráulicos dos aerogeradores tem fortes características em que modelos de decomposição de séries atuam melhores nos resultados de previsão, seja em precisão ou em velocidade.

3. MÉTODO DO ESTUDO

3.1. Da Teoria para a Prática

O artigo traz a realização de uma Prova de Conceito baseada em revisão bibliográfica e documental, com análise de normas técnicas, publicações acadêmicas e estudos de caso de monitoramento preditivo em turbinas eólicas. Os dados analisados incluem:

- Limites técnicos estabelecidos pela AGMA e ISO 4406;
- Estudos sobre degradação do fluido e seus efeitos nos componentes;
- Prova de Conceito (PoC) em parque eólico;
- Ferramentas de análise preditiva baseadas em IA.

3.2. Caso de Estudo

Este estudo foi concentrado em um complexo eólico com mais de 200 aerogeradores, focando no impacto dos cuidados com o fluido hidráulico para preservação do gearbox, componente crítico na transmissão de potência. Usou-se o sistema de monitoramento SFC (Smart Fluid Connection) da empresa HYDAC, com sensores, algoritmos de IA's e tecnologia IIoT integrados à nuvem pela empresa Greylogix.

3.3. Definição do Escopo

O complexo eólico avaliado é representativo de ambientes onshore com desafios típicos de confiabilidade do trem de força, para contextualizar a relevância da gestão do fluido, adotam-se referências de

confiabilidade publicadas para turbinas e gearboxes, que indicam progressão acumulada de ocorrências ao longo do ciclo de vida por múltiplas causas, incluindo contribuição relevante ligadas a contaminação de particulado no sistema hidráulico. Ao longo do período analisado, as taxas de indisponibilidade variaram de forma crescente, como baseline setorial, revisões técnicas-científicas apontam ocorrência acumulada em redutores, conforme a seguir:

*Benchmark setorial	
10% – 20%	até 5 anos
20% – 35%	até 10 anos
35% – 50%	até 15 anos
50% – 65%	até 20 anos

Tabela 1 – Benchmark setorial

***Nota:** Valores de referência da literatura, utilizados apenas para contextualização técnica, não representam dados operacionais de qualquer empreendimento em específico.

3.4. Falhas Hidráulicas do Gearbox

Na avaliação das falhas em uma das torres, o histórico de análises laboratoriais evidência um aumento na tendência dos níveis de particulados. Ressalta-se que os intervalos entre coletas e a latência na emissão dos laudos contribuíram para atrasos no diagnóstico do lubrificante. Quando observado essa tendência nos elementos de desgastes, há aumento gradativo de ferro (Fe) e alumínio (Al) (Tabela 2). Ainda é observado que a quantidade de água evoluiu, refletindo na viscosidade do lubrificante (Tabela 3). É então solicitado uma inspeção interna da caixa de engrenagem, onde os dados apresentados nos laudos laboratoriais, convergiram ao resultado do relatório de boroscopia. No relatório é identificado início de desgastes (scuffing) nos dentes de engrenagens do planeta (Figura 4), e início de micropittings, característicos de falha na lubrificação. Logo, ações de monitoramento são estipuladas para acompanhar a condição da caixa de engrenagens, através de análises laboratoriais do lubrificante e boroscopias. O próximo resultado do lubrificante apresenta desvios significativos nos elementos analisados onde então é solicitado nova boroscopia, revelando evoluções significativas no intervalo de 2 meses (Figura 5). Contudo, observa-se que num intervalo de 30 meses, os desgastes inicialmente apresentados, já evoluem para desgastes avançados, propagando-se em velocidade acelerada.

Date Sampled	Method	12/Sep/18	10/Sep/19	14/Jan/20	23/Jul/20	03/Jan/21	06/Jul/21	23/Dec/21	19/Jul/22	16/Jan/23	08/Aug/23
Sample ID		414.606	496.596	521.944	552.287	580.682	614.067	650.853	691.715	729.390	774.854
Viscosity 40°C (mm²/s)	ASTM D445 - 19a	318,6	313,2	317,0	314,6	313,0	311,2	311,3	308,6	299,4	321,2
Viscosity 100°C (mm²/s)	ASTM D445 - 19a	39,28	38,22	38,05	38,62	38,70	38,50	38,33	35,85	35,08	34,35
Acid Number (mg KOH/g)	ASTM D974 - 14 - COL	0,38	1,14	0,75	0,88	0,50	0,63	0,98	0,70	1,09	0,75
Water-K. Fischer (%)	ASTM D5304 - 20 - PROCEDIMENTO C	0,03	0,05	0,06	0,03	0,05	0,03	0,02	0,01	0,02	0,02
Viscosity Index	ASTM D2270 - 16	170	170	173	175	175	175	173	104	164	154
Water-K. Fischer (ppm)	ASTM D5304 - 20 - PROCEDIMENTO C	343,20	474	568	257	480	266	159	82	157	159
Water-Hot Plate	NER 10356 - 03/2015	PRESENT	PRESENT	PRESENT	PRESENT	PRESENT	PRESENT	PRESENT	PRESENT	PRESENT	PRESENT

Tabela 2 – Resultados de viscosidade e água do lubrificante.

Contaminant Elements											
Date Sampled	Method	12/Sep/18	10/Sep/19	14/Jan/20	23/Jul/20	03/Jan/21	06/Jul/21	23/Dec/21	19/Jul/22	16/Jan/23	08/Aug/23
Sample ID		414.606	496.596	521.944	552.287	580.682	614.067	650.853	691.715	729.390	774.854
Si (Silicon) (ppm)	ASTM D5185 - 18	1,6	3,1	3,0	5,7	2,8	0,0	11	0,92	0,35	0,17
Na (Sodium) (ppm)	ASTM D5185 - 18	3,3	6,7	7,9	6,1	7,2	11	1,8	0,87	0,62	0,0
K (Potassium) (ppm)	ASTM D5185 - 18	1,6	3,3	3,5	1,7	3,2	8,0	0,0	0,0037	0,00021	0,0
Ni (Nickel) (ppm)	ASTM D5185 - 18	0,0	0,0	0,0	0,0	0,31	0,0	0,0	1,00	0,0	0,0
PQ Index	ASTM D8184	3	3	4	5	16	20	3	7	7	6
Part. Count. >4 µm	ISO 4406:2021	19	23		23	23	24	24	23	24	23
Part. Count. >6 µm	ISO 4406:2021	15	20		19	19	20	20	19	22	19
Part. Count. >14 µm	ISO 4406:2021	12	15		15	15	14	13	13	19	13
Part. >14 µm/mL	ISO 4406:2021		161		164	296	103	70	67	3483	66

Tabela 3 – Resultados para elementos de contaminação.



Figura 3 – Início de scuffing na face dos dentes de engrenagens planeta e sol do sistema planetário da caixa de engrenagens.



Figura 4 – Início de micropittings nos dentes de engrenagens planeta e sol do sistema planetário da caixa de engrenagens.

4. PESQUISA DE CAMPO

4.1. Análise e Discussão dos Resultados

O caso de monitoramento offline dos fluidos para uma torre, teve duração de intervalo de 30 meses, e resultou na identificação de danos do gearbox, forçando a equipe do parque a programar uma manutenção corretiva.

Com o sistema de monitoramento de condição online aplicado, o atraso de 30 meses cai para tempo instantâneo, pois se sabe com antecedência de 30 dias (prática comum das previsões das medições) quais os comportamentos do fluido hidráulico, ou seja, dessa forma existe uma janela de tempo muito maior para programar uma manutenção preditiva, e não corretiva.

Essa abordagem possibilita a manutenção da integridade química e físico-química do óleo, assegurando a formação adequada da película lubrificante entre os componentes críticos. Como consequência, garante-se a continuidade da performance operacional e da confiabilidade da caixa de engrenagens, contribuindo diretamente para a preservação da vida útil projetada dos componentes e a mitigação de falhas prematuras.

4.2. Ferramenta de monitoramento SFC

A revisão dos estudos indica que a ausência de monitoramento contínuo do fluido leva a intervenções reativas, com altos custos e tempo de indisponibilidade, conforme evidenciado no Tópico 3.4. Em contrapartida, na prova de conceito foi adotado o monitoramento preditivo baseado em sensores online, resultando em ganhos operacionais, a seguir:

- Redução de paradas por falhas hidráulicas (>30% em POC) - A manutenção da classe de limpeza conforme ISO 4406 (16/14/12), seguindo a indicação do fabricante do redutor, junto às recomendações da AGMA para controle de água e contaminação (<300ppm) manteve a progressão de contaminação particulada sob controle e dentro de limites de confiabilidade, com ganho na vida útil dos redutores.
- Redução do custo médio por intervenção (> 45% em POC) - A priorização por risco (probabilidade × impacto) e o redirecionamento das visitas para momentos de deterioração real dos KPIs diminuíram deslocamentos emergenciais, retrabalho de coletas e substituições tardias, resultando em menor custo total por ocorrência;
- Redução de custo em ações ativas de aditivação e filtragem (até 25%) – Apoiado por evidências de redução de umidade e estabilização de propriedades com filtragem *off-line* e desidratação;
- Redução de custos de coleta (até 60%) - Coletas “dirigidas por eventos” evitam ciclos laboratoriais sem relevância e reduzem retrabalho.
- Segurança e logística aprimoradas – Menos coletas desnecessárias em áreas de difícil acesso, menor riscos as pessoas e de contaminação ao equipamento.

Esses resultados corroboram com a literatura e validam a eficácia do monitoramento de condição online como prática recomendada.

O sistema adotado por esse estudo contempla desde a instalação e conexão de sensores nas máquinas com conectividade IIoT (Figura 6), até o desenvolvimento de relatórios recorrentes que contém valores, métricas e predição de medições conforme métodos comentados no Tópico 2.5.1, além de alarmes e diagnósticos.



Figura 5 – Painel IIOT e Skid de sensores [Autores].

Como resultado do monitoramento contínuo em conjunto com a predição dos dados, o trabalho apresenta gráficos preditivos como os ilustrados na figura 7. Nestas imagens, há a divisão temporal dos dados em 3 etapas, separados por linhas pontilhadas verticais, definidas da seguinte forma em ordem cronológica:

1. Período de treinamento: possui dados consolidados e usados para treinar o algoritmo de decomposição de séries temporais.

2. Período de análise: é o período o qual está sendo analisado no relatório e possui os dados mais recentes, além de trazer a predição realizada anteriormente para fins de validação do algoritmo.
3. Período de predição: mostra a predição para o período (nestes casos, o mês) seguinte, o qual possui uma tendência de valores e uma zona de incerteza.




Figura 6 – Gráficos com predição de particulados e saturação de filtro [Autores].

Todos os meses, as predições de condição dos fluidos se atualizam, e o time de O&M do parque eólico tem uma janela de 30 dias de análise do comportamento dos fluidos, com um alto grau de precisão.

4.3. Plano de manutenção

Em paralelo ao monitoramento contínuo, é preciso elaborar planos de manutenção para ter a eficiência de filtrar os fluidos e garantir por completo um aumento de vida útil. Sem as análises em tempo real dos fluidos, ou seja, utilizando análises laboratoriais periódicas, as equipes de O&M operam com recursos limitados de acordo com as condições de mercado, o que pode representar desafios na execução de manutenções em larga escala, especialmente quando se trata de disponibilidade de mão de obra ou equipamentos de filtragem especializados.

Se existe uma janela futura de condição dos fluidos, é possível com antecedência criar as prioridades de atuação e trabalhar de forma otimizada com os recursos disponíveis, aplicando as técnicas de filtragem ideias conforme citadas no Tópico 2.4. Nesta estratégia otimizada, pode-se verificar a eficiência da abordagem, garantindo que os fluidos estejam sendo tratados de forma correta, pois: há o monitoramento em tempo real! É possível identificar mudanças logo após as ações de manutenção, e esse é um ótimo benefício em relação a esperar meses para se realizar uma nova análise laboratorial.

Resumindo, os dois métodos se complementam: o online oferece respostas rápidas e constantes, ideal para evitar falhas inesperadas, enquanto o laboratório aprofunda o diagnóstico e embasa decisões mais críticas. Juntos, aumentam a confiabilidade do sistema e a vida útil dos equipamentos.

Aspecto	Monitoramento In-line (Online)	Análise Laboratorial (Offline)
Tempo de resposta	Imediato, em tempo real	Retardado (horas ou dias)
Frequência	Continua	Periódica, conforme amostragem
Tipo de dados	Parâmetros operacionais-chave (partículas, água, gases, temperatura)	Composição detalhada e propriedades físicas/químicas
Aplicação	Monitoramento preventivo e manutenção preditiva	Diagnóstico detalhado, análises específicas
Custo e logística	Mais custo inicial em sensores, economiza manutenção	Custos recorrentes de laboratório e coleta
Representatividade	Alta, direto no sistema, sem variabilidade de amostragem	Pode ser afetado por amostragem inadequada

Tabela 4 – Comparação entre análises online e laboratorial [Autores].

5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

5.1. Resultados

Após levantamento com a equipe de O&M do parque eólico da prova de conceito, foram observadas melhorias operacionais e de manutenção do aerogerador com a implantação do sistema de monitoramento preditivo em tempo real do fluido, destacando-se:

- Maior assertividade na abordagem de manutenção preditiva;
- Aumento de eficiência na filtragem realizada;
- Antecipação de falhas com maior margem de tempo;
- Redução de riscos de segurança associados a deslocamentos e intervenções emergenciais.

Além disso, o uso contínuo da solução demonstra potenciais de benefícios financeiros e estratégicos, como:

- **Menor valor de seguro**, devido à redução de custos corretivos, de acordo com negociação com seguradora;
- **Redução de lucro cessante**, em função da maior previsibilidade das “paradas programadas.”

6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

O trabalho realizado em conjunto entre HYDAC, Greylogix e cliente reforça a importância do monitoramento contínuo do fluido hidráulico para garantir a integridade dos aerogeradores. A aplicação de tecnologias da Indústria 4.0 em conjunto com boas práticas de manutenção preditiva do fluido, traz um diferencial no escopo de sistemas de monitoramento aplicados as máquinas eólicas, reduzindo falhas, otimizando recursos e aumentando a eficiência energética.

O monitoramento contínuo dos fluidos hidráulicos não é apenas uma inovação operacional, mas um fator de resiliência energética e de valorização de ativos em um mercado cada vez mais competitivo.

Como recomendação, propõe-se a adoção progressiva desses sistemas em parques eólicos brasileiros.

REFERÊNCIAS

- [1] WORLD WIND ENERGY ASSOCIATION. WWEA Annual Report 2024. Bonn: WWEA, 2024.
- [2] STEHLY, T.; DUFFY, P.; HERNANDO, D. M. Cost of Wind Energy Review. 2024.
- [3] GABRIELI, A.; KALLENBACH, E. Condition monitoring and fault diagnosis of wind turbine gearboxes: a review. *Renewable and Sustainable Energy Reviews*, 2021.
- [4] LEE, J.; KAO, H.-A.; YANG, S. Service innovation and smart analytics for Industry 4.0 and big data environment. *Procedia CIRP*, v. 16, p. 3–8, 2017.
- [5] HAHN, B.; DURSTEWITZ, M.; ROHRIG, K. Reliability of wind turbines. In: *WIND ENERGY*. [S.l.]: Springer, 2007. p. 329–332.
- [6] INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 4406:2021 – Hydraulic fluid power — Fluids — Method for coding the level of contamination by solid particles. Geneva: ISO, 2021.
- [7] AMERICAN GEAR MANUFACTURERS ASSOCIATION. AGMA 6006-B03 – Standard for Design and Specification of Gearboxes for Wind Turbines. Alexandria, VA: AGMA, 2003.
- [8] HYDAC INTERNATIONAL GmbH. Hydraulic and Lubrication Fluid Monitoring in Wind Turbines. [S.l.]: HYDAC, [s.d.].
- [9] ZHU, T.; RAN, Y.; ZHOU, X.; WEN, Y. A survey of predictive maintenance: systems, purposes and approaches. *arXiv preprint*, arXiv:1912.07383v2, 2019.
- [10] HATZELL, R. Improving maintenance by adopting a P-F curve methodology. *InTech Magazine*, International Society of Automation (ISA), Mar./Apr. 2019.
- [11] MOBLEY, R. K. *An Introduction to Predictive Maintenance*. 2. ed. Oxford: Butterworth-Heinemann, 2002.
- [12] LEE, J.; BAGHERI, B.; KAO, H.-A. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, v. 3, p. 18–23, 2014.
- [13] SILVA, J. R.; MOREIRA, J. R.; ALMEIDA, A. M. Monitoramento contínuo de sistemas hidráulicos industriais utilizando sensores inteligentes. *Revista Brasileira de Engenharia de Manutenção*, v. 3, n. 1, p. 45–58, 2020.
- [14] TAYLOR, S. J.; LETHAM, B. Forecasting at scale. *PeerJ Preprints*, v. 5, e3190v2, 2017.