

Sistema FIEB



CENTRO UNIVERSITÁRIO SENAI CIMATEC

PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM

COMPUTACIONAL E TECNOLOGIA INDUSTRIAL

Mestrado em Modelagem Computacional e Tecnologia Industrial

Dissertação de Mestrado

Estudo preliminar para desenvolvimento de um sistema de manutenção em turbinas eólicas de uma planta híbrida, aplicando técnicas de IA, para clusterizar e classificar dados.

Apresentada por: Natasha Benjamim Barbosa

Orientador: Profa. Dra. Bruna Aparecida Souza Machado

Coorientador: Prof. Dr. Álex Álisson Bandeira Santos

Julho de 2023

Natasha Benjamim Barbosa

Estudo preliminar para desenvolvimento de um sistema de manutenção em turbinas eólicas de uma planta híbrida, aplicando técnicas de IA, para clusterizar e classificar dados.

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Modelagem Computacional e Tecnologia Industrial, Curso de Mestrado em Modelagem Computacional e Tecnologia Industrial do Centro Universitário SENAI CIMATEC, como requisito parcial para a obtenção do título de **Mestre em Modelagem Computacional e Tecnologia Industrial**.

Orientador: Profa. Dra. Bruna Aparecida Souza Machado

Coorientador: Prof. Dr. Álex Álisson Bandeira Santos

Salvador

2023

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

B238e Barbosa, Natasha Benjamim

Estudo preliminar para desenvolvimento de um sistema de manutenção em turbinas eólicas de uma planta híbrida, aplicando técnicas de IA, para clusterizar e classificar dados.
/ Natasha Benjamim Barbosa. – Salvador, 2023.

104 f. : il. color.

Orientadora: Prof.^a Dr.^a Bruna Aparecida Souza Machado
Coorientador: Prof. Dr. Alex Álisson Bandeira Santos.

Dissertação (Mestrado em Modelagem Computacional e Tecnologia Industrial) –
Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2023.
Inclui referências.

1. Turbinas eólicas r. 2. Manutenção. 3. Detecção de falhas. 4. Aprendizado de máquina. 5. Patentes. I. Centro Universitário SENAI CIMATEC. II. Machado, Bruna Aparecida Souza. III. Santos, Alex Álisson Bandeira. IV. Título.

CDD 621.8

CENTRO UNIVERSITÁRIO SENAI CIMATEC

Mestrado Acadêmico em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, aprova a Defesa de Mestrado, intitulada “**Estudo preliminar para desenvolvimento de um sistema de manutenção em turbinas eólicas de uma planta híbrida, aplicando técnicas de IA, para clusterizar e classificar dados**” apresentada no dia 20 de julho de 2023, como parte dos requisitos necessários para a obtenção do Título de Mestre em Modelagem Computacional e Tecnologia Industrial.

Electronically signed by:
Bruna Machado
CPF: ***.830.795-**
Date: 7/27/2023 10:39:23 AM -03:00

Orientadora:

Prof.^a Dr.^a Bruna Aparecida Souza Machado
SENAI CIMATEC

Assinado eletronicamente por:
Alex Álisson Bandeira Santos
CPF: ***.191.765-**
Data: 24/07/2023 07:59:21 -03:00

Coorientador:

Prof. Dr. Alex Álisson Bandeira Santos
SENAI CIMATEC

Assinado eletronicamente por:
Roberto Luiz Souza Monteiro
CPF: ***.881.935-**
Data: 27/07/2023 17:06:54 -03:00

Membro Interno:

Prof. Dr. Roberto Luiz Souza Monteiro
SENAI CIMATEC

Electronically signed by:
Marcelo Henrique Souza Bomfim
CPF: ***.646.836-**
Date: 8/2/2023 6:17:46 PM -03:00

Membro Externo:

Prof. Dr. Marcelo Henrique Souza Bomfim
IFMG

Dedico este trabalho à Deus e minha família

Agradecimentos

Agradeço a Deus, que me guiou durante toda a minha vida, cada escolha, cada conquista. Agradeço a ele por nunca ter deixado faltar nada, saúde, forças, determinação.

Agradeço ao meu marido Jader, que aguentou todo esse período, me apoiando e cuidando dos nossos filhos, nos momentos em que eu estava muito ocupada e não conseguia dar a atenção desejada.

A Augusto e Lavínia, meus filhos, que mesmo não entendendo muito bem o significado desse trabalho todo, precisaram aguentar o cansaço e a falta de paciência da mãe, além da ausência, em alguns programas de família e que, já não aguentavam mais, adiar seus planos, para depois do mestrado da mãe. Mas espero que eles também lembrem desse período com carinho, do exemplo da mãe, que mesmo cansada, com dois filhos, trabalhando ainda arrumou forças para dedicar várias noites e finais de semana, estudando e lutando para alcançar os seus sonhos, além de um futuro melhor para todos.

Sou muito grata a meus pais, que também ajudaram bastante durante esse período de mestrado, principalmente apoiando com os netos, mas, Irenaldo e Lucia, não podem ser lembrados só pelo apoio desse período, pois eles sempre foram pais maravilhosos que apoiaram bastante os estudos das três filhas, a eles devemos tudo o que temos e o que somos, todas nossas conquistas.

Agradeço aos orientadores Professora Dra. Bruna Machado e Professor Dr. Alex Santos pelas orientações, ensinamentos, contribuições e paciência, me apoiando e não me deixando desistir, mesmo nos momentos mais difíceis.

Tenho também um agradecimento especial ao professor Dr. Oberdan Pinheiro, que mesmo não sendo o meu orientador oficialmente, foi orientador no projeto e me ensinou e contribuiu bastante para o desenvolvimento desse trabalho.

Aos membros da banca pela disponibilidade em avaliar e realizar comentários construtivos, contribuindo com a evolução do trabalho.

Agradeço aos amigos que fiz no projeto, colegas da CHESF, corajosos que, como eu, tinham um sonho de fazer mestrado ou doutorado e visualizaram no projeto uma oportunidade. Não esmoreçam vai dar tudo certo, vamos alcançar o tão desejado diploma. Preciso aqui também relembrar as muitas conversas de desabafo e apoio nos grupos de zap e no “Café Terapêutico”, momentos essenciais para não desistirmos.

Sou muito grata também aos amigos Danielle Nunes e Rogério Santiago, com quem desenvolvi os artigos dessa dissertação, muito obrigada por todo apoio, paciência e conhecimentos compartilhados.

Agradeço ao Senai Cimatec, pelo suporte no mestrado e no desenvolvimento da pesquisa e à ANEEL (Agência Nacional de Energia Elétrica) e a CHESF (Companhia Hidro Elétrica do São Francisco) pelo financiamento do projeto.

Agradeço também meu chefe Marcelo e meus colegas do DOMS, por todo apoio e compreensão.

E, por fim, as minhas irmãs e amigas, com quem eu desabafava, quando estava triste, desanimada e cansada e que sempre arrumavam um jeitinho de fazer eu ficar melhor.

Tem ainda um agradecimento especial ao meu médico André Flávio, e os fisioterapeutas Thamiris e Artur, que “consertaram” minha coluna, para eu poder chegar bem, agora.

São muitos agradecimentos, costumo dizer que um mestrado ou um doutorado é um projeto de muitos, é muita luta, muito esforço, é preciso uma grande rede de apoio, sem isso, a gente não consegue.

A todos que citei ou que eu tenha esquecido, mas que contribuiu de alguma forma para esse mestrado, registro aqui os meus sinceros agradecimentos.

Salvador, Brasil
20 de Julho de 2023

Natasha Benjamim Barbosa

Resumo

O crescimento da geração eólica, atualmente, tem sido impulsionado pelos fatores ambientais, mudanças climáticas e incentivos oferecidos para o desenvolvimento de tecnologias limpas e sustentáveis, na geração de energia. No entanto, devido ao rápido crescimento desta tecnologia, as preocupações com a segurança e confiabilidade são crescentes, especialmente devido aos riscos e custos financeiros associados, que são bastante elevados. Por isso, o investimento em monitoramento remoto de turbinas é essencial, visto que esses equipamentos costumam ser instalados em locais isolados e de difícil acesso. Nesse contexto, estudos de novas tecnologias, ferramentas, métodos e sistemas para manutenção, monitoramento de saúde e detecção de falhas, nessa área, tornou-se um importante foco de pesquisa. O objetivo deste trabalho foi desenvolver um sistema de manutenção de turbinas eólicas de uma planta híbrida, realizando estudos iniciais exploratórios, partindo de uma prospecção tecnológica sobre: ferramentas e métodos de detecção de falhas em aerogeradores e, seguido, pela construção de um modelo computacional que, analisou dados históricos de plantas eólicas da CHESF, utilizando de ferramentas de IA, para buscar padrões e classificar os dados. A partir de uma análise de documentos, foi realizada a prospecção tecnológica buscando por técnicas e ferramentas desenvolvidas para detectar falhas em turbinas eólicas, além da aplicação de inteligência artificial como inovação. Na segunda etapa desse trabalho, foram coletados e analisados dados de operação e relatórios de manutenção das turbinas eólicas da CHESF, com o objetivo de encontrar padrões e correlações; por fim, um modelo computacional foi construído, utilizando ferramentas de IA, para clusterizar e classificar os dados. Na clusterização dos dados, foram encontrados 3 clusters, que indicam possíveis comportamentos de: operação normal, pré-falha e falha, porém serão necessárias análises mais profundas, utilizando mais dados e um mapeamento mais detalhado, para garantir resultados conclusivos. O modelo construído para treinamento e reconhecimento dos clusters obteve acerto acima de 98%. É importante estender as análises usando novas bases de dados de entrada, para ter certeza da eficácia do modelo. Esses estudos terão continuidade e vão contribuir para o desenvolvimento de um sistema de manutenção de turbinas eólicas da planta híbrida, de um projeto mais amplo em que está inserido. O diferencial deste trabalho é a utilização de dados reais dos aerogeradores da CHESF, além do conhecimento das equipes de manutenção, aliado a novas tecnologias de IA e suporte científico dos professores do Senai Cimatec. Outra contribuição importante é em relação aos aerogeradores de imã permanente, pois não há muitos estudos nessa área, portanto um grande potencial a ser explorado.

Palavras-chave: turbinas eólicas, manutenção, detecção de falhas, aprendizado de máquina, patentes.

Abstract

In recent years there has been an increase in wind generation, driven by environmental factors and the incentive offered for the development of clean and sustainable technologies for energy generation. However, due to the rapid growth of this technology, concerns about the safety and reliability of wind turbines are increasing, especially due to the associated risks and financial costs. Therefore, health monitoring and fault detection for wind turbines has become an important research focus. Thus, the objective of this work was to development of a maintenance system for wind turbines of a hybrid plant, realizing initial exploratory studies, starting from a technological prospection on tools and methods for detecting faults in wind turbines and followed by the construction of a computational model to analyze historical data from CHESF wind farms, using AI tools, to look for patterns and classify this data. For this, documents was analised and a technological prospection was made on techniques and tools developed to detect faults in wind turbines, in addition to the application of artificial intelligence as an innovation; data from operation and maintenance reports of CHESF's wind turbines were collected and analyzed, looking to check patterns and correlations; Finally, a computational model was built, using AI tools, to cluster and classify the data. Interesting results were achieved by analyzing the data with grouping and classification tools. In the clustering of the data, 3 clusters were found, which indicate possible behaviors of: normal operation, pre-failure and failure, but is required deeper analyzes, using more datasets and a detailed maintenance mapping, to ensure more conclusive results. The model built for training and recognition of the clusters obtained accuracy above 98%. It is important to extend the analyzes using new input datasets to be sure of the model's effectiveness. These studies will be extended and should contribute to the development of a maintenance system for wind turbines at the hybrid plant. The differential of this work is the use of real data from CHESF's wind turbines, in addition to the knowledge of the maintenance teams, combined with new AI technologies and scientific support from Senai Cimatec professors. Another important contribution is in relation to permanent magnet wind turbines, as there are not many studies in this field, therefore a great potential to be explored.

Keywords: wind turbine, maintenance, fault detection, patent analysis, machine learning.

Sumário

1	Introdução	1
1.1	Definição do Problema	6
1.2	Objetivos	9
1.2.1	Objetivo Geral	9
1.2.2	Objetivos Específicos	9
1.3	Organização da Dissertação de Mestrado	9
2	Revisão da Literatura	11
2.1	Geração de Energia Eólica	11
2.1.1	Aerogerador IMPSA IV-82	13
2.2	Manutenção	20
2.3	Aprendizado de Máquina	23
2.3.1	Redes Neurais	24
2.4	Trabalhos Correlatos	26
3	Materiais e Métodos	28
3.1	Prospecção Tecnológica	28
3.2	Coleta de Dados	29
3.3	Pré-processamento	30
3.4	Clusterização	32
3.5	Seleção de Atributos	34
3.6	Classificação	35
3.7	Métricas de Avaliação	36
3.7.1	Matriz de Confusão	37
3.7.2	Acurácia	38
3.7.3	Revocação	38
3.7.4	Precisão	38
3.7.5	Especificidade	39
3.7.6	F1-Score	39
4	Artigo I	40
5	Artigo II	62
6	Conclusões	78
6.1	Conclusões	78
6.2	Contribuições	79
6.3	Atividades Futuras de Pesquisa	80
A	Documentos	81
A.1	Atributos	81
A.2	Resultados Obtidos	82
	Referências	85

Lista de Tabelas

2	Dados da Energia Eólica no Brasil.	5
3	Especificações Técnicas do Aerogerador	13
4	Network Hyperparameters	36

Lista de Figuras

1	Matriz elétrica brasileira e Evolução da capacidade instalada.	3
2	Mapa dos processos de eólicas offshore.	4
3	Diagrama do Projeto de P&D.	8
4	Esquema de Motor de Gerador de Ímã Permanente	12
5	Turbina eólica PMSG	12
6	Estrutura mecânica geral do aerogerador	14
7	Componentes do sistema de pitch	15
8	Configuração e peças do gerador	16
9	Nacele	16
10	Conversor de frequência	18
11	Esquema do Freqcon no aerogerador	19
12	Estrutura para prognósticos e gerenciamento de saúde.	20
13	Esquema de abordagem Data-Driven.	21
14	Monitoramento x Componente Aerogerador.	22
15	Comparação da taxa de falha anual de turbinas direct-drive e geared-drive.	23
16	Modelo Perceptron.	25
17	Multi-Layer Perceptron.	26
18	IPC codes used in the prospecting of current patent technology.	28
19	SCADA da Goldwind.	29
20	Procedimento de como foi desenvolvido o modelo computacional.	30
21	Pré-processamento primário.	31
22	Pré-processamento secundário.	32
23	Atributos semelhantes.	35
24	Matriz de Confusão.	37
25	Atributos	81
26	Atributos	81
27	Atributos	82
28	Atributos	82
29	Resultados MLP - clusterização EM	83
30	Resultados MLP - clusterização K-Means - Distância de Manhattan	83
31	Resultados MLP - clusterização K-Means - Distância de Euclidean	84

Lista de Siglas

ABEEólica ..	Associação Brasileira de Energia Eólica e Novas Tecnologias
AC	Corrente Alternada
AI	Artificial Intelligence
AIE	Agência Internacional de Energia
ANEEL	Agência Nacional de Energia Elétrica
ANN	Artificial Neural Network
CBM	Condition-Based Monitoring
CCA	Canonical Correlation Analysis
CC	Corrente Contínua
CFRP	Carbon-Fiber-Reinforced Polymer
CHESF	Companhia Hidro Elétrica do São Francisco
CLLST	Continuous Line Laser Scanning Thermography
CLP	Controlador Lógico Programável
CM	Condition Monitoring
CNN	Convolutional Neural Network
CSV	Comma-Separated-Values
CWT	Continuous Waveform Transect
DC	Direct Current
DOMS	Departamento de Manutenção de Subestações
DRN	Deep Residual Network
DWPI	Derwent Innovation Index
EM	Expectation–Maximization
EPE	Empresa de Pesquisa Energética
EPO	European Patent Office
FD	Fault Diagnosis
FYP	Five Year Plan
GFRP	Glass-Fiber-Reinforced Polymer
GW	Gigawatts
GWEC	Global Wind Energy Council
IA	Inteligência Artificial
IBAMA	Instituto Brasileiro de Meio Ambiente e Renováveis Recursos Naturais
IDH	Índice de Desenvolvimento Humano
IEA	International Energy Agency
IHM	Interface Homem-Máquina
IMPISA	Indústrias Metalúrgicas Pescarmona Sociedad Anónima
IPC	International Patent Classification
IPCC	Intergovernmental Panel on Climate Change
IRT	Infrared Thermography
kW	Kilowatts
MLP	Multi-Layer Perceptron
MRSFN	Multi-Resolution and Multi-Sensor Fusion Network
MW	Megawatts
MWh	Megawatts-hora
NDT	Non Destructive Testing
PCT	Patent Cooperation Treaty
P&D	Pesquisa e Desenvolvimento

PIB	Produto Interno Bruto
PHM	Prognostic Health Management
PMSG	Permanent Magnet Synchronous Generator
PPGMCTI ..	SENAI CIMATEC
PROP&D ...	Procedimento do Programa de Pesquisa e Desenvolvimento
R&D	Research and Development
SCADA	Supervisory Control and Data Acquisition
SGH	Sistema de Geração Híbrida
SHM	Structural Health Monitoring
TWh	Terawatt-hora
UPS	Uninterruptible Power Supply
UTR	Unidade Terminal Remota
WIPO	World Intellectual Property Organization
WT	Wind Turbine
WWW	World Wide Web

Introdução

A energia eólica tem experimentado um crescimento significativo em todo o mundo. Muitos países têm investido em projetos eólicos para diversificar suas fontes de energia, reduzir as emissões de gases de efeito estufa e aproveitar os benefícios das fontes de energia renováveis. Segundo relatórios da Agência Internacional de Energia (AIE) e da Global Wind Energy Council (GWEC), a capacidade global instalada de energia eólica continua a aumentar.

O aumento da energia primária entre 2019 e 2021 foi totalmente impulsionado por fontes de energia renováveis. A geração de eletricidade aumentou 6,2% em 2021 – semelhante à forte recuperação observada em 2010, após a crise financeira (6,4%). Eólica e solar atingiram 10,2% de participação na geração de energia em 2021, foi a primeira vez que as energias eólica e solar forneceram mais de 10% do poder global, superando a contribuição da energia nuclear. A capacidade solar e eólica continuou a crescer rapidamente em 2021, aumentando em 226 GW, perto do aumento recorde de 236 GW observado em 2020. A China continuou sendo o principal impulsionador do crescimento da capacidade solar e eólica no ano passado, respondendo por cerca de 36% e 40% das adições de capacidade global, respectivamente (BP, 2022).

A invasão russa da Ucrânia desencadeou a primeira crise energética verdadeiramente global, gerando um impulso sem precedentes para as energias renováveis. As interrupções no fornecimento de combustíveis fósseis enfatizaram os benefícios de segurança energética da eletricidade renovável gerada domesticamente, levando muitos países a fortalecer as políticas de apoio às energias renováveis. Enquanto isso, os preços mais altos dos combustíveis fósseis em todo o mundo melhoraram a competitividade da geração solar fotovoltaica e eólica em relação a outros combustíveis (RENEWABLE, 2023).

A expansão da capacidade renovável nos próximos cinco anos, será muito mais rápida do que se esperava há apenas um ano. Ao longo de 2022-2027, as energias renováveis devem crescer quase 2.400 GW, igual a toda a capacidade instalada de energia da China hoje. Isso representa uma aceleração de 85% em relação aos cinco anos anteriores. As energias renováveis devem responder por mais de 90% da expansão da capacidade global de eletricidade durante o período. Esse aumento é impulsionado principalmente pela China, União Europeia, Estados Unidos e Índia, que estão implementando políticas existentes e reformas regulatórias e de mercado, ao mesmo tempo em que introduzem novas políticas, mais rapidamente do que o esperado em reação à crise energética. O 14º Plano Quinquenal da China e as reformas de mercado, o plano REPowerEU e a Lei de Redução da Inflação

dos EUA são os principais impulsionadores ([RENEWABLE, 2023](#)).

A capacidade eólica global vai praticamente dobrar, com projetos offshore respondendo por um quinto do crescimento. Prevê-se que mais de 570 GW de nova capacidade eólica onshore se tornem operacionais no período de 2022-27. No entanto, as adições de energia eólica onshore só quebrarão seu recorde anual, estabelecido em 2020, no final do período de previsão devido aos longos procedimentos de licenciamento e à falta de melhorias na infraestrutura da rede. O crescimento eólico offshore acelera globalmente, enquanto a participação da Europa na capacidade offshore instalada diminui de 50% em 2021 para 30% em 2027, pois as políticas provinciais da China apoiam uma expansão mais rápida e os Estados Unidos se tornam um mercado considerável no final do período ([RENEWABLE, 2023](#)).

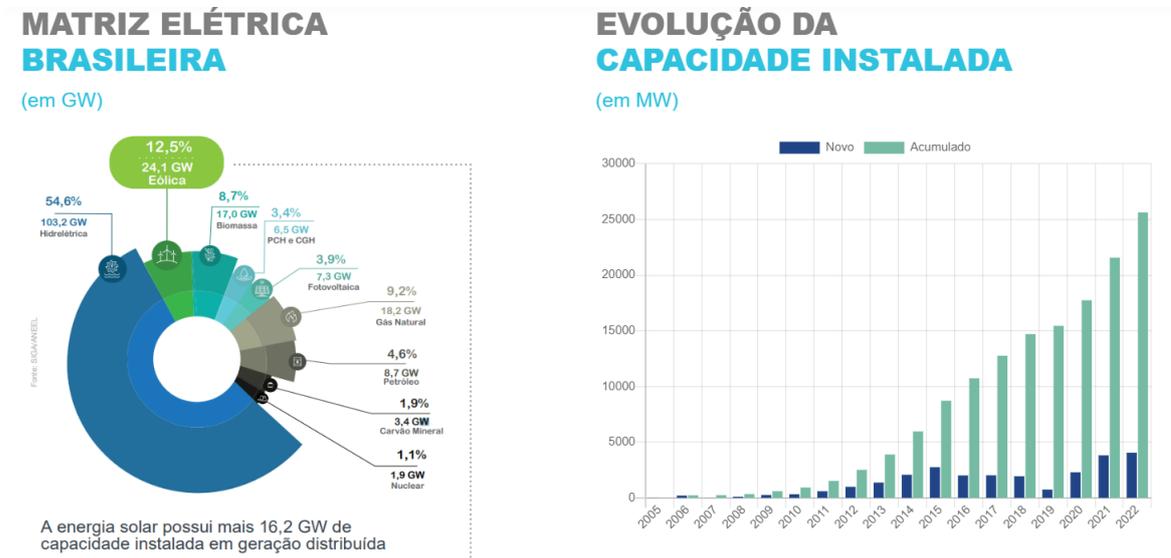
A energia eólica offshore é a fonte de energia limpa e renovável que se obtém aproveitando a força do vento que sopra em alto-mar, onde este alcança uma velocidade maior e mais constante, devido à inexistência de barreiras. Como vantagens da geração offshore é possível citar: que no mar o potencial de geração é maior que na terra, praticamente o dobro; o impacto visual e acústico é pequeno; o transporte marítimo tem poucas limitações à carga e dimensões em comparação com o terrestre, proporcionando assim que os aerogeradores offshore alcancem tamanhos maiores que na terra. Como desvantagens, temos que: os principais impactos da instalação de eólicas no mar são vibrações; emissão de campos eletromagnéticos; altos custos de manutenção e controle; degradação do solo e distúrbios em organismos que habitam fundos marinhos ([IBERDROLA, 2023](#)) ([MATANATIVA, 2023](#)).

No Brasil, a implantação fora do esquema de leilões do governo e a medição líquida solicitam uma revisão para cima de 60% da previsão. Espera-se que o Brasil adicione mais de 70 GW de nova capacidade renovável até 2027, com energia solar fotovoltaica e eólica constituindo a maioria. A previsão deste ano foi revisada para cima em mais de 60% para refletir o crescimento contínuo de projetos em escala de serviços públicos por meio do mercado livre, prazos de leilão para energia eólica onshore e um prazo para benefícios fotovoltaicos distribuídos ([RENEWABLE, 2023](#)).

A revolução da energia eólica brasileira já está em curso há alguns anos, como é possível visualizar na Figura 1, a indústria eólica atingiu 25,6 GW de capacidade instalada em 2022, garantindo para a energia eólica uma posição de destaque, como a segunda fonte da matriz elétrica brasileira. Além do crescimento contínuo da eólica onshore, temos grandes expectativas para o desenvolvimento do brasileiro offshore. O IBAMA - Instituto Brasileiro de Meio Ambiente e Renováveis Recursos Naturais, já recebeu propostas de projetos para mais de 170 GW de energia eólica offshore. A Figura 2 mostra os processos de licenciamento ambiental de eólicas offshore abertos no IBAMA até 24 de março de 2023. Este número é equivalente a praticamente toda a matriz elétrica brasileira e mostra

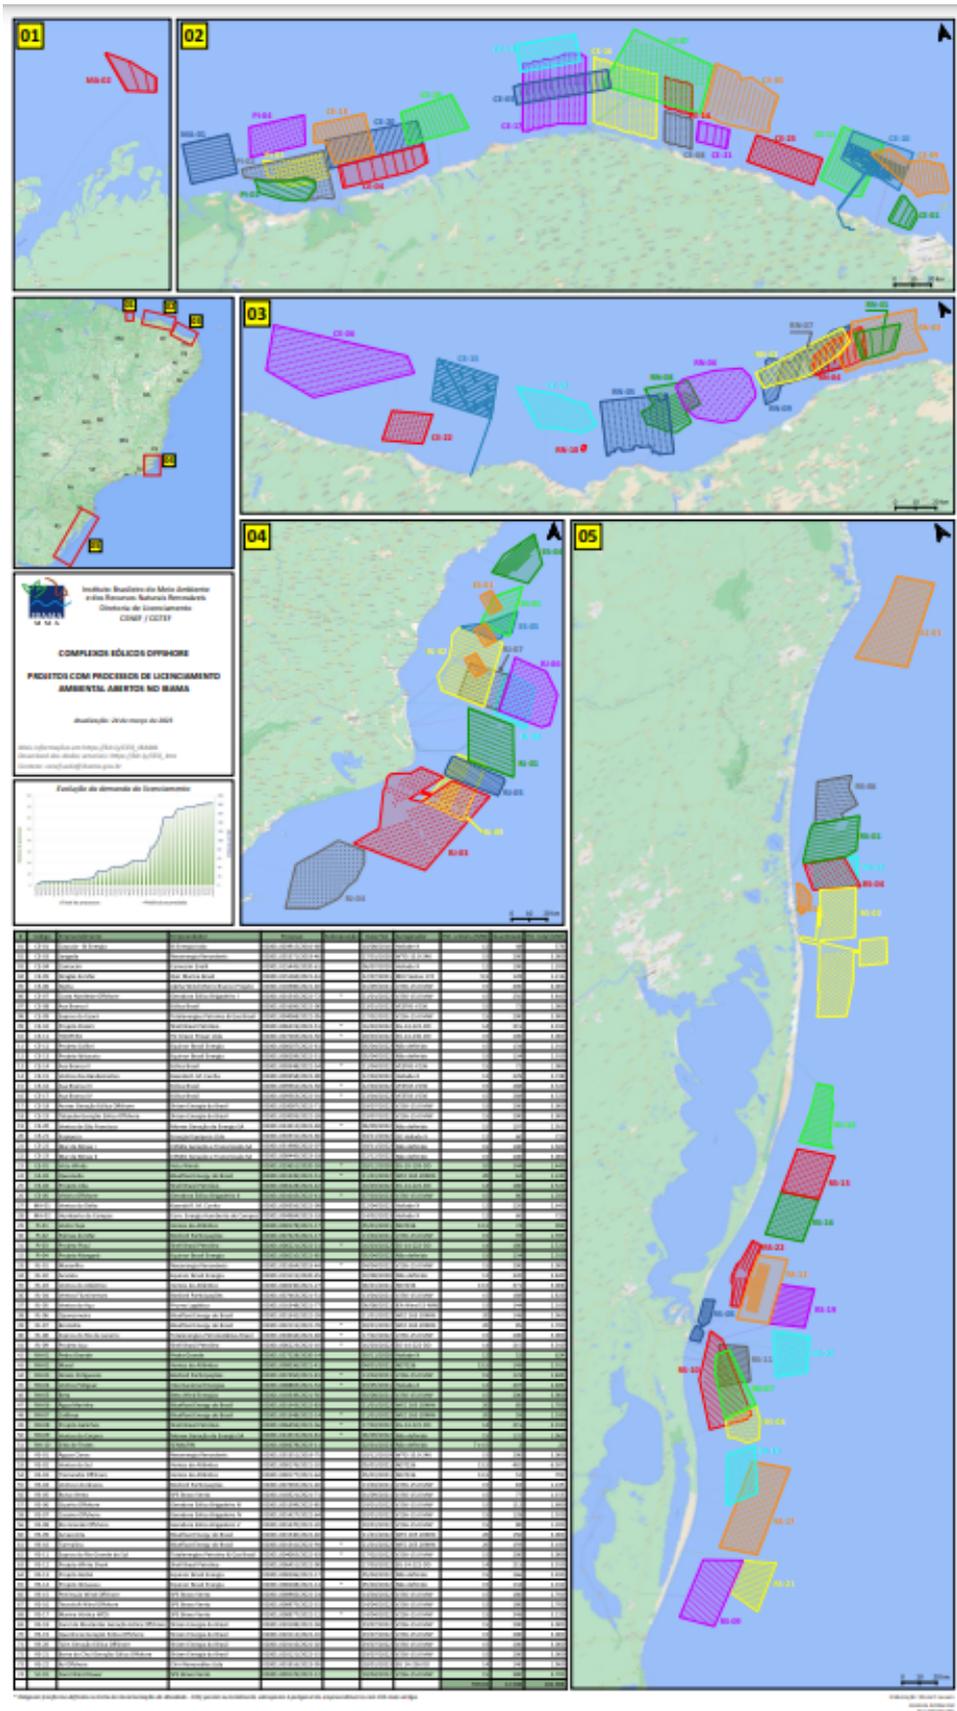
a extensão do apetite do investidor e o enorme potencial da geração offshore em águas brasileiras (HUTCHINSON; ZHAO, 2023), (ABEEÓLICA, 2023) (IBAMA, 2023).

Figura 1: Matriz elétrica brasileira e Evolução da capacidade instalada.



Fonte: ABEEólica.

Figura 2: Mapa dos processos de eólicas offshore.



Fonte: IBAMA.

Benefícios da energia eólica, citados pela ABEEólica:

- Cada R\$ 1,00 investido em eólicas tem impacto de R\$ 2,9 no PIB;
- É renovável, não polui, contribui para que o Brasil cumpra seus objetivos no Acordo do Clima;
- Permite que o proprietário da terra siga com plantações ou criação de animais;
- Gera renda e melhoria de vida para proprietários de terra com arrendamento para colocação das torres;
- Impacta positivamente na economia local aumentando o PIB e o IDH municipal em cerca de 25%;
- Gera cerca de 11 postos de trabalho por MW instalado.

Segundo ([ABEEÓLICA, 2023](#)), dados de 22/05/23, temos a Tabela 2:

Tabela 2: Dados da Energia Eólica no Brasil.

Tamanho da Indústria	
Capacidade Instalada	24,13 GW
Parques eólicos	869
Aerogeradores em operação	mais de 9770
Estados	12
Energia Gerada	
Geração eólica injetada no SIN (2021)	12,1%
Energia eólica gerada em 2021	72,2TWh
Crescimento em relação à 2020	27%
Significado dessa Geração	
Número de residências abastecidas (média mensal)	36,2 milhões
Habitantes Beneficiados	108 milhões
Abastecidos no país no momento de pico	20%
Contribuições para o país	
Dólares investidos de 2010 a 2021	42,3 bilhões
Toneladas de CO ₂ evitadas (2021)	34,4 milhões

A AIE prevê que quase toda a eletricidade adicional gerada entre 2022 e 2025 será gerada por fontes de energia renováveis. Até 2024, o GWEC espera que as instalações eólicas ultrapassem a marca de 100 GW anuais, enquanto em 2025 a previsão é de que a eólica offshore instalará mais de 25 GW em um único ano. As instalações serão aceleradas

rapidamente depois disso, impulsionado pela ambiciosa meta de energia verde dos países e metas climáticas. Segundo o GWEC existem previsão de que 680 GW de capacidade eólica serão instalados globalmente até 2027, dos quais 130 GW serão offshore ([HUTCHINSON; ZHAO, 2023](#)).

Um ponto importante é que turbinas eólicas sofrem regularmente com inconsistências operacionais, levando a custos significativos e desafios em operações e manutenção - O&M. Monitoramento baseado em condição - CBM e avaliação/análise de desempenho de turbinas são aspectos vitais para garantir um planejamento eficiente de O&M e minimização de custos. As técnicas de tomada de decisão baseadas em dados testemunharam uma rápida evolução na indústria eólica para tais tarefas durante a última década, desde a aplicação de métodos de processamento de sinal no início de 2010 até técnicas de inteligência artificial - IA, especialmente aprendizado profundo em 2020 ([CHATTERJEE; DETHLEFS, 2021](#)).

Com o crescimento da quantidade de dados disponíveis, as técnicas de análise de dados usando IA estão sendo aplicadas para otimizar a manutenção de aerogeradores. Algoritmos avançados podem identificar padrões complexos nos dados coletados, ajudando a aprimorar a eficiência dos processos de manutenção.

E, por fim, temos que os projetos híbridos, ou seja, a combinação de energia eólica com outra fonte de energia e/ou armazenamento solução, atualmente é um tema chave na indústria de energias renováveis. A hibridização oferece oportunidades para aumentar a quota de energias renováveis na rede e substituir os combustíveis fósseis ([LEE; ZHAO, 2022](#)).

1.1 Definição do Problema

Esse trabalho faz parte projeto de P&D entre a CHESF e o Senai Cimatec, com título: Sistema Inteligente de Geração Híbrida com Armazenamento, que é regido por um acordo de cooperação sob as diretrizes e as orientações de projetos de P&D regulados pela ANEEL. Cujos termos, definições e condições empregados, relacionados às fases na cadeia de inovação, observam diretrizes do PROP&D (Procedimento do Programa de Pesquisa e Desenvolvimento) de 2016.

Trata-se de uma planta piloto de geração eólica que operará em condições reais, integrada a um sistema gerador fotovoltaico e com armazenamento de energia (storage) para equilíbrio do despacho.

O objetivo é contribuir para uma integração mais inteligente de diferentes fontes de ge-

ração de energia. Serão entregues soluções inovadoras para a melhoria da qualidade, eficiência e confiabilidade do processo de geração de energia elétrica, com ganhos efetivos e mensuráveis de desempenho. O projeto apresenta uma excelente oportunidade para implantação de plataforma para desenvolvimento de novas soluções para melhoria da gestão, operação, supervisão e controle inteligentes e integrados dos sistemas de geração, e possível de ser generalizada e escalada para outros sistemas similares.

Destaca-se que o Nordeste do Brasil possui um elevado potencial eólico e solar, portanto projetos que integrem diferentes empreendimentos de geração nessa região seriam bem convenientes, para a empresa, que já investe bastante na geração de energia nessa área e busca alternativas ainda melhores, para garantir maior confiabilidade e segurança energética.

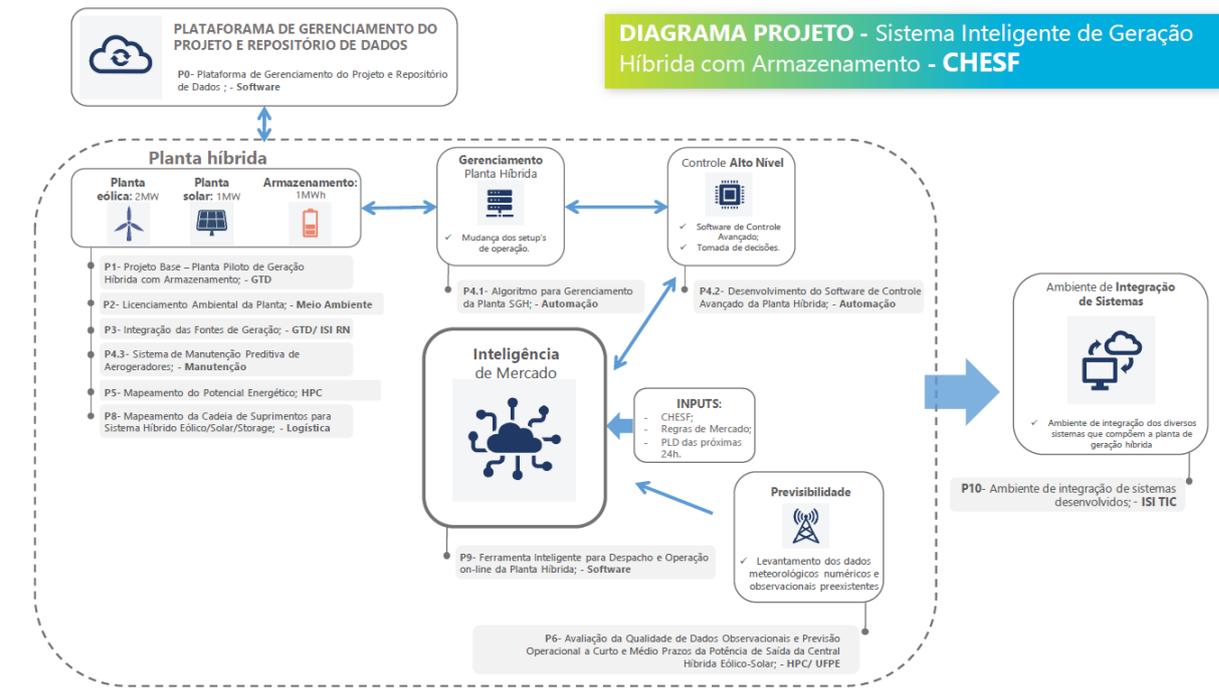
Diversas notícias e estudos têm sido divulgados sobre a viabilidade de empreendimentos híbridos utilizando as fontes eólica e solar. Em muitos casos, é apontada a existência de alguma complementaridade entre as fontes, a possibilidade de otimização dos custos de operação e de investimento, especialmente na conexão e a redução de impactos socioambientais. Por isso, os parques híbridos do tipo eólico-solar se apresentam como interessantes alternativas para investimento e de elevado potencial de viabilização para implantação efetiva, sobretudo se for considerada a tendência de expansão dessas duas fontes no território nacional.

A EPE realizou um estudo sobre usinas híbridas, em que relata experimentos em países como: Índia, China, Austrália, Estados Unidos e Reino Unido, em que a experiência internacional com usinas híbridas demonstrou que, apesar de haver potenciais benefícios, ainda existem grandes dificuldades, sobretudo comerciais e regulatórias para sua implementação. (EPE, 2019).

O Sistema de Geração Híbrida (SGH), será localizado no município de Casa Nova, estado da Bahia, Brasil, composto por um sistema de geração eólica com capacidade de 1,5 MW, um sistema de geração solar com capacidade de geração de 1 MW e um sistema de banco de baterias com capacidade de armazenamento de 1,4 MWh e potência de 1 MW. O sistema de geração funcionará de forma integrada, obedecendo manobras automáticas ou teleoperadas pela CHESF.

Por se tratar de um projeto de alta complexidade, no P&D as atividades estão divididas em subprojetos que estão sendo executados em paralelo, com equipes próprias das entidades executoras. Cada subprojeto recebeu uma designação numérica organizacional (P0 a P10), dentro da qual foram divididas as suas etapas específicas. A Figura 3 apresenta o Diagrama do Projeto de P&D da CHESF com o Senai-Cimatec.

Figura 3: Diagrama do Projeto de P&D.



Fonte: Elaborado pelo projeto.

O Subprojeto 4 está dividido em três núcleos de desenvolvimento, designados como sub-projetos P4.1, P4.2 e P4.3.

O subprojeto P4.1 é responsável por realizar o gerenciamento da planta, desenvolvendo um sistema SCADA (supervisório de controle e aquisição de dados) para a planta híbrida, integrando dados recebidos do P9 e informações climáticas obtidas das estações climáticas dispostas no site da planta híbrida. O P4.2 fará o controle avançado da planta híbrida, onde uma UTR (unidade terminal remota) se comunicará diretamente com os controladores dispostos na subestação, geração eólica, geração solar e banco de baterias. O P4.2 também se comunicará com o sistema SCADA desenvolvido no P4.1. O P4.3 será responsável por monitorar elementos do aerogerador, a fornecer subsídios para manutenção preditiva, utilizando ferramentas de inteligência artificial.

O trabalho desenvolvido nessa dissertação, faz parte do P4.3, subprojeto que tem como objetivo geral o estudo e desenvolvimento de uma aplicação de manutenção preditiva, que utilize IA para processar os dados de monitoramento de um aerogerador de ímã permanente, visando diagnóstico de falhas e tendência de quebra. O monitoramento de dados, aliado à possibilidade de previsão de eventos de demanda elétrica, irá contribuir para uma melhor integração do sistema híbrido proposto, em termos de operação e manutenção ao longo do ciclo de vida do aerogerador.

1.2 *Objetivos*

1.2.1 *Objetivo Geral*

O objetivo geral deste trabalho foi o desenvolvimento de um sistema de manutenção de turbinas eólicas de uma planta híbrida, realizando estudos iniciais exploratórios, partindo de uma prospecção tecnológica sobre ferramentas e métodos de detecção de falhas em turbinas eólicas e seguido pela construção de um modelo computacional para analisar dados históricos de plantas eólicas da CHESF, utilizando ferramentas de IA, para buscar padrões e classificar esses dados.

1.2.2 *Objetivos Específicos*

- Realizar prospecção tecnológica sobre técnicas e ferramentas desenvolvidas para detectar falhas em turbinas eólicas, além da aplicação de inteligência artificial como inovação;
- Coletar dados de operação e dos relatórios de manutenção das turbinas eólicas;
- Analisar os dados coletados, buscando verificar padrões e correlações;
- Construir um modelo computacional, utilizando ferramentas de IA, para clusterizar e classificar os dados de monitoramento das turbinas eólicas;
- Contribuir para o desenvolvimento de um sistema de manutenção de turbinas eólicas de uma planta híbrida.

1.3 *Organização da Dissertação de Mestrado*

Este documento apresenta 6 capítulos e está estruturado da seguinte forma:

- **Capítulo 1 - Introdução:** Contextualiza o âmbito, no qual a pesquisa proposta está inserida. Apresenta, portanto, a definição do problema, objetivos e justificativas da pesquisa e como esta dissertação de mestrado está estruturada;
- **Capítulo 2 - Revisão da Literatura:** Busca na produção acadêmica já publicada trabalhos correlatos que norteiem a pesquisa sobre o assunto desejado;
- **Capítulo 3 - Materiais e Métodos:** Explica os passos da pesquisa realizada;

- **Capítulo 4 - Artigo I:** Technological Advances on Fault Diagnosis in Wind Turbines: A Patent Analysis - publicado em Appl. Sci. 2023 ;
- **Capítulo 5 - Artigo II:** Exploratory analysis of a real wind turbine dataset, using AI tools to cluster and classify data, for condition monitoring and fault detection - submetido em Springer, 2023;
- **Capítulo 6 - Conclusões:** Apresenta as conclusões, contribuições e algumas sugestões de atividades de pesquisa a serem desenvolvidas no futuro.

Revisão da Literatura

2.1 Geração de Energia Eólica

A indústria de energia eólica em grande escala é relativamente nova e está se expandindo rapidamente. A energia eólica é considerada a fonte alternativa de eletricidade que mais cresce em todo o mundo. Os parques eólicos contribuem com um volume significativo de capacidade de geração elétrica, pois consistem em centenas de unidades construídas. A maioria das turbinas eólicas são unidades de três pás compostas por vários componentes. Impulsionadas pelo vento, as pás e o rotor são capazes de passar energia para o gerador, de modo que a velocidade do gerador, seja a mais próxima possível, da velocidade de geração ideal de eletricidade. Portanto, a capacidade de uma turbina eólica de extrair energia do vento é uma função de três fatores principais: a velocidade medida do vento, a curva de potência da turbina e a capacidade da turbina de lidar com as flutuações do vento (BOUKHEZZAR; SIGUERDIDJANE; HAND, 2006) (ELIJORDE; KIM; LEE, 2014).

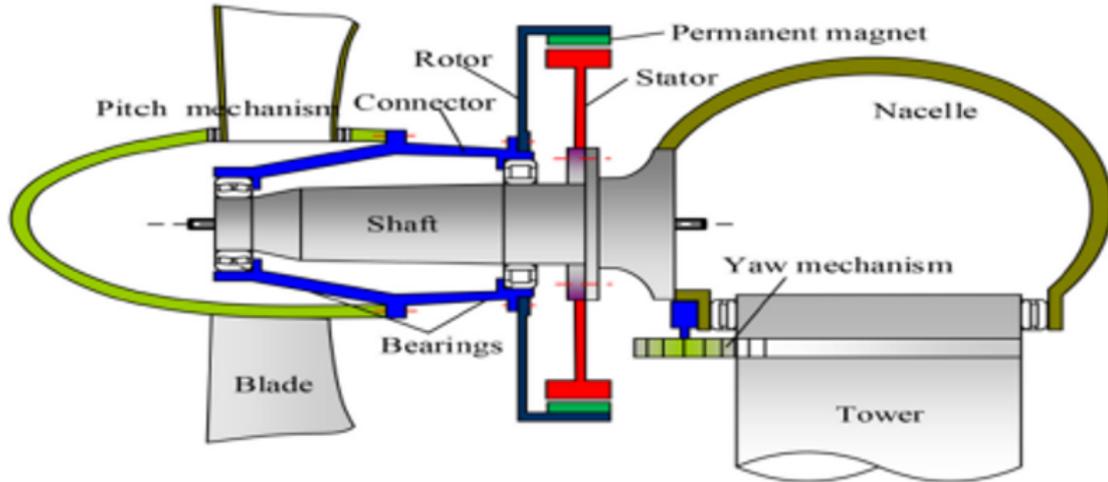
A maioria dos subsistemas em turbinas eólicas pode falhar durante a operação, incluindo rotores e pás, sistemas de controle de inclinação, caixas de engrenagens e rolamentos, sistemas de guinada, geradores, eletrônica de potência, controles elétricos e freios, entre outros. Como as turbinas eólicas estão localizadas em locais remotos de difícil acesso, sua manutenção se torna um problema (ELIJORDE; KIM; LEE, 2014).

Sistemas de turbinas eólicas são subdivididos em duas categorias: velocidade fixa e variável. Os aerogeradores de velocidade fixa, usualmente utilizam um sistema de caixa de engrenagens responsável por converter a rotação baixa e variável das pás eólicas em uma rotação fixa e elevada, a qual é essencial para o tipo de gerador utilizados nessa categoria de turbina. Esse mecanismo permite o uso de geradores de massa menor e evita o uso de equipamentos complexos de geração de energia com grande número de polos e alta complexidade (DUAN; HARLEY, 2009).

No entanto, a caixa de engrenagem (ou gearbox), utilizada em todas as turbinas eólicas de velocidade fixa, é um componente crítico e de baixa confiabilidade. Eliminar o custo de falha e downtime das caixas de engrenagem é um dos principais motivos para usos de aerogeradores de velocidade variável, ou direct-drive. Esses equipamentos não apresentam caixa de engrenagem, mas sim geradores de maior complexidade, capazes de converter a baixa rotação das pás eólicas em energia elétrica alternada, atendendo aos critérios de frequência desejados. Dentre as possibilidades de aerogeradores direct-drive está o gerador síncrono de ímãs permanente, apresentado na Figura 4. Este tipo de turbina

eólica (referência IMPSA IV-82) foi o escolhido para o projeto.

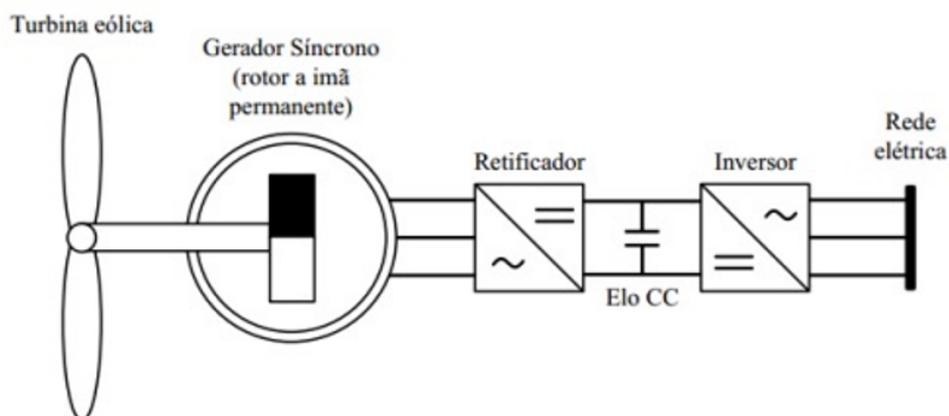
Figura 4: Esquema de Motor de Gerador de Ímã Permanente



Fonte: Faard, 2020.

Os aerogeradores que utilizam PMSGs - Permanent Magnet Synchronous Generators são construídos com elevado número de polos, fato este que garante um bom desempenho em baixas velocidades e, por consequência, a eliminação da caixa multiplicadora de velocidades. Dessa forma vão existir menos partes móveis, o que implica em uma maior confiabilidade e menos manutenções, sejam preventivas ou corretivas, o que é vantajoso tanto pela economia de insumos e de mão de obra, quanto pela redução do tempo com o equipamento fora de operação, também chamado downtime (OLIVEIRA, 2018). A Figura 5 ilustra os principais componentes de uma turbina PMSG.

Figura 5: Turbina eólica PMSG



Fonte: Oliveira, 2018.

2.1.1 Aerogerador IMPSA IV-82

O aerogerador é baseado no conceito de transformação de energia cinética proveniente do vento, em energia elétrica produzida através do gerador. O vento movimentando as pás e faz girar o rotor, que transmite a rotação ao gerador, e, por sua vez, converte essa energia mecânica em energia elétrica. Localizado dentro ou perto da torre, existe um transformador para elevar a tensão de geração para que a energia possa ser transmitida pelas linhas de média tensão da rede até uma subestação. A turbina IMPSA IV-82 utiliza o princípio de geração através de ímãs permanentes (direct drive). As especificações técnicas dessa turbina estão listadas na Tabela 3.

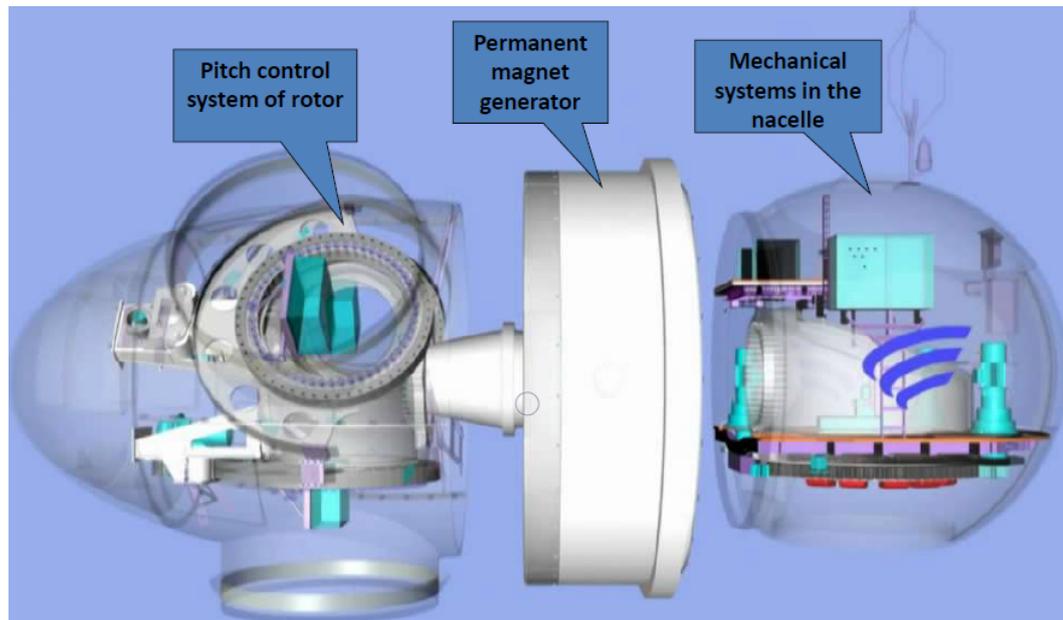
Tabela 3: Especificações Técnicas do Aerogerador

Especificações Técnicas	
Gerador	3 fases (2x) PMSG
Modelo	IMPSA IV-82
Potência nominal	1.500kW
Diâmetro do rotor	82m (GW 82 / 1500)
Velocidade de cut-in do vento	3m/s
Velocidade nominal do vento	11.8m/s, 11m/s, 10.3m/s, 9.9m/s respect.
Velocidade de cut-out do vento	22 ~ 25m/s (10 min em média)
Velocidade de destruição	60m/s (3 min em média)
Tensão nominal (grid)	690 V ou 620 V
Frequência nominal (grid)	50 Hz ou 60 Hz
Velocidade de rotação	9 ~ 21 rpm
Peso da nacela (excluindo rotor e gerador)	11 ton
Peso do gerador	44 ton
Peso do rotor (incluindo rotor e hub)	28 ton

Um aerogerador é composto por diversas partes elétricas, eletrônicas e mecânicas, sendo que, cada uma possui uma função única e específica. Fundamentalmente, o aerogerador está dividido em cinco sistemas principais: rotor, gerador, nacela, conversor e quadro principal.

A Figura 6 ilustra a estrutura mecânica geral do aerogerador, que engloba três dos sistemas citados: o rotor, o gerador e a nacela, vamos detalhar melhor esses sistemas.

Figura 6: Estrutura mecânica geral do aerogerador



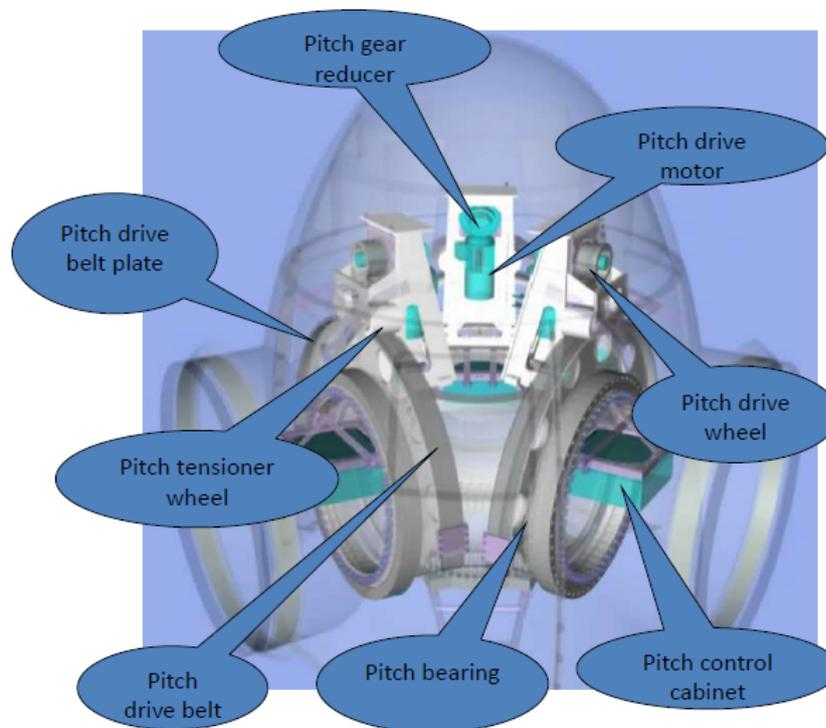
Fonte: Treinamento Goldwind, 2022.

- **Rotor:** parte do aerogerador responsável pela conversão de energia cinética do vento em energia mecânica, e que posteriormente é transformada em energia elétrica através do gerador eólico. O rotor também pode ser classificado em duas formas: rotores de eixos verticais e de eixo horizontais. Turbinas de eixo horizontais são mais utilizadas por sua maior eficiência e maior potência gerada, mas precisam ser instalados em locais mais altos, para um maior aproveitamento do vento. O rotor pode ser subdividido em três partes:
 - **Pás:** componentes responsáveis pela captação do vento, e assim fazer com que o rotor entre em movimento. Atualmente, os compostos mais utilizados para a fabricação das mesmas são a fibra de vidro combinadas com malhas de Aramida (popularmente chamada de Kevlar) ou combinadas com epóxi ou poliéster, conferindo uma boa combinação de durabilidade e leveza. Porém, mesmo utilizando materiais leves, devido ao seu tamanho, uma única pá pode pesar mais de 10 toneladas. Essas pás garantem o movimento do cubo, e conseqüentemente a conversão de energia cinética dos ventos, em energia mecânica do rotor;
 - **Pitch drive (ou controle de passo):** é o responsável pela variação do ângulo das pás, sendo assim ele possui duas funções bastante importantes, executa a mudança de ângulo das pás para que a turbina consiga uma maior eficiência e uma maior geração de potência em qualquer velocidade entre as velocidades de cut-in (velocidade mínima de vento para o início de geração) e cut-out (velocidade máxima de vento para a geração). A outra função do pitch drive é a segurança. Uma vez ultrapassada a velocidade de vento necessária para que a

turbina atinja sua potência de operação nominal, ele atua modificando os ângulos das pás constantemente para que não haja uma sobrevelocidade da turbina e danos aos geradores e demais partes. E, caso a velocidade do vento exceda a velocidade de cut-out, ele atua colocando o ângulo das pás em um valor que sirva de freio aerodinâmico para turbina;

- **Hub (ou cubo):** ponto de ligação entre a nacele e as pás. Geralmente feito de aço, também abriga equipamentos necessários para o acionamento e desligamento do pitch drive dentre eles o pitch box: caixa de comando do pitch drive e responsável pela comunicação entre os sensores e o slip-ring localizados na nacele, com o pitch drive.

Figura 7: Componentes do sistema de pitch

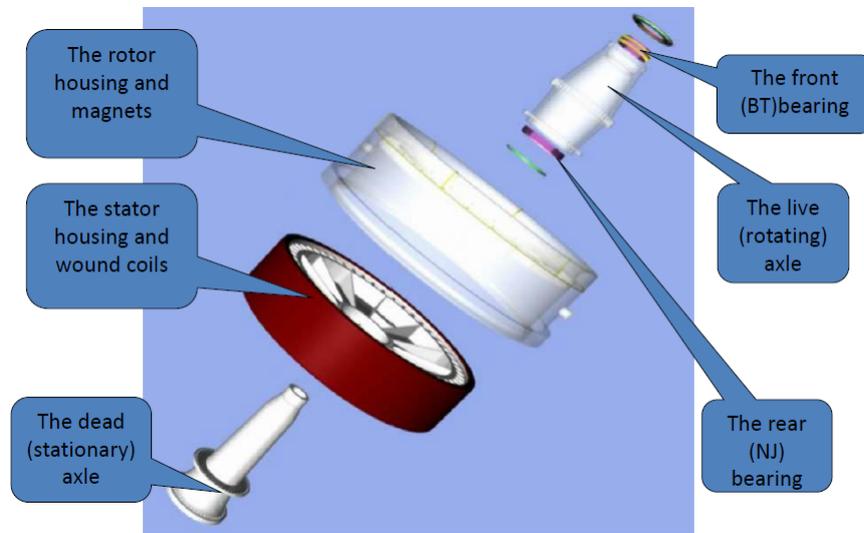


Fonte: Treinamento Goldwind, 2022.

- **Gerador:** responsável por transformar a energia mecânica do rotor em energia elétrica, são divididos em dois tipos: síncronos e assíncronos. Os assíncronos, geralmente, possuem velocidade de operação muito superior à velocidade de rotação da turbina, por isso, é comum, nesse tipo de gerador, uma caixa multiplicadora de rotação entre o rotor e o gerador. Já os geradores síncronos, são dotados de ímãs com vários pólos e conseguem uma faixa de atuação com uma rotação mais baixa, utilizando um planetário de um único estágio; O gerador pode ser dividido em duas partes principais: o estator, que é sua parte fixa, que, em alguns modelos que precisam de excitação para a geração de campo magnético, essa parte também serve de entrada de alimentação para a geração do campo magnético; e o eixo-rotor, parte

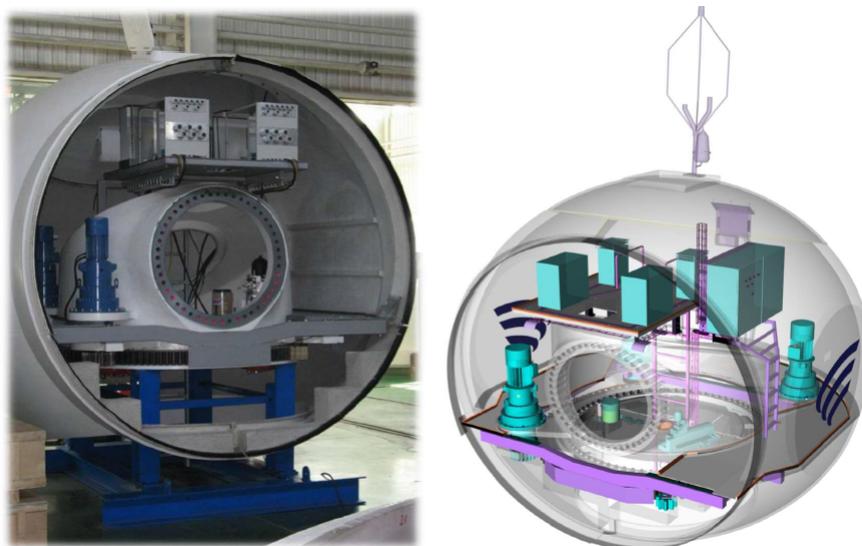
girante do gerador.

Figura 8: Configuração e peças do gerador



Fonte: Treinamento Goldwind, 2022.

Figura 9: Nacele



Fonte: Treinamento Goldwind, 2022.

- **Nacele:** estrutura responsável por abrigar a maior parte dos equipamentos elétricos, eletrônicos e mecânicos do aerogerador. Devido a sua função de resguardar vários outros equipamentos, é a parte mais pesada do aerogerador. Das partes protegidas pela nacele, podemos destacar: o gerador, o sistema yaw e a topbox. Mas devido a sua posição, ela também é responsável por acoplar no seu exterior outros sensores e equipamentos essenciais para o funcionamento da turbina, como os anemômetros, birutas e pára-raios. Comumente é produzida com os mesmos materiais das pás, ou

seja, fibra de vidro misturado com algum outro composto;

- **Yaw-Drive (ou Sistema Yaw):** é responsável pela orientação da nacele em relação ao vento. O sistema de orientação utiliza dados de sensores (anemômetros e windvane) . O drive é composto por dois ou mais motorreduzidores, a coroa de yaw e pelas pinças de freio;
- **Coroa de Yaw:** localizado entre a nacele e o último segmento da torre, junto com os motorreduzidores, o disco (que é responsável por dar o suporte necessário para as pinças de freio atuarem) e o yaw bearing (rolamento existente abaixo do disco que possuem a função de ajudar a rotação da nacele), é responsável pela rotação da nacele sempre em busca da melhor orientação em relação ao vento do momento para a maior geração de energia;
- **Pinças de freio:** uma vez orientada, para evitar deslocamentos inesperados devido a força dos ventos, as pinças de freio possuem a função de parar e manter a nacele parada na posição determinada pelos sensores e posta pelo Yaw drive. Geralmente possuem acionamento hidráulico através do sistema hidráulico de freios. Em alguns casos, as pinças utilizadas para a frenagem podem exercer uma força de mais de 150kN para parada completa da nacele no momento que são acionadas;
- **Sistema Hidráulico de Freio:** formado por um pequeno motor elétrico, um reservatório para óleo e algumas bombas hidráulicas, esse sistema tem como função a ativação e desativação das pinças hidráulicas (responsáveis pela frenagem da nacele) e dos pinos hidráulicos (responsáveis pela trava do rotor, caso, alguma intervenção ou manutenção seja necessária dentro do hub). Possuem valores de pressão variáveis dependendo da potência do aerogerador, e em alguns casos, também possuem ativação e desativação através de bombas manuais para situações de emergência ou de intervenções sem a presença de eletricidade na torre;
- **Sistema Hidráulico de Lubrificação:** é formado por uma bomba e por pinhões de lubrificação, tem a função de manter a coroa do yaw sempre lubrificada em intervalos pré-programados ou em momentos que o operador ache necessário;
- **Top Box:** localizado dentro da nacele, ele tem a função de armazenar e proteger os equipamentos de comando da torre. Nele estão contidos os comandos de todos os equipamentos elétricos e eletrônicos localizados na nacele. Nele também estão localizados os equipamentos responsáveis por receber, tratar e transmitir as informações de sensores internos e externos para a pitch box;
- **Disjuntores:** possuem a função de proteção da top box e de todos os circuitos elétricos da torre. Ele é o responsável pela proteção da top box e dos demais componentes em casos de sobre-tensões e de curtos-circuitos. Na turbina estudada há a presença de dois disjuntores, isso se dá pelo fato de cada disjuntor

ser responsável por um circuito trifásico do bobinado que sai diretamente do gerador da turbina.

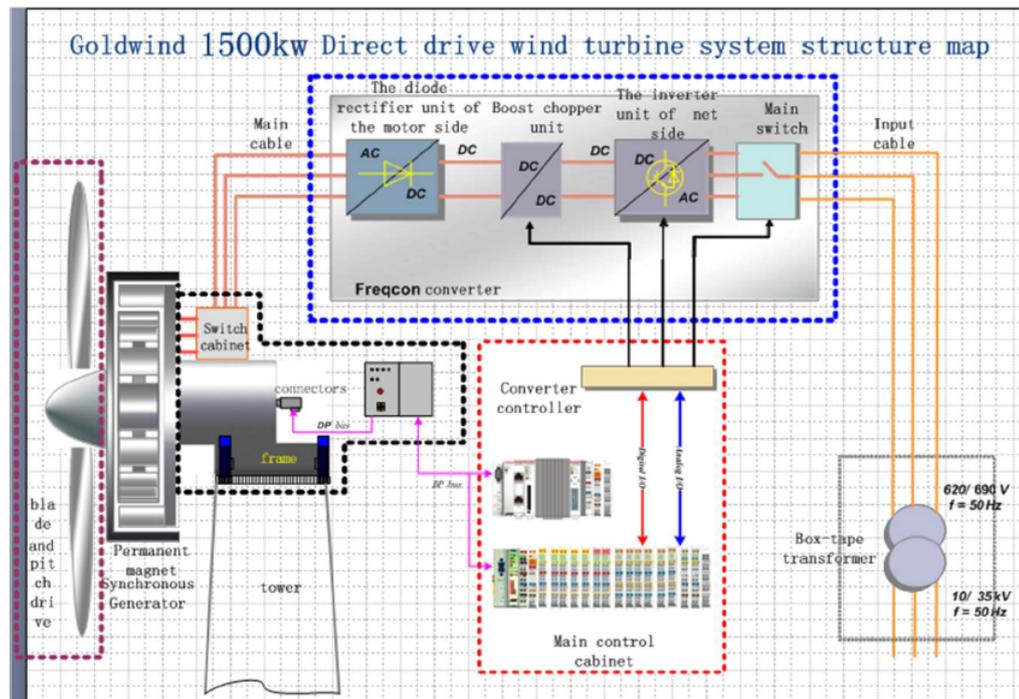
Figura 10: Conversor de frequência



Fonte: Treinamento Goldwind, 2022.

- **Conversor:** nos geradores síncronos de velocidade variável, como a velocidade de giro do rotor não é constante, as frequências dos sinais de corrente e tensão também são variáveis. Por esta razão, para promover uma equalização entre tensão e frequência da saída do gerador e rede elétrica são utilizados os conversores AC/AC. Nas turbinas eólicas, um conversor AC/AC pode ser dividido em seus estágios de conversão: Retificador, DC-Link e Inversor;
 - **Retificador:** formado por dois grupos de diodos retificadores, o retificador tem a função de fazer com que a corrente de frequência alternada proveniente do gerador síncrono, seja convertida em um sinal de corrente contínua;
 - **DC-Link:** é um dos componentes do Retificador, responsável pelo controle da tensão CC;
 - **Inversor:** o inversor dos conversores AC/AC tem a função de converter o sinal CC do DC-LINK para um sinal AC sincronizado com a frequência da rede de distribuição ao qual estará conectado;

Figura 11: Esquema do Freqcon no aerogerador



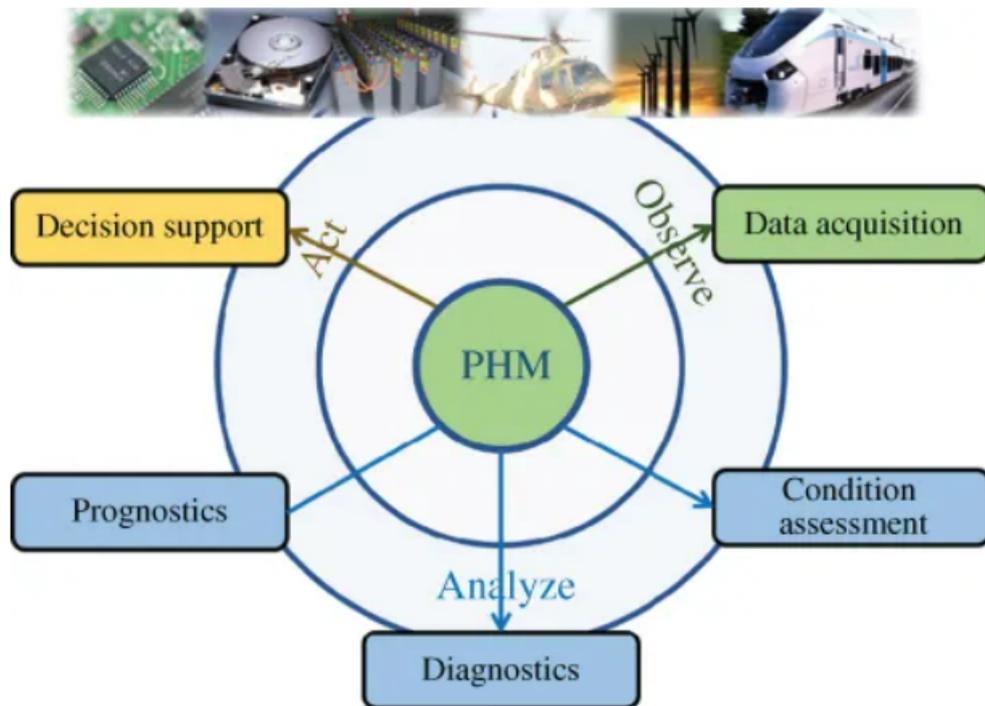
Fonte: Treinamento Goldwind, 2022.

- **Quadro principal:** localizado na base da torre, tem como função alocar e proteger diversos itens cruciais para o funcionamento da máquina como por exemplo: fibras de comunicação, UPS, Controladores, CLP's, dentre outros.
 - **UPS (Uninterruptible Power Supply):** tem a função de alimentar o quadro principal e os sistemas principais da turbina por um curto período de tempo caso haja alguma falha na alimentação principal. É formada por um conjunto de baterias que fornecem energia em caso de falha na alimentação para que dados importantes não sejam perdidos devido a queda abrupta de energia. Ela também tem a função de proteger os equipamentos do quadro principal contra picos de tensão e corrente que podem ocorrer na entrada de alimentação do próprio quadro;
 - **IHM (Interface Homem-Máquina):** tem como função promover a integração de comandos entre o operador e a turbina, e também para a leitura correta de dados críticos ou importantes para o diagnóstico de alguma possível falha na turbina;
 - **Controlador:** é o equipamento mais importante da turbina. O controlador tem a função de tratar todos os dados gerados pelos sensores da máquina e atuar nos controles dos sistemas de Pitch, Yaw e conversor. Nele também estão presentes todas as configurações necessárias para o funcionamento de sistemas eletrônicos da turbina.

2.2 Manutenção

Em geral, o PHM consiste em sensoriamento, detecção de anomalias, diagnósticos, prognósticos e suporte à decisão, conforme mostrado na Figura 12. A detecção é coletar um histórico da operação dependente do tempo de um produto, a degradação dos materiais e/ou as cargas ambientais nos componentes de um produto ou no produto total (PECHT; KANG, 2018).

Figura 12: Estrutura para prognósticos e gerenciamento de saúde.



Fonte: Pecht & Kang, 2018

O objetivo principal da detecção de anomalias é identificar o comportamento estranho, incomum ou inesperado (anômalo) do produto, identificando desvios do comportamento nominalmente saudável. Os resultados da detecção de anomalias podem fornecer avisos avançados de falha, geralmente chamados de precursores de falha.

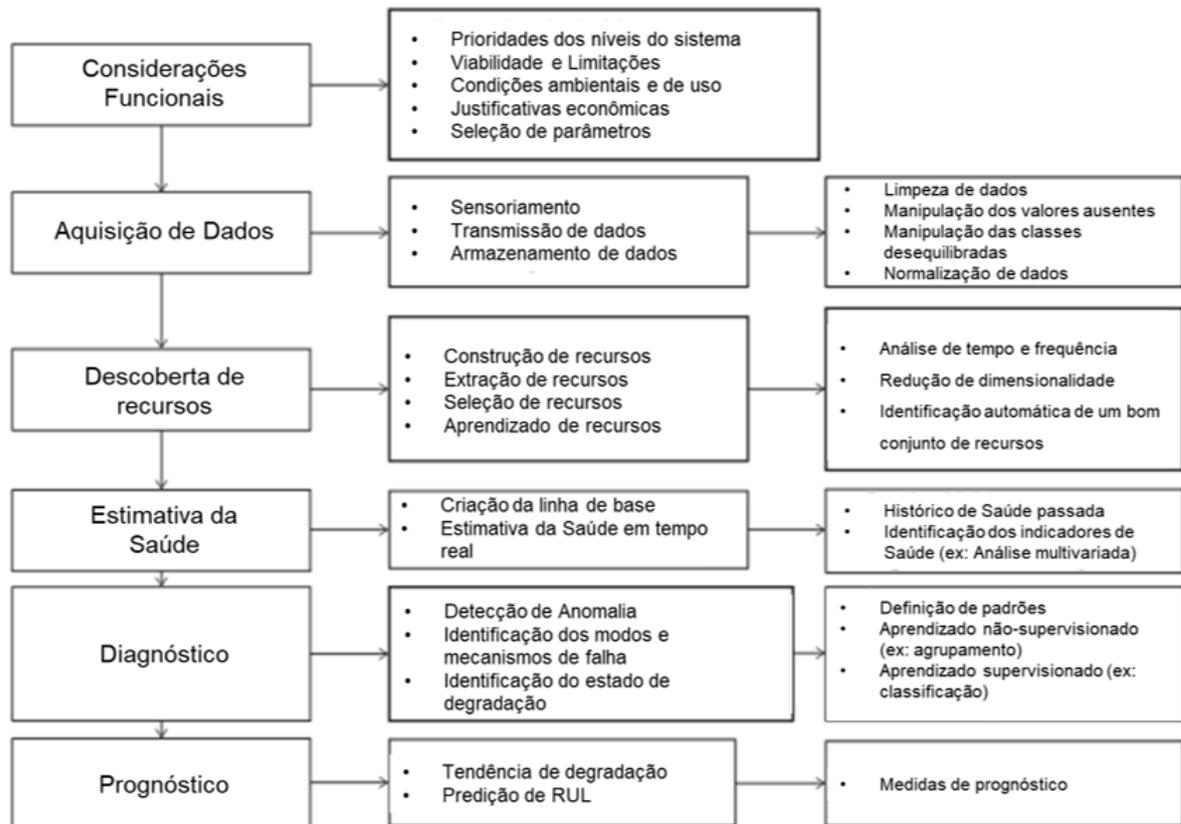
O diagnóstico permite a extração de informações relacionadas a falhas, como modos de falha, mecanismos de falha, quantidade de dano e assim por diante, de dados do sensor causados por anomalias na integridade do produto. Esta é uma informação chave que alimenta o planejamento de manutenção e a logística.

Dentre as abordagens possíveis para a execução das etapas de análise de PHM, os modelos baseados em dados (Data-Driven) são amplamente utilizados nas etapas de diagnóstico e

prognóstico. Nesses casos, uma quantidade grande de dados é coletada e armazenada, e modelos de estatística ou aprendizagem de máquina reconhecem e reproduzem os padrões entre os fenômenos de falha do equipamento e os indicadores de saúde deles.

A Figura 13 apresenta um esquema de etapas para a execução do PHM via abordagens Data-Driven.

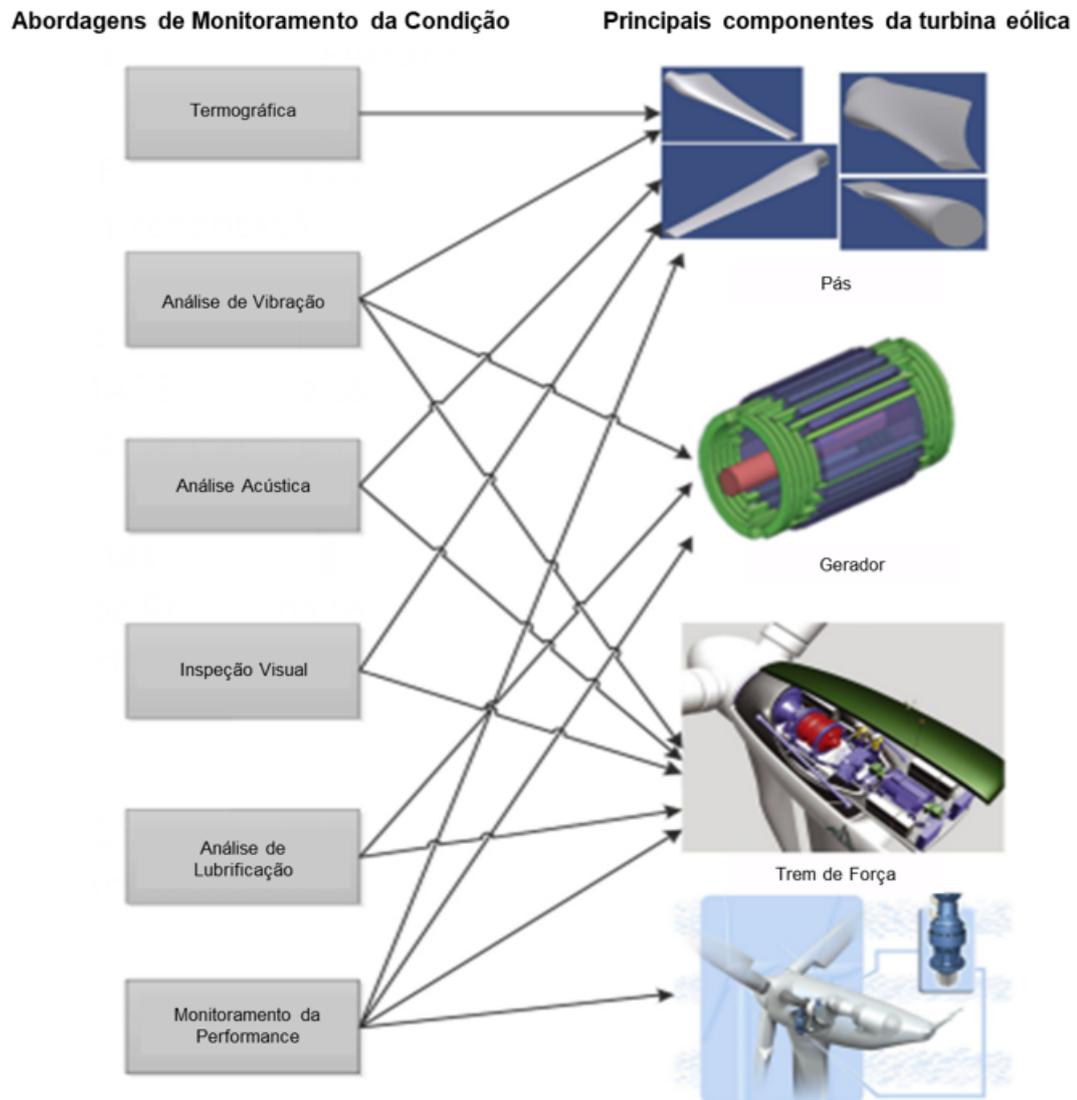
Figura 13: Esquema de abordagem Data-Driven.



Fonte: Pecht & Kang, 2018

Os trabalhos de PHM para aerogeradores são amplamente presentes na literatura. (KUSIAK; ZHANG; VERMA, 2013) apresentam uma revisão de literatura com abordagens de controle, operação e monitoramento da condição de aerogeradores. A Figura 14 apresentada no documento esquematiza a relação entre variável monitorada e componente associado à falha.

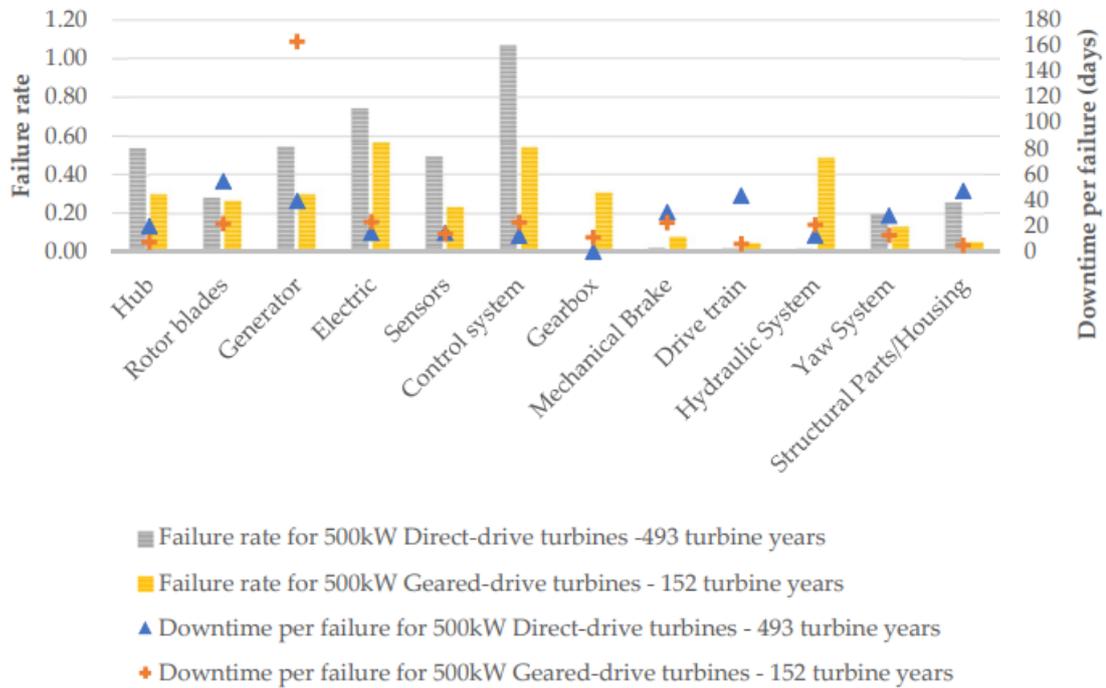
Figura 14: Monitoramento x Componente Aerogerador.



Fonte: Kusiak et. al., 2013.

O tipo de aerogerador influencia diretamente na criticidade dos modos de falhas do equipamento. Para aerogeradores de gerador de ímã permanente síncrono (ou direct-drive), observa-se uma presença maior de falhas relacionadas aos componentes eletrônicos do sistema. Além disso, também é possível observar na Figura 15 que as taxas de falhas em sensores e sistema de controle das turbinas direct-drive são substancialmente maiores que os outros modos de falhas. Apesar disto, observa-se um tempo menor de downtime para estas falhas eletrônica do que em falhas de geradores, pás, sistema yaw e problemas estruturais (OZTURK; FTHENAKIS; FAULSTICH, 2018).

Figura 15: Comparação da taxa de falha anual de turbinas direct-drive e geared-drive.



Fonte: Ozturk et. al., 2018.

A IA pode otimizar a saída e detectar possíveis falhas de equipamentos antes que se tornem problemas mais sérios, ou seja, manutenção preditiva (HUTCHINSON; ZHAO, 2023).

2.3 Aprendizado de Máquina

A indústria de energias renováveis está passando por uma rápida transformação digital. A gama de tecnologias digitais permitirá a transformação dos sistemas de energia e uma melhor integração das fontes renováveis. Geradores, operadores de sistema e consumidores aproveitarão cada vez mais a IA, para fazer previsões mais confiáveis e melhorar as operações. A indústria já está testemunhando o uso de dados para manipular a demanda, melhorar a previsibilidade em padrões climáticos e na produção de energias renováveis, e isso permitirá aos consumidores se tornarem mais ativos no mercado (LEE; ZHAO, 2022).

A aprendizagem de máquina é a área de estudo que foca no desenvolvimento de sistemas capazes de acessar dados e, a partir deles, reconhecer e reproduzir padrões, aprendendo-os e melhorando a performance com a experiência ao realizar determinada tarefa (MITCHEL, 1997).

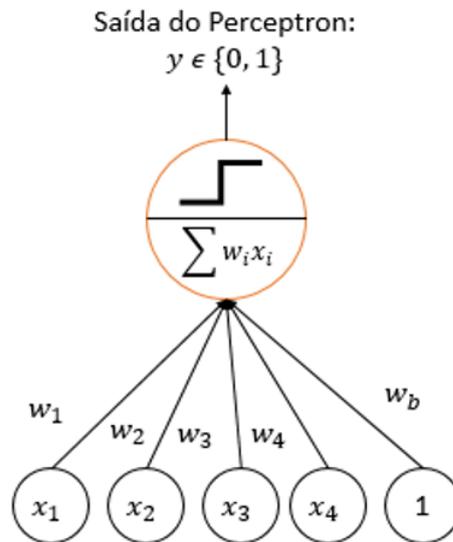
Os modelos de aprendizagem de máquina podem ser categorizados entre: supervisionados, não supervisionados, semissupervisionados e por reforço. No primeiro caso, os dados são previamente rotulados e a tarefa de aprendizagem de máquina é realizar previsão de valores de uma variável dependente “y” a partir dos valores de uma variável independente “x”. Portanto, a ideia de aprendizagem supervisionada gira em torno de construir uma função preditiva $y = f(x)$.

Já os algoritmos não-supervisionados, não requerem a presença do rótulo que, na maioria dos casos, são caros de serem obtidos por exigirem um especialista responsável por anotá-los para cada um dos dados, os quais podem ser da ordem de milhares, milhões, bilhões ou até mesmo mais. Dessa forma, tais modelos devem aprender, de forma implícita ou explícita, a densidade de probabilidade que gerou tais dados, as regras de associação os grupos de padrões existentes, o que levam a um processo mais complexo de análise que os supervisionados (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.3.1 Redes Neurais

As redes neurais estão presentes na literatura há um período relativamente grande. O algoritmo de redes neurais foi proposto pela primeira vez pelo neurocientista Warren McCulloch (1943), que apresentou em estudos a estrutura das redes neurais como uma modelagem matemática e simplificada do processamento de dados em neurônios biológicos, partindo daí a inspiração biológica na fundamentação desses algoritmos. Em 1957, o perceptron, uma das estruturas mais simples de redes neurais, foi proposto. Nesse caso, ela é composta de apenas um operador de função degrau conectado a um somatório ponderado dos dados de entrada ($x \in \mathbb{R}^n$). Na Figura 16, é possível observar que o operador transforma uma combinação linear dos dados de entrada em um valor binário. O treinamento do Perceptron, assim, consiste em encontrar os pesos w que minimizam uma função, a qual associa a saída ($y \in 0,1$) a um erro de classificação.

Figura 16: Modelo Perceptron.

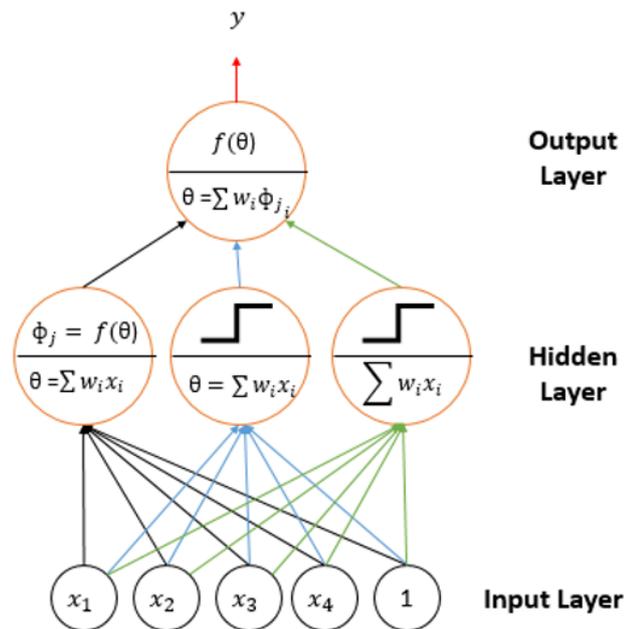


Fonte: Elaborado por P4.3

No entanto, um modelo perceptron só é capaz de resolver problemas lineares, os quais não correspondem à grande parte dos problemas reais de classificação e regressão (GÉRON, 2019). Apesar desse problema, os modelos perceptron (ou neurônios artificiais) podem ser combinados e formar as redes neurais artificiais como são conhecidas na atualidade. Tais estruturas são capazes de gerar funções para realizar atividades supervisionadas ou não supervisionadas.

Uma rede neural de perceptrons multicamadas (MLP – Multi-Layer Perceptron) é composta por uma camada de entrada de dados, uma de saída e pelo menos uma camada escondida com mais de um neurônio. Quando uma rede neural possui uma quantidade relativamente grande de camadas, entende-se que ela faz parte da família de algoritmos de aprendizagem profunda (GÉRON, 2019). A Figura 17 mostra um exemplo de estrutura de MLP. Nota-se que as saídas dos neurônios são combinadas linearmente e processadas a partir de uma função de ativação dos neurônios das camadas posteriores.

Figura 17: Multi-Layer Perceptron.



Fonte: Elaborado por P4.3

A natureza da saída da rede neural depende do contradomínio da função de ativação da última camada. O treinamento de uma rede MLP consiste em uma busca estruturada dos valores dos pesos a partir de uma minimização de medidas de erros da classificação ou regressão.

2.4 Trabalhos Correlatos

(KUSIAK; VERMA, 2012) propuseram um processo de três estágios para prever falhas em turbinas eólicas: prever qualquer tipo de falha, prever falhas específicas do sistema e, em seguida, identificar possíveis falhas. Após o pré-processamento dos dados, cinco algoritmos de aprendizado de máquina: 1. Rede Neural, 2. Support Vector Machine, 3. Random Forest, 4. Boosting Tree e 5. Algoritmo do detector de interação automática qui-quadrado, foram usados para prever os valores de quatro eventos: 1. Turbine OK, 2. Falha, 3. Tempo de inatividade, 4. Inatividade de manutenção. Para os resultados finais, o Random Forest relatou o melhor resultado.

(ZHANG; ZHOU; KUSIAK, 2014) testaram sete algoritmos de aprendizado de máquina: 1. Rede Neural, 2. Conjunto de Redes Neurais, 3. Support Vector Machine, 4. Boosting Tree, 5. Random Forest, 6. K-Vizinho Mais Próximo, e 7. Árvore de Classificação e Regressão, para diagnosticar falhas. As entradas do modelo incluem: energia eólica gerada, velocidade de rotação do motor, torque e temperatura das peças da turbina eólica.

Foi usado o erro percentual absoluto para medir os erros de previsão. Como resultado, a rede neural e o conjunto de redes neurais foram os modelos que obtiveram o menor erro de 0,01, enquanto o Random Forest foi o seguinte melhor algoritmo com um erro de 0,06.

(LIU et al., 2016) usaram K-means e classificação RNA - rede neural artificial para prever falhas no sistema de caixa de engrenagens da turbina eólica. Primeiro, após o pré-processamento dos dados, o K-means foi usado para agrupar dados com características semelhantes em vários clusters. Os resultados do agrupamento de dados foram então predito pela classificação usando RNA. Comparado com a classificação de redes neurais tradicionais, esse método melhorou a precisão da previsão em 3,5%. Com o modelo proposto, falhas mecânicas podem ser detectadas de forma mais precisa e oportuna.

(TURNBULL et al., 2019) construíram um banco de dados de falhas em rolamentos, com base em dados reais de turbinas eólicas e resultante do cruzamento entre falhas identificadas em relatórios de O&M e dados do SCADA, então treinaram algoritmos de aprendizado de máquina para classificar rolamentos como saudáveis ou não.

(HSU et al., 2020) aplicaram técnicas de controle estatístico de processo e aprendizado de máquina para diagnosticar falhas de turbinas eólicas e prever necessidades de manutenção analisando 2,8 milhões de dados de sensores coletados de 31 turbinas eólicas, de 2015 a 2017 em Taiwan. Usaram análises de pareto, gráficos de dispersão e diagrama de causa e efeito para agrupar e classificar os tipos de falha de turbinas eólicas. Construíram dois modelos de predição usando o Random Forest e o algoritmo de árvore de decisão, ambos com validação cruzada K-fold. Os resultados indicam um alto nível de precisão: 92,68% para o modelo de árvore de decisão e 91,98% para o modelo de Random Forest.

(EL-MENSHAWY; GUL; EL-THALJI, 2021) analisaram um conjunto de dados de dois anos de uma turbina eólica SCADA, usando algoritmos de aprendizado de máquina, como: árvore de decisão aprimorada, floresta de decisão e cluster K-means, no Azure ML Learning Studio, com o objetivo de explorar os potenciais benefícios dos dados SCADA para propósitos de manutenção e discutir as limitações pela perspectiva de aprendizado de máquina.

O diferencial desse trabalho é que ele faz parte de um projeto maior de uma planta híbrida, além de trabalhar com dados reais, já coletados dos relatórios de O&M e de monitoramento do SCADA, das plantas em operação na CHESF. Além de que, existem poucos estudos sobre aerogeradores de ímã permanente.

Materiais e Métodos

3.1 Prospecção Tecnológica

Foi realizada uma análise exploratória de patentes existentes relacionadas à detecção de falhas em turbinas eólicas, utilizando o banco de dados Derwent Innovation Index (DWPI), Thomson Innovation©, licenciado para uso pelo SENAI CIMATEC - Centro Universitário. Essa busca foi feita em 19 de agosto de 2022.

Foram escolhidas palavras-chave, relacionadas ao tema desejado, além dos códigos da Classificação Internacional de Patentes (IPC). A Figura 18 apresenta os códigos utilizados na prospecção, com o que cada código está relacionado.

Figura 18: IPC codes used in the prospecting of current patent technology.

IPC Code	Regarding
F03D	Wind Motors
G01H	Measurement of Mechanical Vibrations or Ultrasonic, Sonic, or Infrasonic Waves
G01M	Testing Static or Dynamic Balance of Machines or Structures; Testing of Structures or Apparatus, Not Otherwise Provided For
G01R	Measuring Electric Variables; Measuring Magnetic Variables (Indicating Correct Tuning of Resonant Circuits H03j3/12)
G01J	Measurement of Intensity, Velocity, Spectral Content, Polarization, Phase, or Pulse Characteristics of Infra-Red, Visible, or Ultra-Violet Light; Colorimetry, Radiation Pyrometry (Light Sources F21, H01J, H01K, H05B; Investigating Properties of Materials by Optical Means G01N)
G01K	Measuring Temperature; Measuring Quantity of Heat; Thermally Sensitive Elements Not Otherwise Provided For (Radiation Pyrometry G01j5/00)

Fonte: Autoria própria.

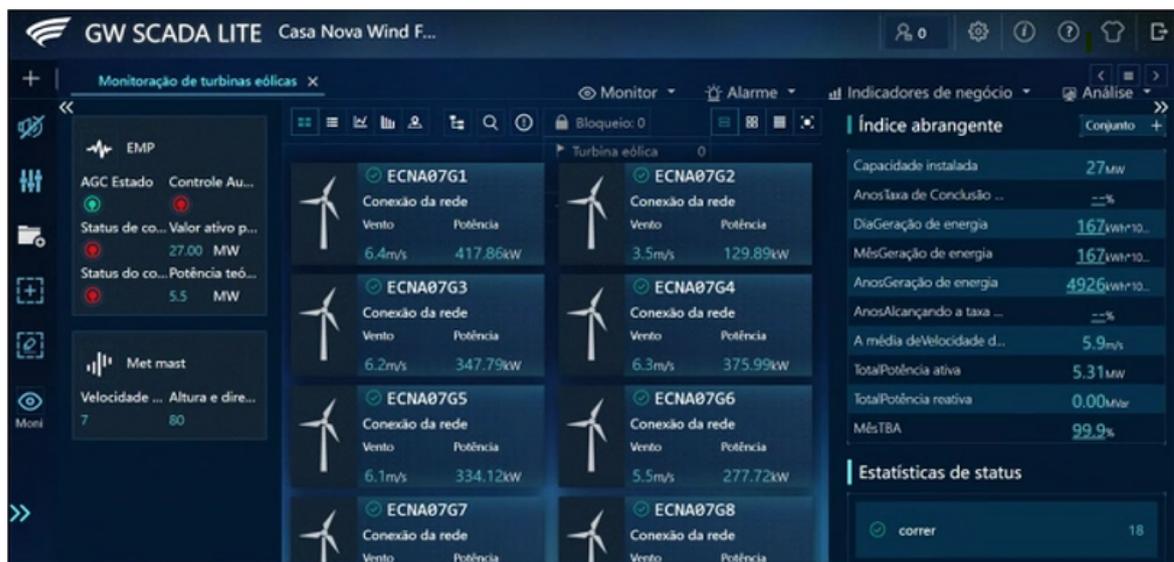
Também foi realizada uma busca exploratória secundária, adicionando a palavra-chave “machine learning”, considerando os mesmos códigos IPC, para uma pesquisa ainda mais específica.

Foi feito o download das patentes encontradas e uma análise geral, para selecionar as mais relacionadas ao trabalho que o grupo do projeto P4.3. está desenvolvendo.

3.2 Coleta de Dados

A CHESF está fornecendo dados das usinas eólicas para o grupo do P4.3 utilizar nos estudos. Para esse trabalho foram disponibilizados dados de monitoramento dos aerogeradores, baixados do SCADA - Supervisory Control And Data Acquisition, além dos relatórios de manutenção disponibilizados pela empresa que presta o serviço de manutenção do parque de Casa Nova A, a Goldwind. A Figura 19 apresenta uma tela do SCADA da Goldwind.

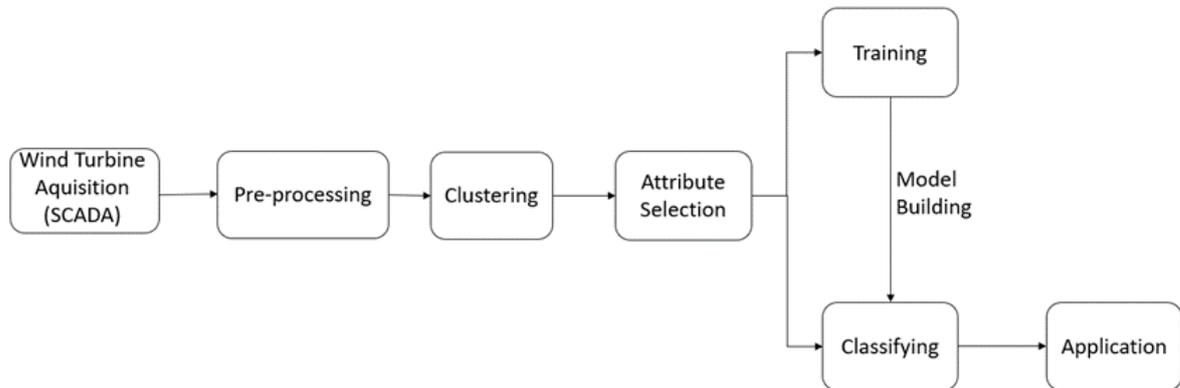
Figura 19: SCADA da Goldwind.



Fonte: Autoria própria.

As etapas seguintes, para o desenvolvimento do modelo computacional, estão representadas no procedimento apresentado na Figura 20 e serão detalhadas nas próximas sessões desse capítulo.

Figura 20: Procedimento de como foi desenvolvido o modelo computacional.



Fonte: Autoria própria.

3.3 Pré-processamento

Antes de iniciar o pré-processamento, foram analisados os relatórios de O&M disponibilizados pela Goldwind, empresa que é contratada pela CHESF para realizar a manutenção dos aerogeradores do Parque Eólico de Casa Nova A. Com isso, foram escolhidos períodos específicos que continham falhas, no intervalo de tempo dos dados baixados do SCADA, para ser possível analisar os diferentes comportamentos existentes.

O banco de dados utilizado foi resultado de um fragmento de quase quatro meses, de medições a cada dez minutos, esses dados precisaram ser pré-processados, pois os arquivos obtidos do SCADA estão em vários arquivos CSV que precisam ser unificados, também foi necessário realizar uma tradução dos dados que estavam em chinês, além da sincronização e uso de métricas como: média, moda e mediana, para adicionar e remover valores duplicados. A Figura 21 apresenta essa etapa inicial de pré-processamento dos dados.

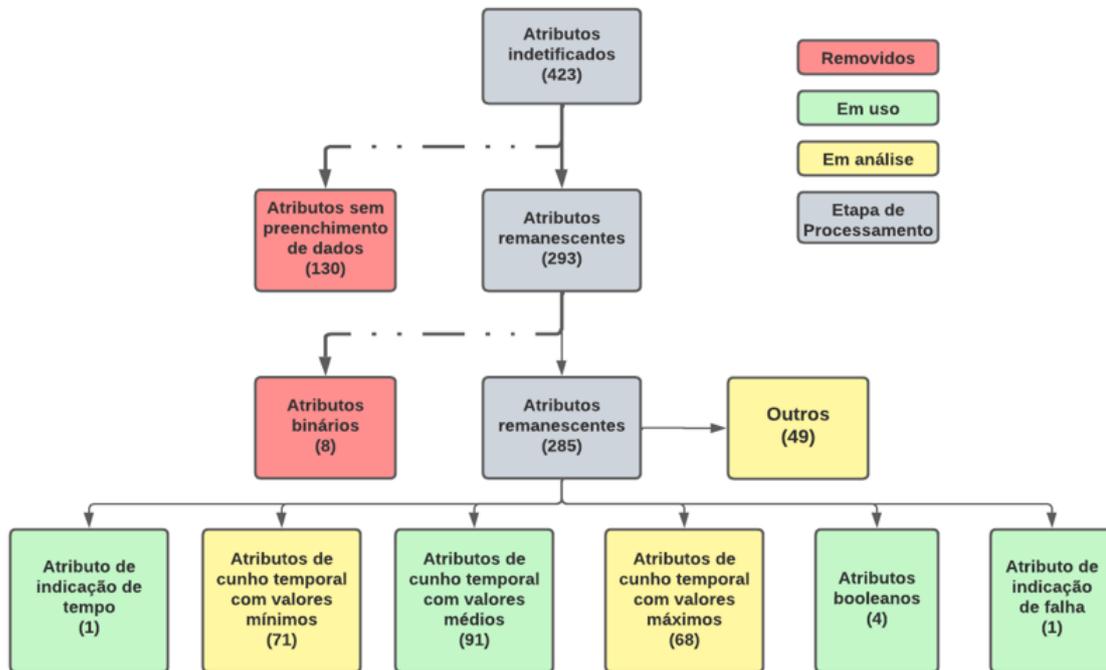
Figura 21: Pré-processamento primário.



Fonte: Elaborado por P4.3

O resultado é um único arquivo CSV, mas para poder aplicar as técnicas de IA, ele precisa ser mais refinado. Partindo então de 423 atributos, foi necessária uma análise mais profunda dos dados existentes para trabalhar apenas com os mais relevantes. Ao final, restaram 106 atributos: 91 de valores médios, 4 booleanos, 1 indicação de tempo, outro de falha e 9 atributos percentuais. Essa outra etapa, está representada pela Figura 22.

Figura 22: Pré-processamento secundário.



Fonte: Elaborado por P4.3

3.4 Clusterização

Clusterização, no aspecto de mineração de dados, é considerado um método ativo de agrupar dados em várias coleções ou clusters, de acordo com a similaridade de recursos e características dos dados (EZUGWU et al., 2022).

O aprendizado não-supervisionado corresponde a métodos estatísticos que extraem significado dos dados, sem treinar um modelo em dados rotulados. Este modelo também constrói um modelo de dados, mas não distingue entre variáveis de resposta e preditoras. Ele pode ser usado para criar uma regra preditiva na ausência de uma resposta rotulada, portanto, o modelo pode ser visto como uma extensão da análise exploratória de dados. Técnicas não-supervisionadas permitirão examinar e analisar variáveis e descobrir relações existentes (GÉRON, 2019).

O algoritmo EM de maximização de expectativa é um método iterativo que alterna entre duas etapas: expectativa (E) e maximização (M). Para agrupamento, o EM faz uso do modelo de misturas gaussianas finitas e estima um conjunto de parâmetros iterativamente até o valor de convergência ser alcançado. Este método apenas infere sobre o conjunto de dados, apontando os agrupamentos, de acordo com as semelhanças encontradas (DEMPS-

TER; LAIRD; RUBIN, 1977).

A primeira abordagem verificada sobre os dados do Aerogerador 18 é baseada no algoritmo K-means desenvolvida e aperfeiçoada pelos pesquisadores (LLOYD, 1957) e (MACQUEEN, 1967). O algoritmo é bastante difundido e seu conceito é de fácil entendimento, podendo ser utilizado em temáticas de agrupamento, identificações de padrões ou anomalias. Seu funcionamento é fundamentado em iterações matemáticas partindo de uma indicação do número de agrupamento (cluster) ao qual os dados observados serão associados. Feita a escolha do número de clusters a etapa de treinamento pode ser iniciada. De forma sucinta, os passos seguintes podem ser descritos, como:

- Inicialização aleatória de K-centroides baseados no número de clusters selecionados previamente;
- Cálculo da distância entre os dados observados e definição do cluster com base nas menores distâncias relativas;
- Cálculo dos novos centroides para cada cluster gerado no passo anterior;
- Repetição dos passos 2 e 3 até apresentar convergência, ou sejam não há alteração do posicionamento dos centroides.

A etapa 1 de inicialização dos centroides de forma aleatória proporciona um custo computacional menos oneroso, mas existe a possibilidade de uma inicialização mais inteligente com a utilização de métodos heurísticos evitando inicializações anômalas que podem dificultar a convergência do modelo.

O maior custo computacional fica a cargo da etapa 2, onde todas as distâncias são calculadas entre os centroides k e todos os pontos observados N resultando em um montante de processamento N x k.

O cálculo da distância normalmente empregada em modelo de K-means é através do método euclidiano, dado por:

$$d(x, y) = \sqrt{\sum_{i=1}^p \|x_i - y_i\|^2} \quad (3.1)$$

Segundo Lloyd (1957) o cálculo para reposicionamento do centroide deve minimizar a soma do quadrado da distância Euclidiana dado por:

$$c_i = \operatorname{argmin}_{p_j \in X_i} d_E^2(c_i, p_j) \quad (3.2)$$

Desta forma, a convergência do modelo é dada quando as iterações não promovem uma atualização do posicionamento através da minimização das distancias.

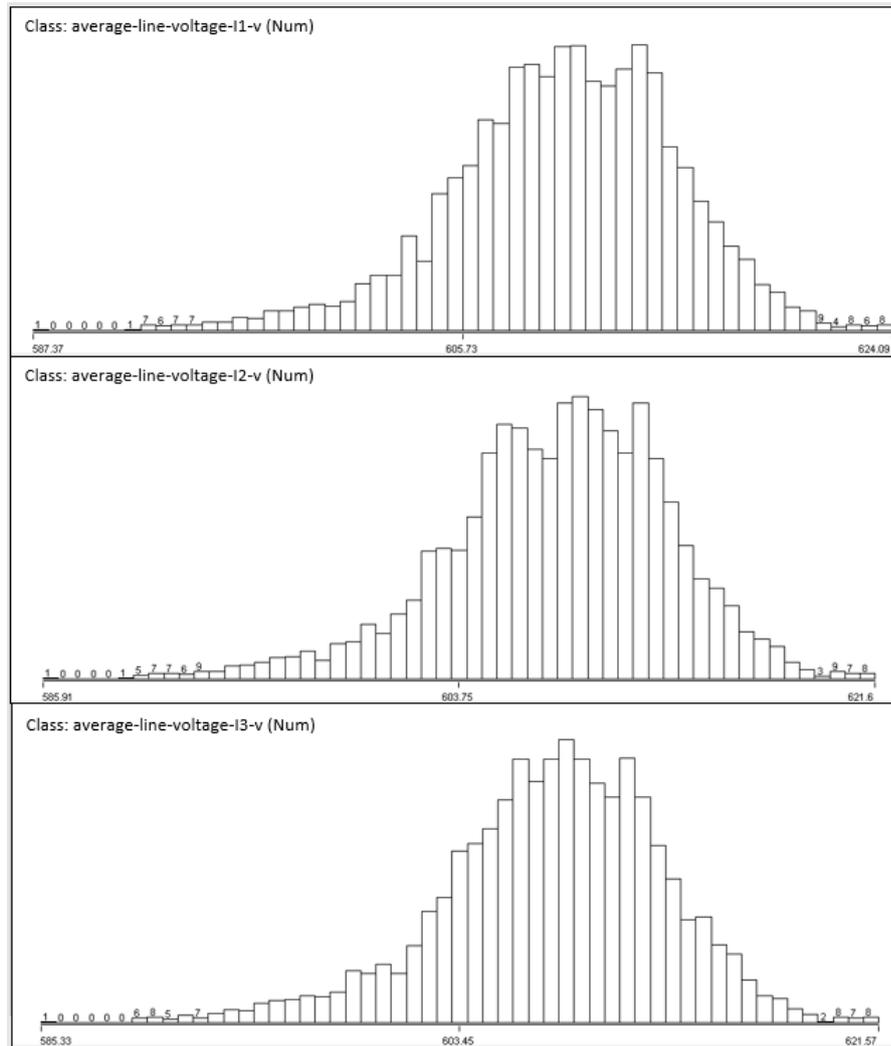
3.5 Seleção de Atributos

Nessa etapa, duas formas foram usadas para selecionar os principais atributos: ferramentas de seleção e a análise exploratória, realizando comparações visuais e conhecimentos de manutenção.

O software de aprendizado de máquina WEKA possui ferramentas de seleção de atributos, que escolhem os principais atributos avaliando o valor de um subconjunto de atributos considerando a capacidade preditiva individual de cada recurso, junto com o grau de redundância entre eles (FRANK et al., 2016).

Também foi realizada uma análise exploratória dos atributos, buscando correlações entre eles e os conhecimentos de manutenção. Por exemplo, a Figura 23 mostra três atributos muito semelhantes, é possível selecionar apenas um deles e eliminar os outros dois, sem causar uma perda significativa de informação no nosso dataset.

Figura 23: Atributos semelhantes.



Fonte: Autoria própria.

3.6 Classificação

Na etapa final da construção do modelo computacional, optou-se pelo processo de classificação de dados agrupados usando Multi-Layer Perceptron (MLP), que é subdividido em duas etapas: treinamento (fase de aprendizado) e classificação dos dados (teste). A MLP é a arquitetura mais recomendada pela literatura, para classificação de padrões em problemas complexos.

O conjunto de dados completo, com os rótulos, é dividido em duas partes, uma para a etapa de treinamento e outra para a etapa de classificação. Na etapa de treinamento, o modelo é construído a partir dos dados rotulados. Em seguida, é executada a etapa de classificação, que analisa o conjunto de dados extraíndo os rótulos, para tentar asso-

ciar cada elemento ao rótulo da classe a que pertence. Por fim, o rótulo de classe de cada elemento é fornecido ao classificador, essa etapa é conhecida como aprendizagem supervisionada.

Foi utilizada a validação cruzada (cross-validation 10 folds), que separa o dataset em 10 grupos distintos, onde 9 são utilizados na etapa de treinamento e 1 na etapa de classificação e o procedimento é repetido 10 vezes, cada vez com uma parte diferente do dataset, sendo utilizada na etapa de classificação, portanto, ao final todo o dataset terá sido utilizado na etapa de classificação.

A tabela 4 apresenta as configurações da MLP que utilizamos: 4 camadas, dentre elas duas escondidas, cada uma com 5 neurônios cada, 9 atributos de entrada e 3 clusters na saída, função de ativação sigmóide, 500 épocas.

Tabela 4: Network Hyperparameters

Hyperparameter	Value
Number of layers	4
Number of hidden layers	2
Number of hidden units(for each hidden layer)	5/5
Batch size	100
Epochs	500
Activation function	Sigmoid
Learning rate	0.3
Momentum	0.2

3.7 Métricas de Avaliação

As avaliações de um modelo direcionado a classificar dados, recaem sobre a comparação dos rótulos dos dados observados, com os rótulos estimados, verificando a discrepância entre eles.

Não existe, atualmente, uma métrica absoluta que aponta, de forma decisiva, a qualidade do modelo em teste. A utilização de combinações de métricas, permite uma análise profunda, observando o desempenho do modelo em variados aspectos.

Para o desenvolvimento do modelo, optou-se pelo emprego das abordagens mais utilizadas:

- Matriz de Confusão;

- Acurácia (Accuracy);
- Revocação (Recall);
- Precisão (Precision);
- Especificidade (Specificity);
- F1-Score.

Para essas métricas, vamos considerar o seguinte:

- VP - Verdadeiro Positivo
- VN - Verdadeiro Negativo
- FP - Falso Positivo
- FN - Falso Negativo

3.7.1 Matriz de Confusão

A matriz de confusão é uma representação visual, entre as classes reais e preditas para os dados, apresenta de forma direta os erros e acertos do modelo, indicando: falsos negativos, falsos positivos, verdadeiros positivos e verdadeiros negativos.

A Figura 24 ilustra a disposição de uma matriz de confusão para problemas de classificação binária.

Figura 24: Matriz de Confusão.



Fonte: Material da aula de IA.

3.7.2 Acurácia

A acurácia é a uma das métricas mais empregadas para avaliação dos modelos de classificação. Ela representa o número de previsões corretas, portanto é alta, quando o modelo está identificando as classes corretamente.

Ela é uma boa métrica para dados balanceados, mas, quando constata-se desbalanceamento, isto é, existe alguma classe com recorrência mais acentuada, é prudente, combinar a acurácia com outras métricas.

Seu cálculo é dado por:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.3)$$

3.7.3 Revocação

A revocação é uma métrica capaz de indicar o desempenho do modelo frente ao verdadeiros positivos.

Sua formulação é dada por:

$$\text{Revocação} = \frac{VP}{VP + FN} \quad (3.4)$$

3.7.4 Precisão

De forma contrária, a precisão julga com mais ênfase a proporção dos falsos positivos.

É calculada da seguinte forma:

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.5)$$

3.7.5 Especificidade

Matematicamente semelhante, a especificidade julga o desempenho do modelo sobre as classificações negativas.

$$\textit{Especificidade} = \frac{VN}{VN + FP} \quad (3.6)$$

3.7.6 F1-Score

A média harmônica da precisão e revocação resulta na métrica F1-Score. Tal métrica é muito utilizada quando os verdadeiros positivos apresentam uma relevância maior para o objetivo do projeto.

É uma boa métrica para classes desbalanceadas, indica boa capacidade de prever e acertar as previsões.

Sua fórmula é:

$$F1 - Score = 2 \frac{Precisão * Revocação}{Precisão + Revocação} \quad (3.7)$$

Artigo I

Technological Advances on Fault Diagnosis in Wind Turbines: A Patent Analysis

Artigo publicado em Appl. Sci. 2023, 13, 1721.

Natasha Benjamim Barbosa, Danielle Devequi Gomes Nunes, Alex Álisson Bandeira Santos and Bruna Aparecida Souza Machado

Computational Modeling and Industrial Technology, SENAI CIMATEC University Center, Salvador 41650-010, Brazil

DOI: 10.3390/app13031721

Este artigo é de propriedade da Applied Sciences.

Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Como o foco do P4.3 no projeto da planta híbrida é construir um sistema de manutenção preditiva para aerogeradores, a prospecção realizada teve como objetivo mapear desenvolvimentos científicos já existentes na manutenção de aerogeradores, envolvendo detecção de falhas e monitoramento de condições, usando as principais técnicas de preditiva: análise de vibração e termografia, além das inovações aplicando as ferramentas de aprendizagem de máquina. Essa pesquisa foi realizada utilizando o banco de dados Derwent Innovation Index (DWPI), licenciado para uso do Cimatec, no dia 19 de agosto de 2022 e resultou nesse artigo, que está apresentado, na íntegra, nesse capítulo.

Article

Technological Advances on Fault Diagnosis in Wind Turbines: A Patent Analysis

Natasha Benjamim Barbosa, Danielle Devequi Gomes Nunes, Alex Álisson Bandeira Santos and Bruna Aparecida Souza Machado *

Computational Modeling and Industrial Technology, SENAI CIMATEC University Center, Salvador 41650-010, Brazil

* Correspondence: brunam@fieb.org.br

Abstract: Given the urgency of mitigating the effects of global warming and the depletion of fossil energy sources, renewable sources of energy, such as wind power, are the focus of the future. However, due to the rapid growth of this technology, concerns about the security and reliability of wind turbines are increasing, especially because of associated hazards and financial costs. Hence, health monitoring and fault identification for wind turbine blades have become an important focus of research. Thus, the objective of this study was to generate data on the current scenario of the techniques used to identify failures and defects in wind turbines and their components. Through the results found, companies can find ways to make decisions and identify potential new technologies. In this way, a technology prospection was conducted that focused on patents to investigate the use of vibration analysis, thermography, and machine learning. A total of 635 patent documents were found, and the evolution in the number of patents over the years has demonstrated the current interest in developing new technologies in this research area. China, the world's leading country in the area of wind energy, was the country with the highest number of filings, followed by the United States. In the patent documents analyzed, it was possible to identify that those innovative technologies for predicting and detecting failures are a topic of interest for the world's largest economies. Additionally, it was clear from the results that the application of artificial intelligence to traditional techniques is a current trend and will continue in the future. Technological prospection studies can foster the development of new methods and devices, providing economic and environmental gains for the wind energy industry.

Keywords: wind turbine; maintenance; fault detection; patents

Citation: Barbosa, N.B.; Nunes, D.D.G.; Santos, A.Á.B.; Machado, B.A.S. Technological Advances on Fault Diagnosis in Wind Turbines: A Patent Analysis. *Appl. Sci.* **2023**, *13*, 1721. <https://doi.org/10.3390/app13031721>

Academic Editor: Frede Blaabjerg

Received: 29 December 2022

Revised: 23 January 2023

Accepted: 24 January 2023

Published: 29 January 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

For many decades, the global utilization of energy has increased remarkably, and significant efforts have been made by most developing countries to attenuate and minimize the impacts of climate change by maximizing energy use and minimizing greenhouse gas emissions [1]. Due to current economic and industrial growth, experts have estimated that by 2050, the global energy requirement will be around ~30 TW [2], exacerbating the negative impacts related to the use of fossil fuels [3]. The Intergovernmental Panel on Climate Change (IPCC) commented on the future risks emanating from climate change, stating: “Continued emission of greenhouse gases will cause further warming and long-lasting changes in all components of the climate system, increasing the likelihood of severe, pervasive, and irreversible impacts for people and ecosystems. Limiting climate change would require substantial and sustained reductions in greenhouse gas emissions which, together with adaptation, can limit climate change risks” [4].

Climate change is undoubtedly a major driver of wind power development, and the use of wind energy is an important factor in attenuating the negative effects of global

warming. Along with the growing safety concerns surrounding the use of nuclear power, many countries have established important strategies targeting renewable energy with low greenhouse gas and pollutant emissions, including the use of wind energy [5,6].

Wind energy is a predominant and potentially low-cost renewable energy technology that plays a key role in the transition toward clean energy [7,8]. Among the current technologies for generating electricity based on renewable sources, the most widely implemented renewable energy in the world is wind power [9]. The energy is collected through conventional wind turbines, converting the kinetic energy of the wind into mechanical energy through the rotation of the blades and then into electrical energy through the use of generators. Depending on their location, wind turbines can be categorized as onshore or offshore wind turbines [10].

In recent decades, the global wind-power-generation capacity has increased from 7.5 GW in 1997 to 743 GW in 2020. Currently, the total world capacity for wind power is about 873 GW, helping the world avoid over 1.2 billion tons of CO₂ annually. China and the U.S. are the two largest wind energy marketplaces in the world. In the United States, installed wind capacity at the end of 2020 was 122,426 MW of onshore wind power and 42 MW of offshore wind power, representing more than USD 20 billion of investment, while in China, the capacity was 272 GW onshore and 9 GW offshore [11]. Experts believe that the global wind energy market will reach over 557 GW of new capacity over the next five years due to current policies. That is more than 110 GW of new installations each year through 2026 [12].

WTs can be categorized according to their location, either onshore or offshore. Onshore wind turbines are located on land, and their systems suffer fewer failures, while offshore turbines, constructed in bodies of water where higher wind speeds are available, generate more electricity due to their larger size and the stronger winds present in the large open spaces where they are located, without restrictions caused by the environment, noise limits, and urban planning [13,14]. The rapid expansion of wind energy has created novel challenges in turbine control, plant operations, production planning, condition monitoring, and maintenance. Wind turbines (WTs) are exposed to highly variable and severe weather conditions, with rapidly changing ambient temperature, air pressure, and alternating load, including calm winds to gale force winds, tropical heat, lightning, arctic cold, hail, and snow [15]. Due to these external variances, WTs undergo constantly changing dynamics and local loads, resulting in a large variation in operating conditions that lead to intense mechanical stress [16,17]. Many of the already installed WTs are aging, driving the growing maintenance and repair market, along with the demand for the development of new maintenance and repair technologies. As the demand for wind power continues to grow at exponential rates, maintenance will be a permanent factor related to costs, and it can directly influence energy prices and the competitiveness of renewable energy [17,18]. Maintenance (O&M) activities are a critical aspect of reliability. As a matter of fact, the global O&M market is projected to grow to USD 27.4 billion by the year 2025. Maintenance is one of the leading costs in the total expenditure of a wind farm project and, if not effective, can cause drastic losses in energy production due to downtime [19–21].

Different faults can affect a WT with different degrees of severity and with different financial impacts (related to the shutdown time caused by the fault). The most common failures associated with WTs are electrical, mechanical, structural, and cyber incidents. When it comes to the components, the most frequent faults involve the electrical system, the blade and pitch system, the sensors, and the hydraulic system [22]. The different failures in the components of a WT can lead to damage directly linked to the electrical system, decreasing the power generated by the WT and increasing the overload of different mechanical parts. This overload can lead to an abnormal vibration spectrum, overheating, and shortening the life of the components of the wind turbine, directly affecting the quality of the energy generated [16,23]. These failures cause serious incidents, both to the workers involved in the operations and to the environment in which they are

exposed; in addition to the loss of efficiency in energy production, one of the main consequences of the late diagnosis of these failures is electrical breakdown and fire in the structural components of the turbines. Due to the height of the turbines, these failures are extremely dangerous and difficult to extinguish while releasing toxic fumes and can cause secondary fires in their immediate environment; they can also lead to operator fatalities [24].

Taking all these factors into consideration, research into condition monitoring and failure diagnosis of WTs is increasing dramatically, and new fault-prediction techniques are needed to avoid downtime and increase plant reliability [25]. Monitoring and fault diagnosis based on vibration analysis is one of the most commonly applied technological tools in the industry for rotating equipment. Moreover, it is considered the method that covers the greatest possible number of failures. A challenge associated with monitoring using vibration analysis is the multiple frequency ranges, both low and high, of the different components of a WT. Usually, vibration techniques range from statistical techniques to techniques based on signal processing algorithms to extract diagnostic data [23,26].

De Azevedo and colleagues placed accelerometers on the main components of a WT and used a vibration-based condition monitoring methodology using signal processing techniques, such as the temporal variations in vibrating signals, spectrum analyses by fast Fourier transforms, and envelope analysis through Hilbert transformation to search for potential faults. The results of the analysis helped find a failure in the generator's non-driving-end bearing, and the vibration characteristics were analyzed and reduced after the bearing was replaced [26]. Aihara et al. designed a blade-vibration monitoring system. The system used a strain gauge installed at the root of the blade to calculate and measure the deflection in real time according to the monitored stress. The results showed an acceptably high estimation accuracy and considered the system practical [27].

Another non-destructive evaluation technology used for detecting faults in wind turbines is thermography. Thermography technology is an advanced method based on thermal imaging that detects different temperatures on structural surfaces [28]. The thermography technique uses an infrared (IR) camera acting as a sensor, and the system makes it possible to detect surface damage on the different elements of wind turbines [29]. Structural defects cause friction between the constituent elements of wind rotors, which, in turn, generates heat. Heat flows along materials can be accurately assessed by capturing and analyzing thermal images. The benefits of using the thermography technique are visual damage description and full-field measurements. In addition, this method could be applied for massive inspections due to the short time consumption. Hwang et al. [30] utilized a thermography system based on a continuous line laser and an algorithm to measure internal delaminability in rotating blades. The thermal images demonstrated the explicit defect by color difference. Yang et al. [31] evaluated passive and active infrared thermographic techniques employed on wind turbine blades to detect multiple defects, such as delamination, air bubbles, and structural defects within glass-fiber-reinforced polymer composite blades.

Comparing the methods mentioned above, the vibration analysis technique, considered traditional, usually indicates failures linked to mechanical and electrical parts, and although it is widely used, it has limitations, such as difficulty in identifying the nature of the failure, many sensors are required to detect the location and severity of the damage, and environmental conditions can make damage detection difficult and inaccurate. In addition, it makes it difficult to differentiate between the vibrations caused by the environment or the operating conditions and the vibrations caused by blade damage [16]. On the other hand, the thermography technique, which can be used in various environmental conditions, presents some disadvantages, including the requirement for expensive thermal imaging cameras; the technique is also sensitive to temperature changes and is affected by air temperature and humidity [16,32–33]. Both

techniques have advantages and limitations, meaning that scientific, technical development is essential for improving traditional techniques and developing new ones.

In recent years, research advances have offered numerous new solutions for various fault problems. Many researchers have focused on wind speed variability, improving power generation efficiency, and decreasing the cost of energy generation. A greater understanding of the evolved models and techniques could positively impact the future of wind energy research.

Patents play an important role in the development and innovation process, directly supporting three important areas, such as: providing back-up support for R&D; by providing state-of-the-art analysis in a given technological area; supporting the acquisition and protection of IP. In addition, the study of patents gives direct support to companies and the development of business and strategic transactions. Important data for analyzing competitors, understanding a particular technological area, determining patent applicability, and identifying potential alliance partners are made available [34]. In view of that, this study had the objective of performing a technological prospection focused on patents in order to verify the technological panorama of the different techniques used to identify faults and defects in wind turbines.

2. Materials and Methods

To analyze the technological information described in the patent documents related to fault diagnosis in WTs, an exploratory search was carried out using the database of Derwent Innovation Index (DWPI), Thomson Innovation®, licensed for use by SENAI CIMATEC University Center. The search was undertaken on 19 August 2022.

After the refinement, the keywords and codes used represented the strategy used in which the technology of interest could be identified in the documents: *wind turbine AND failure detection AND (vibration analysis OR thermography)*

Moreover, International Patent Classification (IPC) codes were also used to refine the exploratory search. In Table 1, the codes used in the prospection, as well as what each code is related to, are described.

Table 1. IPC codes used in the prospecting of current patent technology.

IPC Code	Regarding
F03D	Wind Motors
G01H	Measurement of Mechanical Vibrations or Ultrasonic, Sonic, or Infrasonic Waves
G01M	Testing Static or Dynamic Balance of Machines or Structures; Testing of Structures or Apparatus, Not Otherwise Provided For
G01R	Measuring Electric Variables; Measuring Magnetic Variables (Indicating Correct Tuning of Resonant Circuits H03j3/12)
G01J	Measurement of Intensity, Velocity, Spectral Content, Polarization, Phase, or Pulse Characteristics of Infra-Red, Visible, or Ultra-Violet Light; Colorimetry, Radiation Pyrometry (Light Sources F21, H01J, H01K, H05B; Investigating Properties of Materials by Optical Means G01N)
G01K	Measuring Temperature; Measuring Quantity of Heat; Thermally Sensitive Elements Not Otherwise Provided For (Radiation Pyrometry G01j5/00)

It is worth mentioning that a secondary exploratory search was conducted by adding the keyword of *machine learning* and considering the same IPC codes in order to evaluate a more specific approach. The search browsed the title, abstract, and claims fields of the patent documents without restricting the data collection period. For the graphic

construction, GraphPad Prism 9.2 (San Diego, CA, USA) software, licensed by SENAI CIMATEC University Center, was utilized to provide the time analysis of the patent documents (year of priority and year of expiration), main applicants, inventors, and the International Patent Classification (IPC) codes. The results for the geographical distribution of the main applicant countries/regions and the main technological areas were collected directly from the DWPI database (with adaptations).

3. Results and Discussion

The use of patents is an interesting and important tool in the assessment of innovative technologies and activities [35]. In the present investigation, a patent search was conducted to evaluate the technology of interest, the systems, methods, and devices for wind turbines. In total, 635 were found, with 342 DWPI families. Figure 1 details the annual distribution of patent applications regarding the described technology; the first applications were found in 1982 (Figure 1a). The number of patent document applications showed growth over the analyzed period, indicating a continued strong interest in the development of new technologies for wind energy. Significant growth in the publication year can be observed starting in 2014, followed by a peak in 2021, with 98 documents. The evolution of the number of patent applications may be related to the need to promote technologies aimed at combating extreme climate change caused by global warming, a consequence of exacerbated CO₂ emissions. The first patent found was filed in 1982 by the General Electric Company (Boston, Massachusetts, United States) and refers to the diagnosis of undesirable internal changes in an operating turbine by monitoring the dynamic fluid flow pressure and the vibration of the stationary casing's pump frame. The patent describes monitoring using temperature and static pressure data [36].

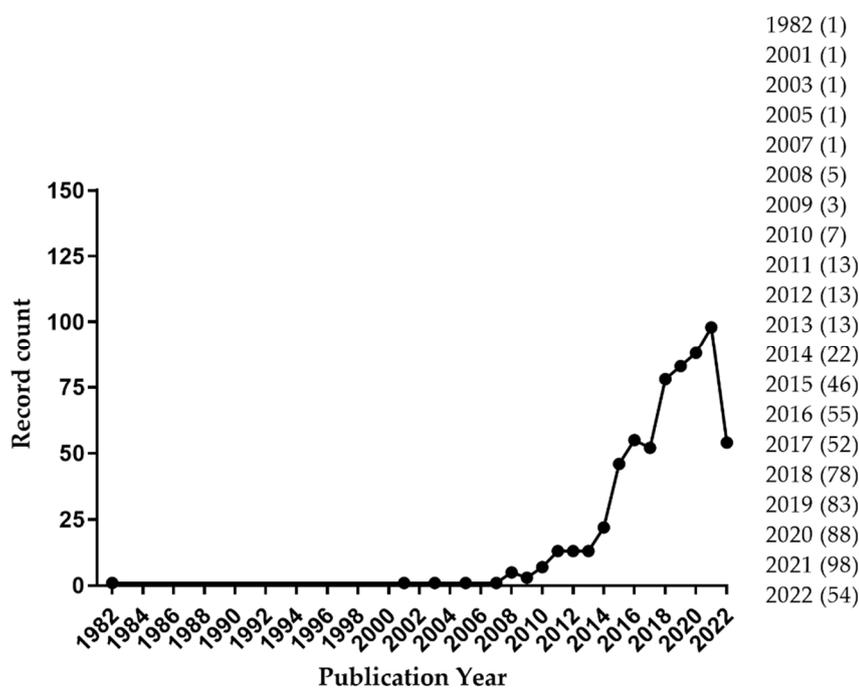


Figure 1. Time analysis of patent documents. First year of priority.

The consequences of exacerbated CO₂ emissions are increasing in both frequency and intensity: floods, wildfires, melting polar ice caps, and extreme seasonal temperature changes—up and down—on all continents. Consequently, the search for strategies to reduce the dependence on fossil fuels for energy production is increasing. One important

strategy is the mission of “net-zero emissions by 2050”, which emerged as a promising strategy to limit global warming and reduce the world temperature to 1.5 °C in order to significantly reduce the risks and impacts of climate change [37]. The accession of renewable energy and technological innovation provides a viable route to reduce fossil energy use and reduce CO₂ emission levels [38,39].

Most of the technologies developed in the patents focused on new methods and/or systems for monitoring wind turbines and rotor blades. The patent filed by Qiao et al., 2021, refers to a wind generator failure detection method that collects and processes two different signals obtained from the wind turbine, the first signal coming from the wind turbine generator and the second coming from a vibration sensor attached to the wind turbine. Therefore, it is possible to detect and identify a characteristic signature from a wind turbine bearing failure [40]. Ernst et al., 2021 [41], described a blade-handling system and method for conducting tomography (X-ray) scans of wind turbine blades to detect various types of manufacturing defects before blade installation. Jiang et al., 2021, described [42] a method of fault diagnosis of the planetary gearbox of a wind turbine that comprised collecting a time domain vibration signal from the planetary gearbox as a sample to be diagnosed, these samples are normalized in amplitude, and the training results are validated and tested to obtain fault-diagnosis results. The present invention has the advantages of solving the problem of time-consuming and labor-intensive collection of real equipment data, reducing the reliance on traditional methods on a large amount of real equipment data, and improving diagnostic accuracy.

As the sectors of wind energy grow, business economics will demand increasingly careful management of costs, especially as the operation and maintenance (O&M) costs of WTs account for about 25–30% of the overall energy generation cost or 75–90% of the investment costs [16]. In view of that, condition monitoring (CM), fault diagnosis (FD), and nondestructive testing (NDT) are currently considered crucial means to increase the reliability and availability of wind turbines. With that, many researchers have focused on CM and FD for different components of wind turbines, especially for evaluating wind turbine blade failures [16,43].

One of the many ways to perform CM and FD is through vibration analysis. Vibration analysis can be used as an early damage-detection method in order to evaluate the health conditions of a structure [28]. The major types of sensors to capture vibration signals are displacement sensors, velocity sensors, and accelerometers [44,45]. The frequency ranges from low-frequency, middle-frequency, and high-frequency ranges and is used in the corresponding vibration sensors. Damage to a wind turbine's structure changes its properties, e.g., mass, stiffness, and damping. In addition, it is also possible to observe changes in the mechanical properties by modifying the modal frequency, mode shape, and damping ratio. Blade damage detection can be mentioned as an example; when the structure is excited by external forces, such as wind flow or turbulence, the dynamic responses of the structure act as vibration signals. These signal responses can be extracted to identify defects using signal processing techniques [25].

Xu and colleagues evaluated a rotor imbalance fault in wind turbines by collecting the vibration signal from an accelerometer that monitored the wind turbine drive train. They proposed a vibration model using a complex Morlet wavelet transform applied to rotor-imbalance detection and a health indicator that quantified the degree of rotor imbalance by the ratio of the vibration amplitude of the rotational frequency to the third harmonics. The result showed a successful detection and qualification of rotor imbalance caused by a blade crack in an on-site wind turbine [46]. Strömbergsson et al. studied the relationship between the rotational speed recorded during a vibration measurement and the calculated condition indicator values of specific bearing failures in three wind turbine gearboxes. Using an artificial neural network (ANN), they demonstrated the differences between the predicted and true values, and the results showed the increased sensitivity of the detection in two cases of gearbox output-shaft bearing failures, indicating a planet bearing failure, which had gone undetected in the previous data [47]. Aihara et al.

developed a vibration-monitoring system to be used in wind turbine blades with the objective of estimating the deflection on the blade tip in a wind turbine tower. The monitoring system developed in this research is considered easy to install and can measure in real time. The experiments were performed with a simple blade model of a 300 W rotating wind turbine, and the signals obtained from the strain gauges were acquired by a sensor network and sent to a computer via wireless communication. The results showed that the estimation accuracy was acceptably high, concluding that their proposed system was practical [27].

Thermography technology is an advanced method that uses thermal imaging to detect the temperature differences of structural surfaces [22]. The technique uses an infrared (IR) camera acting as a sensor and can inspect local damage or global damage, depending on the resolution of the camera, to access a single point or a full structure [48]. Material damages on the WT can be measured using temperature gradients in a non-destructive way, and the detected damaged part will present with a higher temperature than the normal part [49]. The use of thermography has some advantages, such as the availability for full-field measurements, suitability for detecting damages caused by fatigue and delamination, capability for visual interpretation, and a short inspection interval. Inspection techniques can be split into two categories: active and passive. In active thermography, different heating sources are employed to heat the object, which makes the technique less frequently used for operating wind turbines, while passive thermography utilizes solar radiation to heat a blade (usually around sunrise) or to cool it at sunset [15]. This method has been widely used to detect the subsurface defects of different materials, including metals, composites, and concrete [50–52].

Hwang and colleagues assessed a continuous line laser scanning thermography (CLLST) system to remotely inspect internal delamination defects in wind turbine blades. In order to evaluate the feasibility of the CLLST system, both laboratory and full-scale tests were conducted using a carbon-fiber-reinforced polymer (CFRP) plate, a glass-fiber-reinforced polymer (GFRP) 10 kW wind turbine blade, and a 3 MW GFRP wind turbine blade. The results demonstrated that the 10 mm diameter internal delamination located 1 mm below the blade surface was successfully detected even at a 10 m distance from the target blade with a laser scan speed of 2 mm/s. [53]. Doroshnasir et al. used thermography to detect potential subsurface defects or damage to offshore wind farms. It was performed from remote distances by a data processing algorithm, which differs from the ordinary method of thermographic analysis using thermal photographic images. The results showed the detection of potential subsurface defects within rotating rotor blades from greater distances, such as from the ground, aircraft, or vessels [54]. Oehme et al. employed IR-thermography-based detection to assess turbulent flow separation in wind turbine rotor blades during operation. The measurement approaches measured the surface temperature response to unsteady flow conditions and enabled unambiguous detection of flow separation via temperature fluctuation maxima in flow transition regions, as well as increasing temperature fluctuations within the separated flow region [55].

As WTs are exposed to harsh environmental conditions, such as rain, snow, and airborne particles, such as snow, rain, and ice, multiple faults can occur at the same time. Acknowledging that each failure detection method has its own limitations, new investigations are seeking to combine different failure detection techniques to provide more accurate and detailed information. As an example, Li et al. [56] and Ma et al. [57] united the techniques that use acoustic and vibration signals for gearbox fault diagnosis, and the results proved the superior performance of multi-sensor fusion compared with single-sensor-based methods.

In recent decades, artificial intelligence, such as machine learning, has been investigated for optimal control in industrial applications and is considered to be a promising approach to increasing system efficiency by including probability functions and nonlinear modeling into relevant signal processing methods. Wang et al. proposed a deep-learning-based model called Multi-Resolution and Multi-Sensor Fusion Network (MRSFN) to

evaluate motor fault diagnosis through the multi-scale analysis of motor vibrations and stator current signals. The applied method's advantage is that it automatically learns discriminating characteristics through the training process of the network without requiring manual feature selection. The results of the two cases studied demonstrated the advantages of the developed method [58]. Dao et al. presented a novel approach for condition monitoring and fault diagnosis in wind turbines based on structural break detection in SCADA data. The technique was employed for the DC of a wind turbine with 2 MW rated power using SCADA data related to the temperature. To detect structural changes, they used a method based on control charts, where the sequences of the calculated probability (p-values) were plotted together with the critical line and defined by the significance level. The method was validated using two known fault events on the WTs, and the results demonstrated the effectiveness of the method in monitoring the WT and confidently detecting abnormal faults [59]. Mian et al. studied multiple combinations of bearing defects, including both dual- and multiple-defect conditions. They selected two predominant methods of fault diagnosis: vibration monitoring utilizing time–frequency scalograms extracted using a Continuous Waveform Transect (CWT) and a Non-Invasive Infrared Thermography (IRT). The group found adequate accuracy in both the dual- and multiple-fault conditions for vibration-based fault diagnosis, with a range of 99.39% to 99.97%. Meanwhile, for the IRT-based failure diagnosis, a 100% classification accuracy was reached for double and multiple failures under all conditions [60]. Table 2 presents some articles in the scientific literature that approach the use of the prospected technologies.

Table 2. Articles that focus on the use of condition monitoring (CD) and nondestructive testing (NDT) for fault diagnosis on Wind Turbines.

Title	Technology	Main Findings and/or Conclusions	Reference
Multiview enhanced fault diagnosis for wind turbine gearbox bearings with fusion of vibration and current signals	Vibration Analysis + Canonical correlation analysis (CCA)	The paper undertook a novel evaluation of a multiview fault diagnosis framework enhanced to comprehend the correlated and complementary features between current and vibration signals, which were considered as two different but related views. They used an unsupervised multiview learning method based on canonical correlation analysis (CCA) to evaluate this correlation. The results have shown balanced fault characteristics and achieved higher performance in fault diagnosis, especially in composite faults, compared to methods based on unimodal signals.	[61]
Alternative fault detection and diagnostic using information theory quantifiers based on vibration time-waveforms from condition monitoring systems: Application to operational wind turbines	Vibration + Probability mass function	The paper analyzed information on two theory quantifiers used to monitor and detect changes in the vibration signals of two operational wind turbines of 750 kW and 2 MW. The authors evaluated the signals by power spectrum (frequency domain method), wavelet transform (time-frequency domain method), and Bandt–Pompe (time-domain method). The results demonstrated that the proposed method could distinguish (cluster) well between the states of fault.	[62]
Wind turbine fault detection based on deep residual networks	SCADA	In this article, researchers proposed a new depth network called deep residual network (DRN) to further analyze the raw data generated by WTs. In the method, the raw data gathered by the SCADA system are applied directly as inputs to the DRN network. Then, a	[63]

		convolutional residual building block (CRBB) was established by using convolutional layers and squeeze and excitation units. The results indicate that the proposed DRN achieved better performance and outperforms some published fault-detection methods.	
Deep learning strategies for automatic fault diagnosis in photovoltaic systems by thermographic images	Deep Learning + Thermography	The authors proposed a system for the automatic classification of thermographic images using a convolutional neural network developed via open-source libraries. The results showed a 99% accuracy for a dataset of 1000 images using a multi-layer perceptron architecture and 100% accuracy for a convolutional neural network.	[64]
Attention-guided joint learning CNN with noise robustness for bearing fault diagnosis and vibration signal denoising	Deep Learning + Vibration	The paper reports a novel attention-driven joint learning convolutional neural network (JL-CNN) for monitoring conditions. The fault diagnosis task (FD-Task) and the signal denoising task (SD-Task) are integrated into an end-to-end CNN architecture, reaching good noise robustness through dual-task joint learning. This method allowed FD-Task and SD-Task to achieve deep cooperation and mutual learning, and the results showed outstanding fault diagnosis capacity and signal denoising ability.	[65]

Figure 2 shows the main applicants (a) and inventors (b) of the prospected patent documents. The Vestas Wind Systems A/S (Aarhus N, Aarhus, Denmark) appears in first place with 26 documents. The company is a Danish company and the global leader in sustainable energy solutions, with more than 40 years of experience in wind energy, and currently has more than 160 GW of wind turbines installed in 88 countries, preventing 1.5 billion tonnes³ of CO₂ from being emitted into the atmosphere. The group is specialized in the manufacturing, installation, and servicing of wind turbines and is the market leader in the North American wind industry, with 42,000 MW installed and more than 38,000 MW under service in the U.S. and Canada [66]. Compared to the top ten competitors in this set, Vestas Wind Systems A/S has approximately 13% of those records. In second place is the State Grid Corporation of China, with 18 documents. The State Grid Corporation of China ((Beijing, China), founded on 29 December 2002, is a large corporation and is considered crucial to China's energy and economic security. The company supplies power to a population of more than 1.1 billion across 26 provinces, autonomous regions, and municipalities, covering 88% of China's national territory [67]. General Electric, in third place with 16 documents, is an American multinational company with 125 years of experience; it is known for its efforts in the power, renewable energy, aviation, and healthcare industries. In 2021, the company had 52k wind turbines installed in more than 35 countries, the first position in the United States in terms of wind installations [68].

It can be seen from Figure 2a that not only do companies appear between the main applicants but also research institutes and universities. This reflects the possibility of patent applications not only by companies but also by research and development institutions. Among the patents that can be cited is the Inner Mongolia University of Technology (Inner Mongolia–Hohhot, China), which is the publication applied for in 2021. The invention concerns a process related to a new device and method for measuring the dynamic noise of wind turbines. Figure 2b shows the top ten inventors of the prospected technologies, most of whom are associated with the companies and universities found.

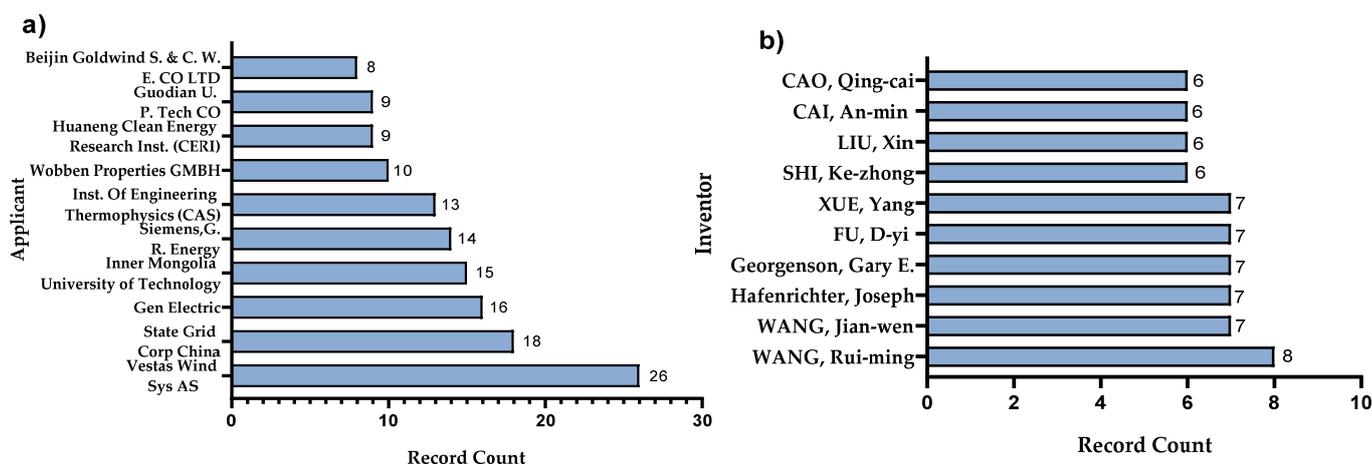


Figure 2. Analysis of the main (a) applicants and (b) inventors of the prospected technologies.

The main countries and regions that produce this type of technology are demonstrated in Figure 3. By analyzing the main countries that deposited those technologies, it is possible to observe that China and the United States are the main countries, with 373 and 45 documents, respectively. China plays an important role in the development and export of technologies involving renewable energies [69,70]. The country has made a commitment to achieving peak carbon by 2030 and carbon neutrality by 2060, and wind power has become a practical alternative [71]. The electricity created in China by wind power was 467 billion kWh in 2020, accounting for more than 20% of the total renewable energy generated [72]. In order to encourage the sustainable development of the wind power industry, China's Government has provided support through political measures [73]. Such policies might include clarifying the goal of large-scale wind power development, raising the amount of wind power in the electricity supply, and sharing the operating costs of wind power generation through some political actions such as taxation, financial subsidies, and feed-in tariff adjustments [74,75].

In 2010, China became the leading wind power market in the world, both annually and cumulatively, in terms of market size. The country usually establishes a Five-Year Plan (FYP), which takes five years as a stage to undertake the development planning of social economy and energy. The most current FYP is the 14th Five-Year Plan (FYP) on Renewable Energy Development (2021–2025), released in June of 2022 [76]. The plan aims for a 50% increase in renewable energy generation (from 2.2 trillion kWh in 2020 to 3.3 trillion kWh in 2025), establishes a 33% share of renewable electricity consumption by 2025, and mandates that 50% of the increase in electricity and energy consumption nationally must come from renewable sources in the period 2021–2025. Achieving the objectives, China will reduce up to 2.6 gigatons of carbon emissions annually [77].

The development history of wind power in China can be divided into four main stages: the initial pilot stage (1986–1995), the experimental development stage (1995–2006), the comprehensive expansion stage (2006–2010), and the stable development stage (since 2010) [78]. In the initial stage, the Chinese government imported small off-grid wind turbines to be used in remote areas, and the country initiated the application and construction of wind farms [79,80]. During the experimental stage, China built small wind farms with foreign grants and loans, and the government provided support to companies to license and start the production of wind turbines and all relevant technology [81,82]. The comprehensive stage defined the development targets of the wind power industry and established a stable cost-sharing system by publishing the Renewable Energy Law of the People's Republic of China in 2006 [83]. In the stable development stage (since 2010), China has become one of the largest technology-developing countries in the world, and, in light of this, companies have explored the development of raw materials, component

manufacturing, wind turbine manufacturing, and wind-farm management in order to decrease costs and increase the competitiveness of the wind energy market in the world. By the end of 2010, four Chinese companies were among the world's top 10 wind turbine manufacturers [78].

It is important to mention that one of the reasons for the great technological advance achieved by China is the growing collaboration between research centers and private companies. An example of this collaboration was the creation of the Offshore Wind Power Research Institute by the Shanghai Electric Wind Power Group and Zhejiang University and also the Shanghai Donghai Wind Power Co. Ltd., who cooperated with the Shanghai Electric Power University to develop floating wind power [78]. This collaboration can also be seen in the results found in the patents. The patent refers to an infrared thermal image detection method for detecting micro-defects in the blades of large wind turbines, and the Shenyang University of Technology (Tiexi, Shenyang, China) is the applicant: deposited by Nanjing Ruigong Engineering Testing Co. Ltd (Nanjing, China), the patent is related to a nondestructive testing device for wind turbine blades. Considering all these important efforts, and under the guidance of wind power policies, China has grown significantly in the wind energy industry and market. However, there are still some problems in the industry, such as the difficulty of accommodation, inadequate financial subsidies, and imperfect market systems, which can occur due to imperfect policies, inadequate implementation of such policies, etc. [84]. Therefore, China still needs to improve policies and continue to develop wind power technology in order to solve the problems that might arise along the way.

The United States (U.S.) was the second country found in terms of research conducted and started seriously harnessing wind power after the oil crisis. In 2021, wind energy accounted for 32% of the country's total energy capacity, with 13.4 GW of wind capacity taking the cumulative total to almost 136 GW by the end of the year [85,86]. The country's investments in wind energy were about USD 20 billion, with the aim of implementing new wind power projects by 2021, accumulating to about USD 270 billion since the early 1980s [87]. One of the ways that the U.S. used to support the development of wind power was the establishment of the National Offshore Wind Power Strategy: creating the U.S. Offshore Wind Power Industry released by the United States Department of Energy and the Department of the Interior. This strategy planned to invest in research and innovation, wind turbine manufacturing, and grid technology [88]. In terms of policies, the government provides support from federal funds and wind energy technology foundations, such as credit loans and financing R&D designs and equipment manufacturing, as well as wind farm construction. These policies prioritized the development and promotion of wind energy technology and invested substantial R&D technical subsidies in wind energy technology [89].

It is worth mentioning that two international organizations were identified, these being the World Intellectual Property Organization (WIPO) and the European Patent Office (EPO), with 60 and 49 applications, respectively. These organizations make it possible to apply for several international applications through a single application, such as the WIPO Patent Cooperation Treaty (PCT). Most technology manufacturers are looking to secure their inventions through international applications via EPO and WIPO with the aim of reducing costs and simplifying the individual filing process in each country while protecting their technology in several countries.

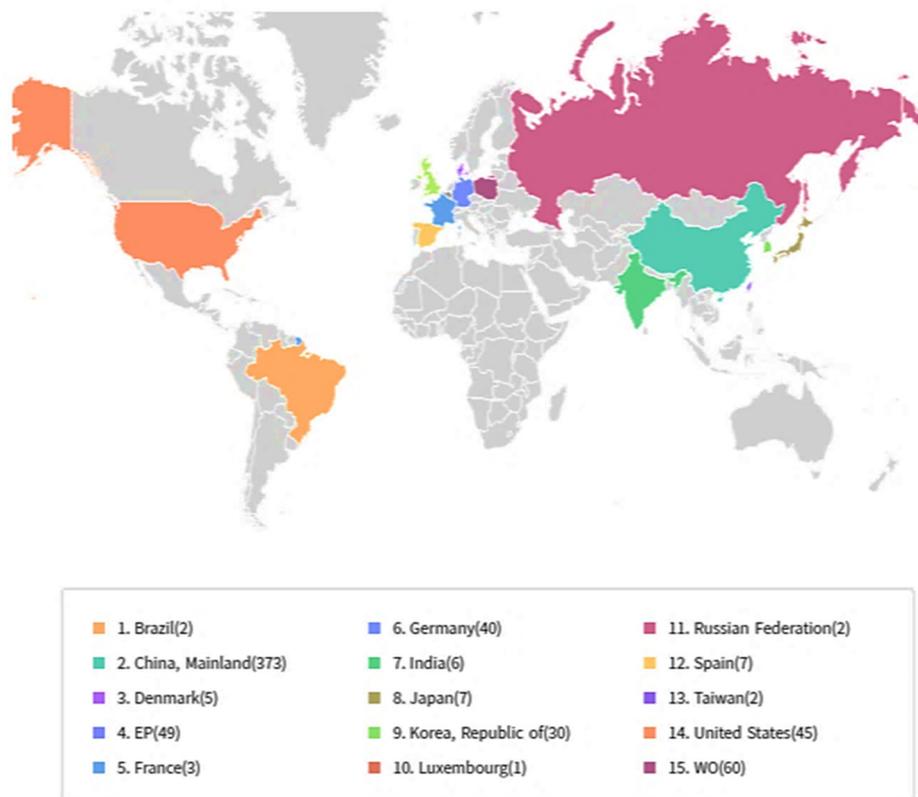


Figure 3. Geographical distribution of the analysis of the main countries/regions of the depositories of the prospected technologies with their number of patent documents. EPO—European Patent Office; WIPO—World Intellectual Property Organization.

In regard to the technological areas of the prospective inventions (Figure 4), 24 technology classifications were discovered. According to the DWPI database, the number of technologies points to recent innovations and can provide an important overview of the “state of the market” and how it is segmented. The number of technology area assignments to patent applications can report a diversified portfolio or a specific technical focus. As it can be noticed, the three leading companies in development in these technological areas are Vestas Wind, State Grid Corp, and Gen Electric, and they count for 41% of all records in the resulting set.

In regard to the technological area (a), pink refers to “wind turbine, rotor blade”. Here, Gen Electric has 47% of their patent applications classified in this area, while Vestas Wind has 38% and State Grid Corp has 28%. From this result, we can observe that practically all the applicants have patents that fit in this technological area.

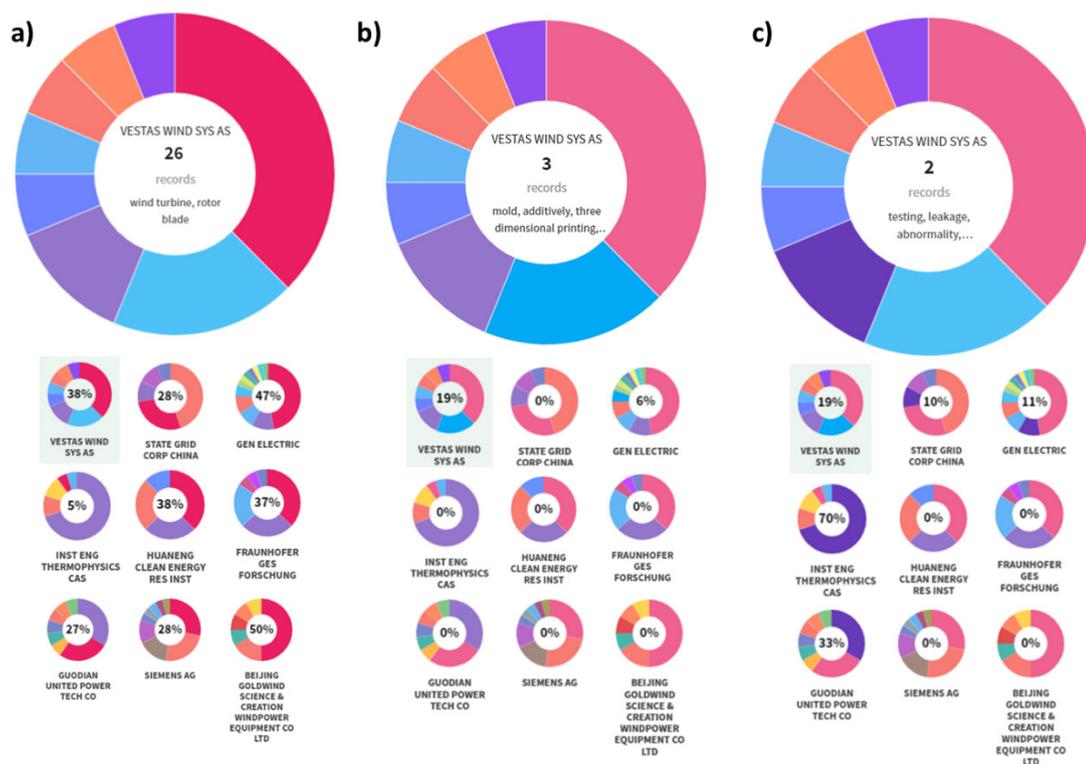


Figure 4. Analysis of the three main technological areas related to the inventions. Comparisons between the top filing company, Vestas Wind Sys As, and other companies, wherein ((a), pink) refers to wind turbine, rotor, and blade; ((b), blue) refers to additively, three-dimensional printing, additive, composite, build, and thermoplastic; ((c), purple) refers to testing, leakage, abnormality, monitoring, sensor, detecting, and inspection. In the center of the larger donut chart is the number of patent documents of the main applicant for a given technology and, in the smaller donut charts, the percentage of companies involved in the production of inventions related to this technology.

The technological area (b) in blue refers to “additively, three-dimensional printing, additive, composite, build, thermoplastic”, and (c) purple refers to “testing, leakage, abnormality, monitoring, sensor, detecting, inspection “. The identified patent applications in these technological areas most often seek improvements in wind turbines, especially in individual turbine parts, such as motors, blades, and gearboxes. In addition, many of the patents describe a new device or even a novel method for fault diagnosis based on non-destructive testing. Zhang et al., 2022 [90], described a utility model using an infrared non-destructive device related to a wind turbine blade infrared flaw-detection robot. The robot can realize omni-directional scanning of blades with complex shapes and automatic quantitative identification of internal damage in blades. Jiang and colleagues, 2022 [91], showed a wind power generation blade defect-detection system comprised of a working device, where the working device comprises a main bracket, a walking mechanism, and a flaw-detection mechanism. Table 3 shows other patents that have been prospected that are related to the use of different techniques to identify faults in the wind turbine and its components.

Table 3. Patents documents involving technologies related to fault diagnosis for wind energy.

Priority Number	Title	Refers to	Reference
US20210108988A 1	Detecting Faults in Wind Turbines	A wind turbine monitoring system for detecting faults produced by wind turbine generators and comprises a shaft rotation frequency signal that is determined from the first signal, and the first signal that is obtained from the generator of the wind turbine.	[40]
CN108957315A	Fault diagnosis method and equipment of wind turbine generator system	A wind turbine generator system fault diagnosing method that involves determining the testing point of fault detection of a system, detecting the testing signal of a testing point for fault detection, and determining the fault diagnosis function system.	[92]
CN104374575A	Wind turbine main bearing fault diagnosis method based on blind source separation	Blind source separating wind turbine main bearing fault diagnosis method involves receiving sound transmission signals and acoustic emission signals, adopting a reconstruction algorithm, and determining turbine test normal operation conditions.	[93]
CN107560849A	Wind turbine generator bearing fault diagnosis method for multi-channel deep convolutional neural network	Neural-network-based multi-channel depth convolution wind turbine bearing fault diagnosing method involves collecting test bearing under each state drive end and evaluating diagnosis model for obtaining application bearing to be monitored.	[94]
CN113323823A	Fan blade icing fault detection method and system based on AWKELM	Method for detecting fan blade icing fault that involves inputting supervisory control and data acquisition (SCADA) data of wind generating set to be tested and performing maintenance decisions according to the detection results.	[95]

The last indicator of the patent search performed: Figure 5 shows the main International Patent Classification (IPC) codes attributed to the patent documents found. The IPC code was declared in 1971 and is based on a hierarchical language of independent symbols for the classification of patents and utility models in accordance with the different areas of technology to which they belong. Of all the documents found, 241 were classified with the code F03D 17/00, which is related to the monitoring or testing of wind motors. The second code exhibited in the patent documents was the G01M, which refers to the testing of machine parts, which corroborates with the key words chosen in this work for the patent search.

Most of the documentation was classified in technology area F, which relates to "mechanical". However, some of the patents were classified by area G, which is related to "physics". It is worth pointing out that the same document can be assigned more than one code. Table 4 shows the descriptions of the top 10 codes.

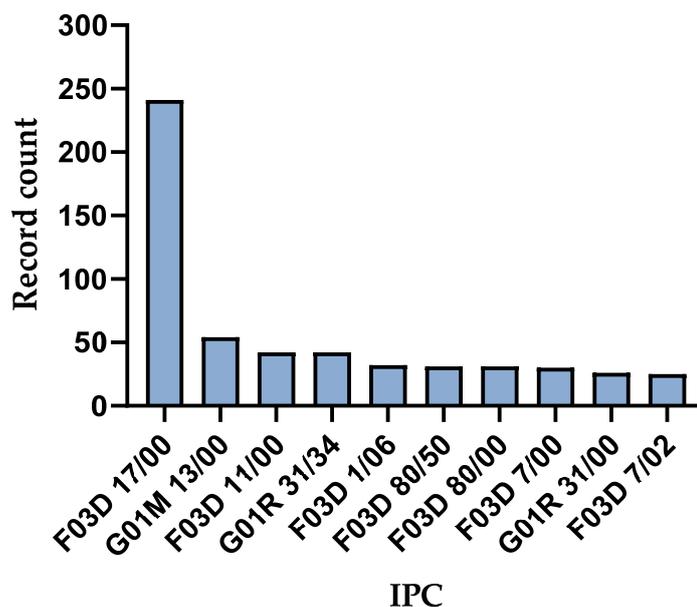


Figure 5. Most-used classification codes in area of development of technologies applied to wind turbines.

Table 4. IPC codes in technological prospecting.

IPC Code	Related to
F03D 17/00	Monitoring or testing of wind motors, e.g., diagnostics (testing during the commissioning of wind motors F03D13/30)
G01M 13/00	Testing of machine parts
F03D 11/00	Details, parts, and accessories not included in or pertinent to the other groups of this subclass
G01R 31/34	Testing dynamo-electric machines
F03D 1/06	Rotors
F03D 80/50	Maintenance or repair
F03D 80/00	Details, components, or accessories not provided for in groups F03D1/00–F03D17/00
F03D 7/00	Controlling wind motors
G01R 31/00	Arrangements for testing electric properties; arrangements for locating electrical faults; arrangements for electrical testing characterized by what is being tested not provided for elsewhere
F03D 7/02	The wind motors have a rotation axis substantially parallel to the air flow entering the rotor

One of the challenges of the 21st century is the great need to change the way energy systems generate around the world. Energy transition is a reality for all nations because of the targets made in the Paris agreement. Decarbonization plans are under constant evolution by the global community with the aim of reducing greenhouse gas emissions in a sustainable manner. This is due to the global warming effect and its drastic consequences for society. There are several strategies, measurements, and technologies that can be applied to improve sustainability, and wind energy is one of them [3,9].

Wind power is a renewable energy source with great potential for reducing greenhouse gas emissions from the use of fossil fuel and can mitigate climate change and improve air quality. The rapid and great advances in the use of wind energy have raised

important concerns about the costs associated with this technology, mainly the operational and security cost impacts and also reliability [96]. Consequently, new technologies are constantly being developed with the main objective of mitigating the potential failures and defects found in wind turbines. Several researchers have employed structural health monitoring (SHM) and nondestructive testing (NDT) techniques to further develop effective damage detection tools for WTBs. These techniques can play a key role in improving reliability, optimizing production yield, and managing maintenance strategies for wind turbines.

The main techniques used for fault detection are strain measurements, acoustic emission methods, ultrasonic-based methods, and thermography and, more recently, researchers are trying the combination of at least two NDTs to be applied to WTB monitoring. In addition, as wind turbines are usually sited in remote areas, health monitoring with long-distance applications is extremely necessary for instantaneous service. In light of this, signal processing techniques involving data extraction, analysis, and normalization are increasingly being employed to extract features from the signals and attempt to determine potential damage and their location and quantify it.

Signal-processing algorithms can provide useful and accurate results in order to mitigate the shortcomings of existing and currently employed techniques. Examples of recently developed and applied algorithms for fault diagnosis in wind turbines are the fast S-transformation, empirical WT, full EMD set, and others.

Machine learning is a system that can modify its behavior autonomously based on its own experience. Improvements were observed in the integrated application of computational techniques such as machine learning, SCADA, and neural networks (ANNs) with the more traditional techniques [97,98]. One of the main technological advances in the field of wind energy is not only the identification of faults but also their prediction using the Internet of Things (IoT) on Deep Learning (DL) based on Artificial intelligence (AI). These are considered future directions and have potential benefits, such as high-performance predictive and low false-positive rates via numerical simulations of collapsing phases and the diagnostic troubleshooting of wind energy production equipment [99].

The estimation of patent documents could reflect the newness that is brought by this work, and this may help companies and/or organizations in making decisions about technological developments in this particular area. Based on the information presented, companies can target opportunities as well as review the risks associated with the development of new inventions in the area of renewable energies, especially wind power energy. By leveraging the information extracted from patent research, together with marketing research, consumer analysis, and the assessment of internal production capacity, the process of research and development of new products can be guided to help the industry. Overall, the analysis and extraction of patent data can support the acquisition of information to analyze and predict possible future trends in technological development, providing assistance in corporate decision-making.

4. Conclusions

Wind power is a renewable energy widely used worldwide, and its rapid advances raise concerns, especially relating to safety and reliability. Based on the results of this work, it was possible to observe that fault diagnosis for wind turbines is very important, and the development of new technologies is still necessary. This can be seen by taking into account the increasing evolution in patent filings over the years. Furthermore, it can be observed that of the 636 patent documents found, most reported the development of new methods or new devices for identifying potential faults and defects in wind turbines and their components, especially in the blade components. In addition, it was possible to retrieve patents for a used model, improving an already used technique.

This technological prospection focused on patent documents has highlighted the important growth in the development of inventions of new methods and techniques used for the accurate detection of faults in wind turbines through non-destructive methods.

The findings pointed out the main applicants of the technologies, as well as the main inventors, highlighting Vestas Wind SYS As and Wang, Rui-ming, respectively. In evidence, the world leader in the wind power market is China, which has a total of 373 patent documents and is also the main market for these applications. The results found in this study make clear that artificial intelligence and database analysis are the future strategies for improving the methods already used, especially in view of the peculiarities involved in the maintenance and viability of wind turbines.

All the results observed in this prospection can directly contribute to possible investments in research and development on fault diagnosis techniques, identifying potential saturated fields and also the ones that present possible technological trends. Furthermore, by identifying the main areas and countries, companies can use this technological research to help in their decision-making when needed. They could also use the findings to target new possible technologies of interest and focus their efforts on the development of their own inventions while identifying gaps that can be converted into new discoveries.

Additionally, this work could directly support the identification of market needs, which may be the target for research and development of novel inventions based on the application of different fault diagnosis techniques, combining traditional techniques with advanced mathematical models, such as artificial intelligence and deep learning, especially considering the increased importance for the worldwide development of renewable and sustainable energy. This research may present some limitations, which may be similar to any other technological prospection using patent analysis. The limitations may be related to the search strategy, which limited access to documents related to the selected keywords. However, it is important to point out that the keywords proposed in this analysis allowed the presentation and discussion of a cohesive and robust form regarding the diagnosis of wind turbine failures, exposing, especially, the challenges of this sector. Continued research is needed to contribute to clarifying the issues within this area.

Author Contributions: Conceptualization, N.B.B., D.D.G.N., A.Á.B.S. and B.A.S.M.; Data Curation, D.D.G.N.; Formal Analysis, N.B.B., D.D.G.N., A.Á.B.S. and B.A.S.M.; Investigation, N.B.B., D.D.G.N. and B.A.S.M.; Methodology, N.B.B., D.D.G.N., A.Á.B.S. and B.A.S.M.; Project Administration, A.Á.B.S. and B.A.S.M.; Software, D.D.G.N.; Supervision, B.A.S.M.; Validation, A.Á.B.S.; Visualization, N.B.B.; Writing—Original Draft, N.B.B. and D.D.G.N.; Writing—Review and Editing, A.Á.B.S. and B.A.S.M. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: All research data were reported in the manuscript.

Acknowledgments: The authors thank the SENAI CIMATEC University Center for their support in the development of this research, CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (BASM is a Technological fellow from CNPq 306041/2021 and AÁBS is a Technological fellow from CNPq 313213/2019), and also Aneel (Agência Nacional de Energia Elétrica) and CHESF (Companhia Hidro Elétrica do São Francisco).

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Bashir, M.; Bashir, A. Principle Parameters and Environmental Impacts that Affect the Performance of Wind Turbine: An Overview. *Arab. J. Sci. Eng.* **2022**, *47*, 7891–7909. <https://doi.org/10.1007/s13369-021-06357-1>.
2. Duc Luong, N. A critical review on potential and current status of wind energy in Vietnam. *Renew. Sustain. Energy Rev.* **2015**, *43*, 440–448. <https://doi.org/10.1016/J.RSER.2014.11.060>.
3. Porté-Agel, F.; Bastankhah, M.; Shamsoddin, S. Wind-Turbine and Wind-Farm Flows: A Review. *Bound.-Layer Meteorol.* **2020**, *174*, 1–59. <https://doi.org/10.1007/s10546-019-00473-0>.
4. Pachauri, R.K.; Meyer, L.A. *IPCC, 2014: Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*; IPCC: Geneva, Switzerland, 2014.

5. Mishnaevsky, L. Sustainable End-of-Life Management of Wind Turbine Blades: Overview of Current and Coming Solutions. *Materials* **2021**, *14*, 1124. <https://doi.org/10.3390/MA14051124>.
6. de Souza Mendonça, A.K.; Vaz, C.R.; Lezana, Álvaro G.R.; Anacleto, C.A.; Paladini, E.P. Comparing patent and scientific literature in airborne wind energy. *Sustainability* **2017**, *9*, 915. <https://doi.org/10.3390/su9060915>.
7. Fazal, M.K. and M.R. Chapter 1—Fundamentals of renewable energy systems. In *Renewable Energy Conversion Systems*; Academic Press Inc.: Cambridge, MA, USA, 2021; pp. 1–19.
8. Joo, K.; Lee, M.; Lee, G. Technology Originality and Convergence Analysis in the Wind Power Field Using Patents. *Energies* **2022**, *15*, 3316. <https://doi.org/10.3390/EN15093316>.
9. Costa, Á.M.; Orosa, J.A.; Vergara, D.; Fernández-Arias, P. New tendencies in wind energy operation and maintenance. *Appl. Sci.* **2021**, *11*, 1386. <https://doi.org/10.3390/app11041386>.
10. Zhengru Ren, Amrit Shankar Verma, Ye Li, Julie, J.E. Teuwen, Z.J. Offshore wind turbine operations and maintenance: A state-of-the-art review. *Renew. Sustain. Energy Rev.* **2021**, *144*, 110886.
11. Lee, J.; Zhao, F. *Global Wind Report | GWEC*; Global Wind Energy Council: Bonn, Germany, 2021; Volume 75.
12. Global Wind Energy Council. Annual Wind Report. 2022. Available online: <https://gwec.net/global-wind-report-2022/> (accessed on 28 December 2022).
13. Gao, B.; He, Y.; Woo, W.L.; Tian, G.Y.; Liu, J.; Hu, Y. Multidimensional Tensor-Based Inductive Thermography with Multiple Physical Fields for Offshore Wind Turbine Gear Inspection. *IEEE Trans. Ind. Electron.* **2016**, *63*, 6305–6315. <https://doi.org/10.1109/TIE.2016.2574987>.
14. Junginger, M.; Hittinger, E.; Williams, E.; Wiser, R. *Onshore Wind Energy*; Elsevier Inc.: Amsterdam, The Netherlands, 2019.
15. Sanati, H.; Wood, D.; Sun, Q. Condition monitoring of wind turbine blades using active and passive thermography. *Appl. Sci.* **2018**, *8*, 2004.
16. Wang, W.; Xue, Y.; He, C.; Zhao, Y. Review of the Typical Damage and Damage-Detection Methods of Large Wind Turbine Blades. *Energies* **2022**, *15*, 5672.
17. Chen, I.W.; Wong, B.L.; Lin, Y.H.; Chau, S.W.; Huang, H.H. Design and analysis of jacket substructures for offshore wind turbines. *Energies* **2016**, *9*, 264. <https://doi.org/10.3390/en9040264>.
18. Mishnaevsky, L.; Thomsen, K. Costs of repair of wind turbine blades: Influence of technology aspects. *Wind Energy* **2020**, *23*, 2247–2255. <https://doi.org/10.1002/WE.2552>.
19. IRENA. *The Power to Change: Solar and Wind Cost Reduction Potential to 2025*; IRENA: Masdar City, United Arab Emirates, 2016; ISBN 9789295111974.
20. Artigao, E.; Martín-Martínez, S.; Honrubia-Escribano, A.; Gómez-Lázaro, E. Wind turbine reliability: A comprehensive review towards effective condition monitoring development. *Appl. Energy* **2018**, *228*, 1569–1583. <https://doi.org/10.1016/j.apenergy.2018.07.037>.
21. Agarwal, A. Wind Turbine Operations and Maintenance Market—Global Market Size, Trends, and Key Country Analysis to 2025. *Technol. Rep. Glob. Data* 2017.
22. Du, Y.; Zhou, S.; Jing, X.; Peng, Y.; Wu, H.; Kwok, N. Damage detection techniques for wind turbine blades: A review. *Mech. Syst. Signal Process.* **2020**, *141*, 106445.
23. Sunder Selwyn, T.; Hemalatha, S. Experimental analysis of mechanical vibration in 225 kW wind turbine gear box. *Mater. Today Proc.* **2021**, *46*, 3292–3296. <https://doi.org/10.1016/J.MATPR.2020.11.461>.
24. Civera, M.; Surace, C. Non-Destructive Techniques for the Condition and Structural Health Monitoring of Wind Turbines: A Literature Review of the Last 20 Years. *Sensors* **2022**, *22*, 1627. <https://doi.org/10.3390/s22041627>.
25. Marquez, F.P.G.; Muñoz, C.Q.G. A new approach for fault detection, location and diagnosis by ultrasonic testing. *Energies* **2020**, *13*, 1192.
26. de Azevedo, H.D.M.; de Arruda Filho, P.H.C.; Araújo, A.M.; Bouchonneau, N.; Rohatgi, J.S.; de Souza, R.M.C. Vibration monitoring, fault detection, and bearings replacement of a real wind turbine. *J. Brazilian Soc. Mech. Sci. Eng.* **2017**, *39*, 3837–3848. <https://doi.org/10.1007/s40430-017-0853-2>.
27. Aihara, A.; Kawaguchi, T.; Miki, N.; Azami, T.; Sakamoto, H.; Okuma, M. A Vibration Estimation Method for Wind Turbine Blades. *Exp. Mech.* **2017**, *57*, 1213–1224. <https://doi.org/10.1007/s11340-017-0295-x>.
28. Kaewniam, P.; Cao, M.; Alkayem, N.F.; Li, D.; Manoach, E. Recent advances in damage detection of wind turbine blades: A state-of-the-art review. *Renew. Sustain. Energy Rev.* **2022**, *167*, 112723.
29. Ciang, C.C.; Lee, J.R.; Bang, H.J. Structural health monitoring for a wind turbine system: A review of damage detection methods. *Meas. Sci. Technol.* **2008**, *19*, 20. <https://doi.org/10.1088/0957-0233/19/12/122001>.
30. Hwang, S.; An, Y.K.; Sohn, H. Continuous Line Laser Thermography for Damage Imaging of Rotating Wind Turbine Blades. *Procedia Eng.* **2017**, *188*, 225–232.
31. Yang, B.; Zhang, L.; Zhang, W.; Ai, Y. Non-destructive testing of wind turbine blades using an infrared thermography: A review. In *2013 International Conference on Materials for Renewable Energy and Environment*; IEEE: Piscataway, NJ, USA, 2014; pp. 407–410. [doi:doi.org/10.1109/ICMREE.2013.6893694](https://doi.org/10.1109/ICMREE.2013.6893694).
32. Glowacz, A. Thermographic Fault Diagnosis of Shaft of BLDC Motor. *Sensors* **2022**, *22*, 8537. <https://doi.org/10.3390/s22218537>.
33. Liu, Z.; Zhang, L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. *Meas. J. Int. Meas. Confed.* **2020**, *149*, 107002. <https://doi.org/10.1016/j.measurement.2019.107002>.

34. Fatimi, A. Exploring the Patent Landscape and Innovation of Hydrogel-based Bioinks Used for 3D Bioprinting. *Recent Adv. Drug Deliv. Formul.* **2022**, *16*, 145–163, doi:dx.doi.org/10.2174/2667387816666220429095834.
35. Liu, Z.; Jia, Z.; Vong, C.M.; Han, J.; Yan, C.; Pecht, M. A Patent Analysis of Prognostics and Health Management (PHM) Innovations for Electrical Systems. *IEEE Access* **2018**, *6*, 18088–18107. <https://doi.org/10.1109/ACCESS.2018.2818114>.
36. T, P.; Park, C.; Stephen, E. Detecting Internal Abnormalities in Turbines. U.S. Patent 4,335,600, 22 June 1982.
37. Nian, V.; Mignacca, B.; Locatelli, G. Policies toward net-zero: Benchmarking the economic competitiveness of nuclear against wind and solar energy. *Appl. Energy* **2022**, *320*, 119275. <https://doi.org/10.1016/J.APENERGY.2022.119275>.
38. Su, C.W.; Khan, K.; Umar, M.; Zhang, W. Does renewable energy redefine geopolitical risks? *Energy Policy* **2021**, *158*, 112566. <https://doi.org/10.1016/J.ENPOL.2021.112566>.
39. Su, C.W.; Pang, L.D.; Tao, R.; Shao, X.; Umar, M. Renewable energy and technological innovation: Which one is the winner in promoting net-zero emissions? *Technol. Forecast. Soc. Change* **2022**, *182*, 121798. <https://doi.org/10.1016/j.techfore.2022.121798>.
40. Qu, W.Q.; Liyan, J.W. Detecting Faults in Wind Turbines. Patent U.S. US20210108988, 11 May 2021.
41. Ernst, R.; Klinge, I.S.; Enoch, C.; Hawkins, J. Handling System and Associated Methods for Conducting Tomography Scans for Defects In Manufactured Wind Turbine Blades 2021. Patent WO/2021/151448, 5 August 2021.
42. Li, D.D.; Zhao, Y.; Zhao, Y.; Jiang, H.T.; Zhang, K. Fault Diagnosis Method of Planetary Gear Box of Wind Turbine 2021. Patent CN112861787A, 28 May 2021.
43. Chou, J.S.; Chiu, C.K.; Huang, I.K.; Chi, K.N. Failure analysis of wind turbine blade under critical wind loads. *Eng. Fail. Anal.* **2013**, *27*, 99–118. <https://doi.org/10.1016/J.ENGFAILANAL.2012.08.002>.
44. García Márquez, F.P.; Tobias, A.M.; Pinar Pérez, J.M.; Papaalias, M. Condition monitoring of wind turbines: Techniques and methods. *Renew. Energy* **2012**, *46*, 169–178. <https://doi.org/10.1016/J.RENENE.2012.03.003>.
45. Tchakoua, P.; Wamkeue, R.; Ouhrouche, M.; Slaoui-Hasnaoui, F.; Tameghe, T.A.; Ekemb, G. Wind Turbine Condition Monitoring: State-of-the-Art Review, New Trends, and Future Challenges. **2014**, *7*, 2595–2630. <https://doi.org/10.3390/en7042595>.
46. Xu, J.; Ding, X.; Gong, Y.; Wu, N.; Yan, H. Rotor imbalance detection and quantification in wind turbines via vibration analysis. *Wind Eng.* **2022**, *46*, 3–11. <https://doi.org/10.1177/0309524X21999841>.
47. Strömbergsson, D.; Marklund, P.; Berglund, K. Increasing wind turbine drivetrain bearing vibration monitoring detectability using an artificial neural network implementation. *Appl. Sci.* **2021**, *11*, 3588.
48. Gholizadeh, S. A review of non-destructive testing methods of composite materials. *Procedia Struct. Integr.* **2016**, *1*, 50–57. <https://doi.org/10.1016/J.PROSTR.2016.02.008>.
49. Park, B.; An, Y.K.; Sohn, H. Visualization of hidden delamination and debonding in composites through noncontact laser ultrasonic scanning. *Compos. Sci. Technol.* **2014**, *100*, 10–18. <https://doi.org/10.1016/J.COMPSCITECH.2014.05.029>.
50. Mohr, G.; Sommer, K.; Knobloch, T.; Altenburg, S.J.; Recknagel, S.; Bettge, D.; Hilgenberg, K. Process Induced Preheating in Laser Powder Bed Fusion Monitored by Thermography and Its Influence on the Microstructure of 316L Stainless Steel Parts. *Metals* **2021**, *11*, 1063. <https://doi.org/10.3390/MET11071063>.
51. Ishikawa, M.; Tsukagoshi, M.; Kasano, H.; Nishino, H. Influence of composition and surface discoloration of concrete on active thermographic nondestructive inspection. *Measurement* **2021**, *168*, 108395. <https://doi.org/10.1016/J.MEASUREMENT.2020.108395>.
52. Mezza, S.; Vazquez, P.; Ben M'barek Jemai, M.; Fronteau, G. Infrared thermography for the investigation of physical–chemical properties and thermal durability of Tunisian limestone rocks. *Constr. Build. Mater.* **2022**, *339*, 127470. <https://doi.org/10.1016/J.CONBUILDMAT.2022.127470>.
53. Hwang, S.; An, Y.K.; Yang, J.; Sohn, H. Remote Inspection of Internal Delamination in Wind Turbine Blades using Continuous Line Laser Scanning Thermography. *Int. J. Precis. Eng. Manuf. Green Technol.* **2020**, *7*, 699–712. <https://doi.org/10.1007/s40684-020-00192-9>.
54. Doroshnasir, M.; Worzewski, T.; Krankenhagen, R.; Röllig, M.; Doroshnasir, C.M. On-site inspection of potential defects in wind turbine rotor blades with thermography. *Wind Energy* **2015**, *19*, 1407–1422.
55. Oehme, F.; Gleichauf, D.; Suhr, J.; Balaesque, N.; Sorg, M.; Fischer, A. Thermographic detection of turbulent flow separation on rotor blades of wind turbines in operation. *J. Wind Eng. Ind. Aerodyn.* **2022**, *226*, 105025.
56. Li, C.; Sanchez, R.V.; Zurita, G.; Cerrada, M.; Cabrera, D.; Vásquez, R.E. Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals. *Mech. Syst. Signal Process.* **2016**, *76–77*, 283–293. <https://doi.org/10.1016/J.YMSSP.2016.02.007>.
57. Ma, M.; Sun, C.; Chen, X. Deep Coupling Autoencoder for Fault Diagnosis with Multimodal Sensory Data. *IEEE Trans. Ind. Informatics* **2018**, *14*, 1137–1145. <https://doi.org/10.1109/TII.2018.2793246>.
58. Wang, J.; Fu, P.; Zhang, L.; Gao, R.X.; Zhao, R. Multilevel Information Fusion for Induction Motor Fault Diagnosis. *IEEE/ASME Trans. Mechatron.* **2019**, *24*, 2139–2150. <https://doi.org/10.1109/TMECH.2019.2928967>.
59. Dao, P.B. Condition monitoring and fault diagnosis of wind turbines based on structural break detection in SCADA data. *Renew. Energy* **2022**, *185*, 641–654. <https://doi.org/10.1016/j.renene.2021.12.051>.
60. Mian, T.; Choudhary, A.; Fatima, S. Vibration and infrared thermography based multiple fault diagnosis of bearing using deep learning. *Nondestruct. Test. Eval.* **2022**, *1–12*.
61. Jiang, G.; Jia, C.; Nie, S.; Wu, X.; He, Q.; Xie, P. Multiview enhanced fault diagnosis for wind turbine gearbox bearings with fusion of vibration and current signals. *Meas. J. Int. Meas. Confed.* **2022**, *196*, 111159. <https://doi.org/10.1016/j.measurement.2022.111159>.

62. de Novaes Pires Leite, G.; da Cunha, G.T.M.; dos Santos Junior, J.G.; Araújo, A.M.; Rosas, P.A.C.; Stosic, T.; Stosic, B.; Rosso, O.A. Alternative fault detection and diagnostic using information theory quantifiers based on vibration time-waveforms from condition monitoring systems: Application to operational wind turbines. *Renew. Energy* **2021**, *164*, 1183–1194. <https://doi.org/10.1016/j.renene.2020.10.129>.
63. Liu, J.; Wang, X.; Wu, S.; Wan, L.; Xie, F. Wind turbine fault detection based on deep residual networks. *Expert Syst. Appl.* **2023**, *213*, 119102.
64. Manno, D.; Cipriani, G.; Ciulla, G.; Di Dio, V.; Guarino, S.; Lo Brano, V. Deep learning strategies for automatic fault diagnosis in photovoltaic systems by thermographic images. *Energy Convers. Manag.* **2021**, *241*, 114315.
65. Wang, H.; Liu, Z.; Peng, D.; Cheng, Z. Attention-guided joint learning CNN with noise robustness for bearing fault diagnosis and vibration signal denoising. *ISA Trans.* **2022**, *128*, 470–484. <https://doi.org/10.1016/j.isatra.2021.11.028>.
66. This is Vestas. Available online: <https://www.vestas.com/> (accessed on 6 December 2022).
67. State Grid Corporation of China. Available online: <https://stategrid.com.br/> (accessed on 7 December 2022).
68. GE—ABOUT US. Available online: <https://www.ge.com/about-us> (accessed on 7 December 2022).
69. Bahramian, P.; Jenkins, G.P.; Milne, F. The displacement impacts of wind power electricity generation: Costly lessons from Ontario. *Energy Policy* **2021**, *152*, 112211. <https://doi.org/10.1016/J.ENPOL.2021.112211>.
70. Crijns-Graus, W.; Wild, P.; Amineh, M.P.; Hu, J.; Yue, H. International Comparison of Research and Investments in New Renewable Electricity Technologies: A Focus on the European Union and China. *Energies* **2022**, *15*, 6383. <https://doi.org/10.3390/en15176383>.
71. Guo, X.; Zhang, X.; Du, S.; Li, C.; Siu, Y.L.; Rong, Y.; Yang, H. The impact of onshore wind power projects on ecological corridors and landscape connectivity in Shanxi, China. *J. Clean. Prod.* **2020**, *254*, 120075. <https://doi.org/10.1016/j.jclepro.2020.120075>.
72. Wu, Z.; Zhou, M.; Li, G.; Zhao, T.; Zhang, Y.; Liu, X. Interaction between balancing market design and market behaviour of wind power producers in China. *Renew. Sustain. Energy Rev.* **2020**, *132*, 110060. <https://doi.org/10.1016/J.RSER.2020.110060>.
73. Enrique Rosales-Asensio, David Borge-Diez, Jorge-Juan Blanes-Peiró, Ana Pérez-Hoyos, A.C.-S. Review of wind energy technology and associated market and economic conditions in Spain. *Renew. Sustain. Energy Rev.* **2019**, *101*, 415–427. <https://doi.org/10.1016/j.rser.2018.11.029>.
74. Qiang Wang Effective policies for renewable energy—The example of China’s wind power—Lessons for China’s photovoltaic power. *Rev. Renew. Sustain. Energy* **2010**, *14*, 702–712. <https://doi.org/10.1016/j.rser.2009.08.013>.
75. Yu-Ling Hsiao, C.; Sheng, N.; Fu, S.; Wei, X. Evaluation of contagious effects of China’s wind power industrial policies. *Energy* **2022**, *238*, 121760. <https://doi.org/10.1016/j.energy.2021.121760>.
76. Stern, N.; Xie, C. China’s new growth story: Linking the 14th Five-Year Plan with the 2060 carbon neutrality pledge. *J. Chinese Econ. Bus. Stud.* **2022**, 1–12.
77. Niu, Z.; Xiong, J.; Ding, X.; Wu, Y. Analysis of China’s Carbon Peak Achievement in 2025. *Energies* **2022**, *15*, 5041.
78. Jiang, Z.; Liu, Z. Policies and exploitative and exploratory innovations of the wind power industry in China: The role of technological path dependence. *Technol. Forecast. Soc. Change* **2022**, *177*, 121519. <https://doi.org/10.1016/j.techfore.2022.121519>.
79. Dai, J.; Xin, Y.; Li, W. Development of wind power industry in China: A comprehensive assessment. *Renew. Sustain. Energy Rev.* **2018**, *97*, 156–164. <https://doi.org/10.1016/j.rser.2018.08.044>.
80. Song, Y.; Liu, J.; Wei, Y.; Zhang, M. Study on the direct and indirect effectiveness of wind power policy: Empirical evidence from 30 provinces in China. *Renew. Energy* **2021**, *170*, 749–763. <https://doi.org/10.1016/j.renene.2021.02.044>.
81. Jiang, Z.; Zhiying, L. Can wind power policies effectively improve the productive efficiency of Chinese wind power industry? *Int. J. Green Energy* **2021**, *18*, 1339–1351. <https://doi.org/10.1080/15435075.2021.1904407>.
82. Zihao Jiang, Jiarong Shi, Zhiying Liu, L.G. Beyond bean counting: Is the policy effective for the innovation efficiency of wind power industry in China? *Res. Eval.* **2022**, *31*, 132–144. <https://doi.org/10.1093/reseval/rvab037>.
83. Wang, X.; Zhi, M. Summary of object detection based on convolutional neural network. In *Eleventh International Conference on Graphics and Image Processing*; SPIE: Bellingham, WA, USA, 2020; Volume 113730.
84. Zhang, S.; Chen, L.; Zheng, Y.; Li, Y.; Li, Y.; Zeng, M. How policies guide and promoted wind power to market transactions in china during the 2010s. *Energies* **2021**, *14*, 4096.
85. Shoeib, E.A.H.; Renski, H.C.; Hamin Infield, E. Who benefits from Renewable Electricity? The differential effect of wind power development on rural counties in the United States. *Energy Res. Soc. Sci.* **2022**, *85*, 102398.
86. Muhammed, G.; Tekbiyik-Ersoy, N. Development of renewable energy in china, usa, and brazil: A comparative study on renewable energy policies. *Sustain.* **2020**, *12*, 1–30. <https://doi.org/10.3390/su12219136>.
87. Wiser, R.; Bolinger, M.; Hoen, B. *Land-Based Wind Market Report: 2022 Edition*; Lawrence Berkeley National Lab. (LBNL): Berkeley, CA, USA, 2022.
88. Zhang, H.; Yang, J.; Ren, X.; Wu, Q.; Zhou, D.; Elahi, E. How to accommodate curtailed wind power: A comparative analysis between the US, Germany, India and China. *Energy Strateg. Rev.* **2020**, *32*, 100538. <https://doi.org/10.1016/j.esr.2020.100538>.
89. Msigwa, G.; Ighalo, J.O.; Yap, P.S. Considerations on environmental, economic, and energy impacts of wind energy generation: Projections towards sustainability initiatives. *Sci. Total Environ.* **2022**, *849*, 157755.
90. Zhang, X.-Y.; Zhou, B. Infrared Flaw Detection Robot for Wind Turbine Blades. Patent CN215979709U, 8 March 2022.
91. Wei, J. Wind Power Generation Blade Defect Detection System. Patent CN217029182U, 22 July 2022.
92. Ma, X. Fault Diagnosis Method and Equipment of Wind Turbine Generator Set. Patent CN108957315A, 7 December 2017.

93. Liu, H.; Gao, S.Z.; Wang, J.; Zhao, L.J.; Z.; Guo, S. Wind Turbine Main Bearing Fault Diagnosis Method Based on Blind Source Separation 2015. Patent CN104374575A, 25 February 2017
94. Ma, Y.C.; Liu, Y.Q.; Yang, Z.L.; Zhao, Y.; Zhang, L.N. Wind Turbine Generator Bearing Fault Diagnosis Method for Multi-channel Deep Convolutional Neural Network 2018. Patent CN107560849B, 18 February 2020.
95. Li, P.; Tong, R.N.; Lang, X.; Gao, L.; Zeng, J.R.; Fu, L.T.; Wang, Y.X.; Wang, H.Y. Fan Blade Icing Fault Detection Method and System Based on AWKELM 2021. Patent CN113323823B, 31 August 2021.
96. Soares-Ramos, E.P.P.; de Oliveira-Assis, L.; Sarrias-Mena, R.; Fernández-Ramírez, L.M. Current status and future trends of offshore wind power in Europe. *Energy* **2020**, *202*, 117787. <https://doi.org/10.1016/j.energy.2020.117787>.
97. Souza, R.M.; Nascimento, E.G.S.; Miranda, U.A.; Silva, W.J.D.; Lepikson, H.A. Deep learning for diagnosis and classification of faults in industrial rotating machinery. *Comput. Ind. Eng.* **2021**, *153*, 107060. <https://doi.org/10.1016/j.cie.2020.107060>.
98. Elyasichamazkoti, F.; Khajehpoor, A. Application of machine learning for wind energy from design to energy-Water nexus: A Survey. *Energy Nexus* **2021**, *2*, 100011. <https://doi.org/10.1016/j.nexus.2021.100011>.
99. Sudhakar, P.; Kamble, N.K.; Geetha, K.; Turukmane, A. V.; Babu, S.; Jayaraman, P. Faulty diagnostics model for wind power plant application using AI. *Meas. Sensors* **2023**, *25*, 100621. <https://doi.org/10.1016/j.measen.2022.100621>.

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Artigo II

Exploratory analysis of a real wind turbine dataset, using AI tools to cluster and classify data, for condition monitoring and fault detection

Artigo publicado em CONCILIUM, 23(12), 527–541.

Url: <https://clium.org/index.php/edicoes/article/view/1539>, em junho de 2023.

Natasha Benjamim Barbosa, Rogerio Adriano da Fonseca Santiago, Ricardo Cerqueira Medrado, Tassio Farias de Carvalho, Oberdan Rocha Pinheiro, Erick Giovani Sperandio Nascimento, Bruna Aparecida Souza Machado, Alex Alisson Bandeira Santos

Computational Modeling and Industrial Technology, SENAI CIMATEC University Center, Salvador 41650-010, Brazil

DOI: 10.53660/CLM-1539-23H60

Este artigo é de propriedade da CONCILIUM JOURNAL.

Após a realização das prospecção tecnológica, fazendo uso dos conhecimentos adquiridos, foi iniciado o estudo exploratório dos dados que o P4.3 conseguiu coletar: os relatórios de O&M da Goldwind e os dados de monitoramento do SCADA do aerogerador 18, separado para integrar a planta híbrida. Analisando esses dados, foi realizada uma seleção dos períodos desejados, além de, um pré-processamento para organizar o dataset. Ferramentas de IA foram utilizadas para clusterizar e classificar os dados do dataset, e, os resultados encontrados estão relatados no artigo apresentado nesse capítulo, além de alguns complementares que encontram-se no Apêndice A.

Exploratory analysis of a real wind turbine dataset, using AI tools to cluster and classify data, for condition monitoring and fault detection

Análise exploratória de um conjunto de dados de turbina eólica real, usando ferramentas de IA para agrupar e classificar dados, para monitoramento de condições e detecção de falhas

Received: 2023-05-20 | Accepted: 2023-06-23 | Published: 2023-06-30

Natasha Benjamim Barbosa

ORCID: <https://orcid.org/0009-0006-3338-6730>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: natasha.barbosa@aln.senaicimatec.edu.br

Rogério Adriano da Fonseca Santiago

ORCID: <https://orcid.org/0009-0006-1005-6843>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: rogerio.santiago@aln.senaicimatec.edu.br

Ricardo Cerqueira Medrado

ORCID: <https://orcid.org/0009-0009-3181-502X>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: ricardo.medrado@fieb.org.br

Tassio Farias de Carvalho

ORCID: <https://orcid.org/0000-0003-4493-1897>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: tassio.carvalho@fieb.org.br

Oberdan Rocha Pinheiro

ORCID: <https://orcid.org/0000-0002-8904-520X>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: oberdan.pinheiro@fieb.org.br

Erick Giovani Sperandio Nascimento

ORCID: <https://orcid.org/0000-0003-2219-0290>
Centro Universitário SENAI CIMATEC, Brasil
University of Surrey, Inglaterra
E-mail: erick.sperandio@fieb.org.br, erick.sperandio@surrey.ac.uk

Bruna Aparecida Souza Machado

ORCID: <https://orcid.org/0000-0003-1655-0325>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: brunam@fieb.org.br

Alex Alisson Bandeira Santos

ORCID: <https://orcid.org/0000-0001-9935-4084>
Centro Universitário SENAI CIMATEC, Brasil
E-mail: alex.santos@fieb.org.br

ABSTRACT

In recent years there has been an increase in wind generation, driven by environmental factors and the incentive offered for the development of clean and sustainable technologies for energy generation. However, due to the rapid growth of this technology, concerns about the safety and reliability of wind turbines are increasing, especially due to the associated risks and financial costs. Therefore, health monitoring and fault detection for wind turbines has become an important research focus. Thus, the

objective of this work was to realize an exploratory study of real data from a wind turbine, using AI tools that help to group the different behaviors, according to the similarity of resources and characteristics of the data. For this, unsupervised learning methods were used to cluster the data and a model was proposed to train and test, using a multilayer perceptron network, to classify these clusters. The differential of this work is the use of real data from CHESF's wind turbines. Another important contribution is in relation to permanent magnet wind turbines, as there are not many studies in this field, therefore a great potential to be explored.

Keywords: Wind turbine; Maintenance; Fault detection; Cluster; Multilayer perceptron.

RESUMO

Nos últimos anos houve um aumento da geração eólica, impulsionado por fatores ambientais e pelo incentivo oferecido para o desenvolvimento de tecnologias limpas e sustentáveis para geração de energia. No entanto, devido ao rápido crescimento desta tecnologia, as preocupações com a segurança e confiabilidade das turbinas eólicas são cada vez maiores, especialmente devido aos riscos associados e aos custos financeiros. Portanto, o monitoramento da integridade e detecção de falhas para turbinas eólicas tornou-se um importante foco de pesquisa. Assim, o objetivo deste trabalho foi realizar um estudo exploratório de dados reais de uma turbina eólica, utilizando ferramentas de IA que ajudem a agrupar os diferentes comportamentos, de acordo com a similaridade de recursos e características dos dados. Para isso, métodos de aprendizado não supervisionado foram usados para agrupar os dados e um modelo foi proposto para treinar e testar, usando uma rede perceptron multicamadas, para classificar esses agrupamentos. O diferencial deste trabalho é a utilização de dados reais dos aerogeradores da CHESF. Outra contribuição importante é em relação aos aerogeradores de ímã permanente, pois não há muitos estudos nessa área, portanto um grande potencial a ser explorado.

Palavras-chave: Turbina eólica; Manutenção; Detecção de falha; Agrupamento; Perceptron multicamadas.

INTRODUCTION

The energy consumption global has increased exponentially and significant efforts have been made by most developing countries to attenuate the impacts of climate change by maximizing clean energy use that to minimize greenhouse gas emissions (BASHIR; BASHIR, 2022).

The Intergovernmental Panel on Climate Change (IPCC) commented on the future risks emanating from climate change, stating:

Continued emission of greenhouse gases will cause further warming and long-lasting changes in all components of the climate system, increasing the likelihood of severe, pervasive, and irreversible impacts for people and ecosystems. Limiting climate change would require substantial and sustained reductions in greenhouse gas emissions which, together with adaptation, can limit climate change risks (PACHAURI; MEYER, 2014).

Wind energy is a virtually carbon-free and pollution-free electricity source, with global wind resources greatly exceeding electricity demand. Accordingly, the installed capacity of wind turbines (WTs) grew at an annualized rate of bigger than 20% from 2000 to 2019 and is projected to increase by a further 50% by the end of 2023 (PRYOR; BARTHELMIE R.J.AND BUKOVSKY; OTHERS., 2020).

Due to these external variances, WTs undergo constantly changing dynamics and local loads, resulting in a large variation in operating conditions that lead to intense mechanical stress (WANG et al., 2022). Many of the already installed WTs are aging, driving the growing maintenance and repair market, along with the demand for the development of new maintenance and repair technologies. As the demand for wind power continues to grow at exponential rates, maintenance will be a permanent factor related to costs, and it can directly influence energy prices and the competitiveness of renewable energy (MISHNAEVSKY; THOMSEN, 2020). Maintenance (O&M) activities are a critical aspect of reliability. As a matter of fact, the global O&M market is projected to grow to USD 27.4 billion by the year 2025. Maintenance is one of the leading costs in the total expenditure of a wind farm project and, if not effective, can cause drastic losses in energy production due to downtime (ARTIGAO et al., 2018).

Considering this context, it is important to detect failures before they occur to avoid greater financial losses. Therefore, knowing the standard behavior of a WT and being able to classify health conditions, so that the O&M can act at the right time, justify studies like this one.

In this work, an initial exploratory study was realized using real WT data, from a CHESF wind farm, selecting a period that, due to a previous mapping of the O&M reports, contained failures. The objective was to analyze data and identify behavior patterns that can be classified as: normal operation, failure and pre-failure. This application is only possible due to the existence

of failure labeling in the equipment data, but on the other hand, the pre-failure condition does not present labeling, justifying the use of unsupervised learning methods to highlight these possible patterns.

Using AI tools, a model was built to analyze a dataset of a real WT, separate these data into clusters, using non-supervised models and classify them into different behavior patterns using multilayer perceptron (MLP), for later application.

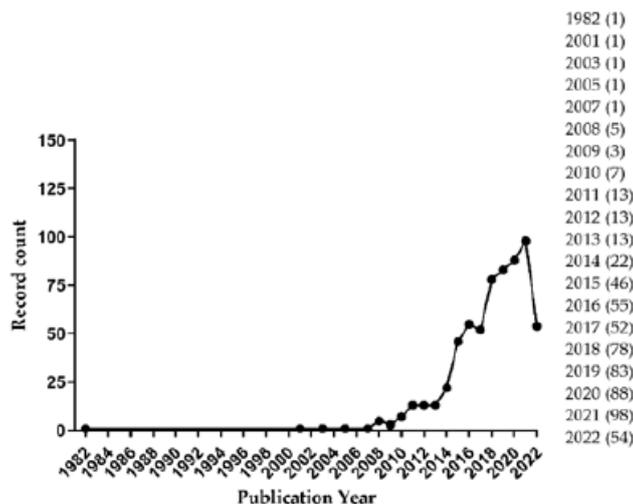
The results obtained in the training and testing phase were above 98%, which was already an excellent result. It is important to expand the application of the model using other datasets and deepen the studies of the behavior of the WTs, to confirm that the patterns found, really can be classified as the possible states of health of the WTs.

RELATED WORK AND CONTRIBUTIONS

As already mentioned, environmental concerns, global warming and other factors have awakened governments, large companies and the academic community to the benefits of wind generation. Therefore, they are investing a lot of money to develop new technologies in this area and the number of studies, documents and patents related to wind turbines has only grown.

In August 2022, a patent search was conducted to evaluate the technology of interest, systems, methods and devices for wind turbines. Figure 1 details the annual distribution of patent applications regarding the described technology; the first applications were found in 1982. The number of patent document applications showed growth over the analyzed period, indicating a continued strong interest in the development of new technologies for wind energy (BARBOSA et al., 2023).

Figure 1 – Time analysis of patent documents. First year of priority.



Source: Elaborated by the authors (2023)

Reder, Yürüşen e Melero. (2018) used a fault dataset of modern wind turbines and applied supervised and unsupervised data mining techniques to obtain logical interconnections between faults and environmental data.

Turnbull et al. (2019) built a dataset of bearing failures based on wind turbine real data resulting from crossing between failures identified in O&M reports and SCADA data, then they trained machine learning algorithms to classify bearings as healthy or not.

ZHAO et al. (2019) presented a model, based on SSI - Stochastic Subspace Identification and MSVM - Multi-kernel Support Vector Machine, to diagnose faults in wind turbine bearings.

Hsu et al. (2020) used statistical control and machine learning techniques to diagnose failures in wind turbines and determine maintenance needs, based on the analysis of real data collected from 2015 to 2017 in Taiwan and data provided by Taipower professionals, about possible causes of failures.

El-Menshawy, Gul e El-Thalji (2021) analyzed a two-year dataset of a SCADA wind turbine, using machine learning algorithms such as: boosted decision tree, decision forest and K-means cluster, in Azure ML Learning Studio.

Xiao, Zhang e Zhang (2021) propose models of neural networks with deep learning for fault detection in wind turbine converters.

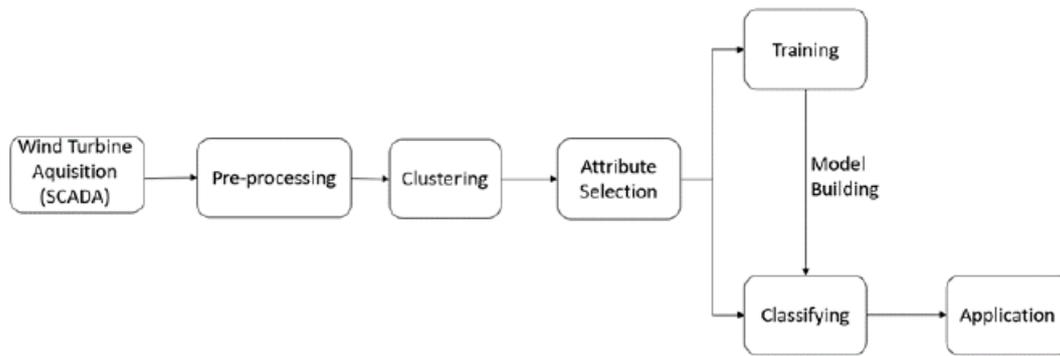
This work is interesting because it uses real data from a permanent magnet wind turbine from the Casa Nova A wind farm. There are not many studies on permanent magnet wind turbines. In addition, the results of this work will be used for various applications, such as modeling condition monitoring systems and helping the maintenance of CHESF's wind farms.

MATERIALS AND METHODS

This study was based on real operational data from Wind Generator 18, with permanent magnet, located at state of Bahia, Brazil, in the Casa Nova A windfarm (Latitude: 09° 09' 43" S / Longitude: 40° 58' 15" W), and made use of data processing, exploration, and interpretation approaches, as well as the application of machine learning techniques, for grouping, selection of attributes and classification.

The proposed computational model was constructed from seven essential steps: acquisition of data from the wind turbine using SCADA, the pre-processing step, which will be described in the next topic, the clustering of the database, then a selection of attributes, followed by training, and classification, whose results will be applied for fault detection. Figure 2 demonstrates this flow of steps for modeling.

Figure 2 – Computer modeling procedure.

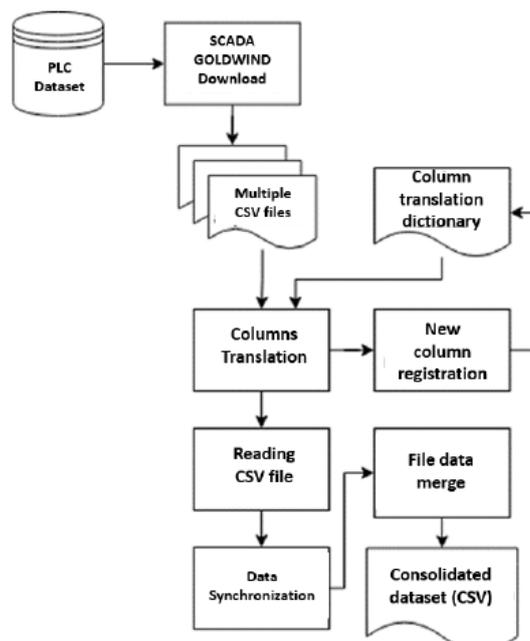


Source: Elaborated by the authors (2023)

Dataset

The dataset used was generated from wind turbine 18 of the Casa Nova A windfarm, obtained from the SCADA – Supervisory Control and Data Acquisition, provided by CHESF. This database was the result of a fragment of almost four months, measurements every ten minutes of a period chosen precisely because it contains some failure. This information was previously mapped in the maintenance reports provided by Goldwind, the company responsible for the maintenance of this wind turbine. This data needed to be pre-processed, Figure 3 resumes this data pre-processing. The files obtained from SCADA are in multiple CSV files that need to be unified, for this a translation of the data that are in Chinese is carried out, in addition to synchronization and use of metrics such as: average, mode and median, to add and remove duplicate values.

Figure 3 – Data pre-processing.



Source: Elaborated by the authors (2023)

The result is a single CSV file, but to be able to apply the AI techniques, it needs to be further refined. Starting from 423 attributes, a deeper analysis of the existing data was necessary to work only with the most relevant ones. In the end, 106 attributes remained: 91 of average values, 4 booleans, 1 indication of time, another of failure and 9 percent attributes.

Clustering

Clustering, in the data mining aspect, is considered an active method of grouping data into many collections or clusters according to similarity of data features and characteristics (EZUGWU et al., 2022).

Unsupervised learning corresponds to statistical methods that extract meaning from data without training a model on labeled data. This model also builds a data model but does not distinguish between response and predictor variables. This model can be used to create a predictive rule in the absence of a labeled response, so this model can be seen as an extension of exploratory data analysis. Unsupervised techniques will allow examining and analyzing variables and discovering existing relationships (GÉRON, 2019).

Expectation-maximization EM algorithm is an iterative method which alternates between two steps, expectation (E) and maximization (M). For clustering, EM makes use of the finite Gaussian mixtures model and estimates a set of parameters iteratively until a desired convergence value is achieved. This method only infers about dataset, pointing out the groupings, according to the similarities founds (DEMPSTER; LAIRD; RUBIN, 1977).

K-means is a popular algorithm was developed and perfected by researchers Lloyd (1957) and MacQueen (1967), its concept is easy to understand and can be used in grouping themes, identification of patterns or anomalies (LLOYD, 1957; MACQUEEN, 1967). The goal of k-means is to obtain a partition that minimizes the squared error between the mean of a cluster and the observations within that cluster. Different from EM in the k-means is necessary to previously define the desired number of clusters. Next steps:

- Random initialization of k-centroids based on the number of previously selected clusters.
- Calculation of the distance between the observed data and definition of the cluster based on the smallest relative distances.
- Calculation of new centroids for each cluster generated in the previous step.
- Repetition the last two steps until convergence, that is, there no change in the positioning of the centroids.

The biggest computation cost is in the step where are calculated the distances between the k-centroids and all N points observed, resulting in an amount of processing $N \times k$. For the calculation of the distances, the k-means method usually uses these functions: Euclidean Distance or Manhattan Distance.

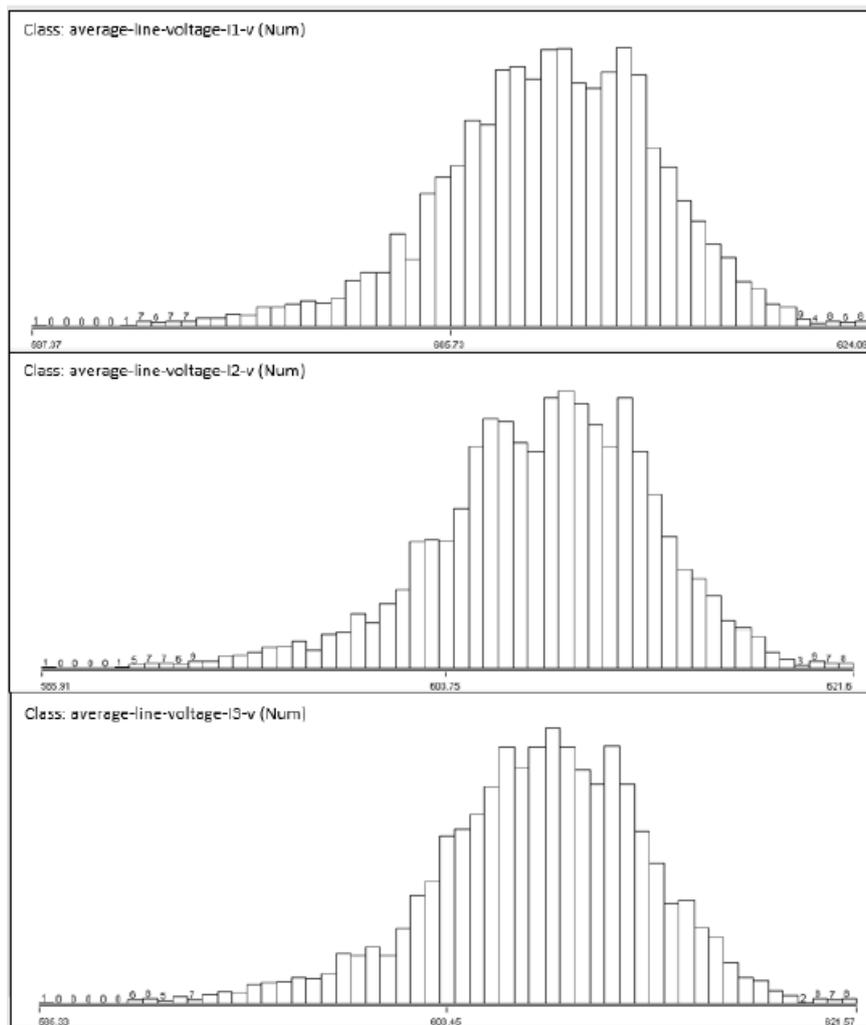
Selecting Attributes

In this study, two ways were used to select the main attributes, using select attributes tools and the exploratory analysis, performing visual comparisons and previous maintenance knowledge.

The Weka machine learning software has attribute selection tools, which choose the main attributes by evaluating the value of a subset of attributes considering the individual predictive capacity of each resource along with the degree of redundancy between them (FRANK et al., 2016).

An exploratory analysis of the attributes was realized, looking for correlations between them, in addition to maintenance knowledges. For example, the Figure 4 shows very similar attributes, then is possible choose only one.

Figure 4 – Similar Attributes.



Source: Elaborated by the authors (2023)

Classify

It was decided to use a multilayer perceptron network to build the pattern classification and recognition model.

The classification process of grouped data using Multi-Layer Perceptron (MLP) is subdivided into two steps: training (learning phase) and data classification (test). The complete dataset, with the labels, is divided into two parts, one for the training step and the other for the classification step. In the training step, the classification model is built from the labeled data. Then, the classification step is executed, which analyzes the dataset extracting the labels, to try to associate each element with the class label that it belongs to. Since each element's class label is provided to the classifier, this step is known as supervised learning.

RESULTS AND DISCUSSIONS

Table 1 presents the results of clustering the complete dataset, with 106 attributes and 16.414 instances, using EM and k-means, choosing: Euclidean Distance and Manhattan Distance. The processing time of EM was much longer than k-means times, but in EM, it is not necessary, to previously define the number of clusters.

Table 1 – Clusters results and time take to build models.

	EM		K-means (EuclideanDistance)		K-means (ManhattanDistance)	
	Clustered Instances		Clustered Instances		Clustered Instances	
0	4.521	28%	1.128	7%	1.496	9%
1	1.809	11%	13.300	81%	12.943	79%
2	10.084	61%	1.986	12%	1.975	12%
Time:	274.93 seconds		0.17 seconds		0.69 seconds	

Source: Elaborated by the authors (2023)

Starting from the exploratory analysis and with the objective of removing similar attributes, it was possible to verify an interesting result with the reduction of 106 attributes to 72, the Table 2 shows the results of clustering with 72 attributes and 16.414 instances, using EM and k-means, choosing: Euclidean Distance and Manhattan Distance.

Table 2 – Clusters results and time take to build models.

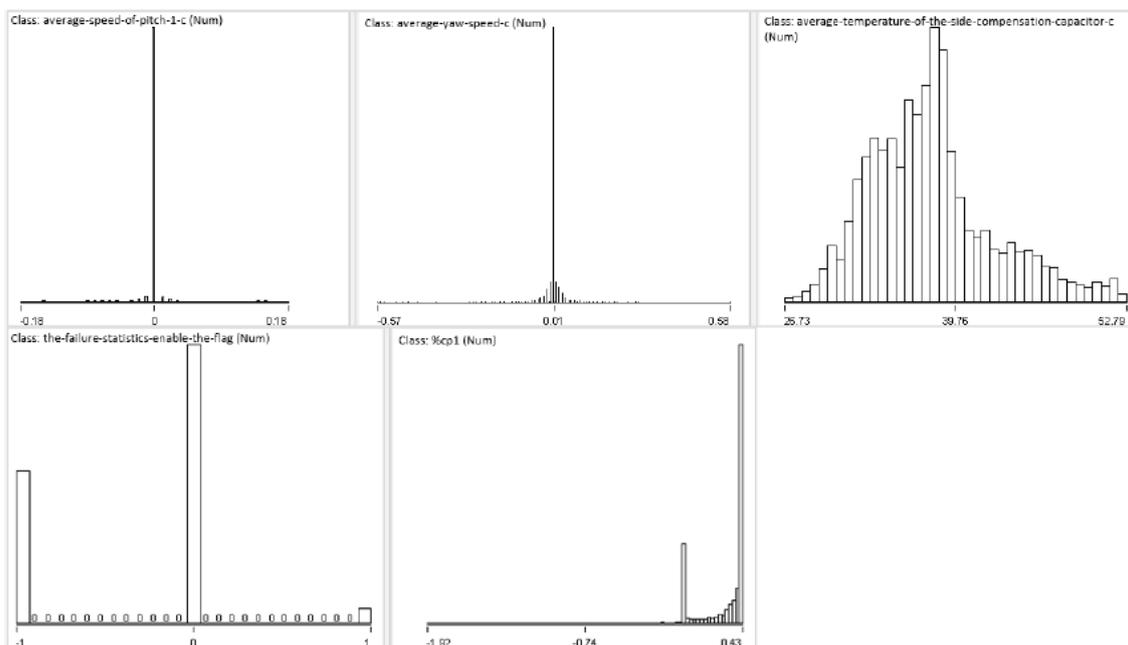
	EM		K-means (EuclideanDistance)		K-means (ManhattanDistance)	
	Clustered Instances		Clustered Instances		Clustered Instances	
0	1.928	12%	1.116	7%	1.136	7%
1	11.406	69%	13.299	81%	13.277	81%
2	3.080	19%	1.999	12%	2.001	12%
Time:	102.85 seconds		0.16 seconds		0.30 seconds	

Source: Elaborated by the authors (2023)

Removing some similar attributes, much better results were achieved in clustering, shorter times and much closer results comparing EM with k-means.

Figure 5 shows the selected attributes from the complete dataset, with 106 attributes and from the dataset with 72 attributes, after exploratory analysis. Both selections were performed using the system's selection tools, the difference was the input dataset, but the result is the same.

Figure 5 – Attribute selection.



Source: Elaborated by the authors (2023)

Using MLP for classification, it started with the complete dataset with 108 input attributes (108 for being the post-grouping dataset), then the dataset with 74 was used, but it was not successful. So, based on the selections of the main attributes, the attributes were removed until this case:

Table 3 – Attributes selected to MLP classify.

Attributes Selected
Instance_number
average-speed-of-pitch-1-c
average-yaw-speed-c
instantaneous-value-of-average-speed-of-generator-rpm
min-inclination-angle-c
average-temperature-of-the-side-compensation-capacitor-c
enable-power-curve-generation-flag
the-failure-statistics-enable-the-flag
%cp1
Cluster

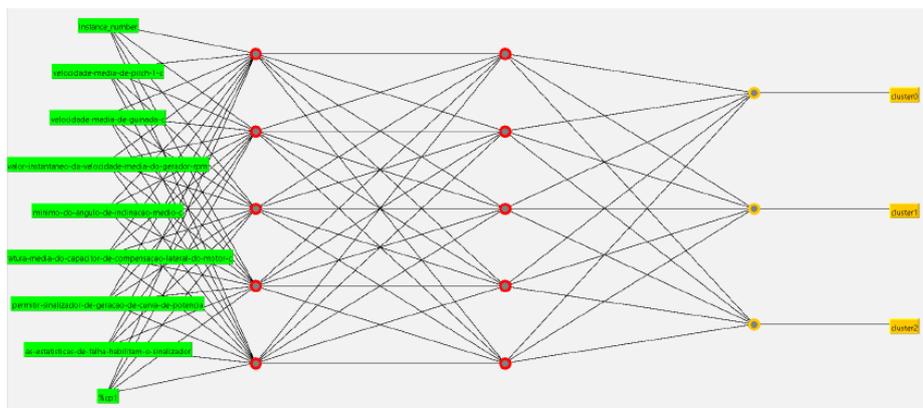
Source: Elaborated by the authors (2023)

The selection used to perform the classification using MLP was with 10 input attributes, shown in Table 3. Hall et al. (2009) defines the number of hidden layers, using this formula:

$$N_{hidden} = \sqrt{N_{in} \times N_{out}}$$

The MLP architecture obtained was this: 10 input attributes and 3 outputs, therefore the indicated number of hidden layers is root 30, which is approximately five. Therefore, two inner layers of five neurons each were chosen. The Table 4 contains the list of the network hyperparameters used as input to the simulator and Figure 6 shows the MLP architecture.

Figure 6 – MLP architecture.



Source: Elaborated by the authors (2023)

Table 4 – Network Hyperparameters.

Hyperparameter	Value
Number of layers	4
Number of hidden layers	2
Number of hidden units (for each hidden layer)	5/5
Batch size	100
Epochs	500
Activation function	Sigmoid
Learning rate	0.3
Momentum	0.2

Source: Elaborated by the authors (2023)

For ME clustering, with 16.414 instances selected to compound the training dataset, the model could classify 16.091 instances correctly, achieving an accuracy of approximately 98,0322%. The confusion matrix is shown in Figure 7. This figure also shows the confusion matrix to k-means clustering, using EuclideanDistance and the same 10 attributes. This model accuracy was approximately 99,9147% and presents the confusion matrix to k-means clustering, using ManhattanDistance, the same 10 attributes and the model accuracy was approximately 99,9086%.

Figure 7 – Confusion Matrix.

Confusion Matrix - ME Clustering				
a	b	c	<--	classified as
1928	0	0		a = cluster0
0	11265	141		b = cluster1
4	178	2898		c = cluster2
Confusion Matrix - K-means Clustering (EuclideanDistance)				
a	b	c	<--	classified as
1112	3	1		a = cluster0
1	13292	6		b = cluster1
1	2	1996		c = cluster2
Confusion Matrix - K-means Clustering (ManhattanDistance)				
a	b	c	<--	classified as
1133	3	0		a = cluster0
6	13267	4		b = cluster1
2	0	1999		c = cluster2

Source: Elaborated by the authors (2023)

CONCLUSION

The current environmental condition requires urgent changes, so the development of new technologies in clean sources of energy generation is essential. In addition, remote monitoring of wind turbines is very important, as this equipment is usually installed in isolated and difficult to access places.

In this context, this study focused on the analysis of data from a wind turbine and on the treatment of these data applying AI tools.

Interesting results were found analyzing SCADA data with clustering tools. It was verified that k-means processing time is better than EM, but it is necessary to define the desired number of clusters.

From the result obtained by the EM, 3 clusters were found, which indicate possible behaviors of: normal operation, pre-failure and failure, however further analysis will be necessary, using more data and a previous mapping to guarantee more conclusive results.

The exploratory analysis of the attributes and the selection using tools, demonstrate that there is a lot of redundancy in the input dataset, so it is important to invest some time to analyze the data and selecting main attributes to save on processing time.

The model built for training and recognition of the clusters obtained an excellent result, with an accuracy above 98%. It is important to extend the analyzes using new input data to be sure of the effectiveness of the model.

As already mentioned, this work is introductory and will contribute to the development of a condition monitoring system, fault detection and recommendations for the maintenance team of CHESF's wind farms.

REFERENCES

- Artigao, E., Martín-Martínez, S., Honrubia-Escribano, A., & Gómez-Lázaro, E. (2018). **Wind turbine reliability: A comprehensive review towards effective condition monitoring development.** *Applied Energy*, 228, 1569–1583. doi:10.1016/j.apenergy.2018.07.037.
- Barbosa, N. B., Nunes, D. D. G., Santos, A. A. B., & Machado, B. A. S. (2023). **Technological Advances on Fault Diagnosis in Wind Turbines: A Patent Analysis.** *Appl. Sci.*, 13, 1721. doi:10.3390/app13031721.
- Bashir, M., & Bashir, A. (2022). **Principle Parameters and Environmental Impacts that Affect the Performance of Wind Turbine: An Overview.** *Arab. J. Sci. Eng.*, 47, 7891–7909. doi:10.1007/s13369-021-06357-1.
- Dempster, A. P., Laird, N. M., & Rubin, D. B. (1977). **Maximum Likelihood from Incomplete Data Via the EM Algorithm.** *Journal of the Royal Statistical Society: Series B (Methodological)*, 39 (1), 1–22. doi:10.1111/j.2517-6161.1977.tb01600.x.
- El-Menshawy, A., Gul, Z., & El-Thalji, I. (2021). **Azure machine learning studio and SCADA data for failure detection and prediction purposes: A case of wind turbine generator.** *IOP Conf. Ser.: Mater. Sci. Eng.*, 1201, 012086. doi:10.1088/1757-899X/1201/1/012086.
- Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A. (2022). **A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects.** *Engineering Applications of Artificial Intelligence*, 110, 104743. doi:10.1016/j.engappai.2022.104743.
- Frank, E., & Others. (2016). **The WEKA Workbench.** Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques. Fourth Edition: Morgan Kaufmann.
- Géron, A. (2019). **Hands-on Machine Learning with Scikit-Learn, Keras and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems.** 2nd ed.: CA 95472: O'Reilly.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). **The WEKA data mining software: an update.** *ACM SIGKDD Explorations Newsletter*, 11 (1), 10--18. doi:10.1145/1656274.1656278.
- Hsu, J.-Y., Wang, Y.-F., Lin, K.-C., Chen, M.-Y., & Hsu, J. H.-Y. (2020). **Wind Turbine Fault Diagnosis and Predictive Maintenance Through Statistical Process Control and Machine Learning.** *IEEE Access*, 8, 23427–23439. doi:10.1109/ACCESS.2020.2968615.
- Lloyd, S. P. (1957). **Least squares quantization in PCM.** *IEEE Transactions on Information Theory*. *IEEE Transactions on Information Theory*, 28 (2), 129--137. doi:10.1109/TIT.1982.1056489.

- MacQUEEN, J. B. (1967). **Some Methods for classification and Analysis of Multivariate Observations**. Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability. 1. University of California Press, 281--297.
- Mishnaevsky, L., & Thomsen, K. (2020). **Costs of repair of wind turbine blades: Influence of technology aspects**. *Wind Energy*, 23, 2247--2255. doi:10.1002/WE.2552.
- Pachauri, R. K., & Meyer, L. A. (2014). **Climate Change 2014: Synthesis Report**. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. IPCC: Geneva, Switzerland.
- Pryor, S. C., Barthelmie, M. S., R. J. and Bukovsky, & others. (2020). **Climate change impacts on wind power generation**. *Nat Rev Earth Environ* 1, 627–643. doi:10.1038/s43017-020-0101-7.
- Reder, M., Yürüşen, N. Y., & Melero., J. J. (2018). **Data-driven learning framework for associating weather conditions and wind turbine failures**. *Reliability Engineering & System Safety*, 169, 554–569. doi:10.1016/j.ress.2017.10.004.
- Turnbull, A., Carroll, J., McDonald, A., & Koukoura, S. (2019). **Prediction of wind turbine generator failure using two-stage cluster-classification methodology**. *Wind Energy*, 1–10. doi:10.1002/we.2391.
- Wang, W., Xue, Y., He, C., & Zhao, Y. (2022). **Review of the Typical Damage and Damage-Detection Methods of Large Wind Turbine Blades**. *Energies*, 15, 5672.
- Xiao, C., Liu, T., Z. adn Zhang, & Zhang, X. (2021). **Deep Learning Method for Fault Detection of Wind Turbine Converter**. *Appl. Sci.*, 11, 1280. doi:10.3390/app11031280.
- Zhao, H., Gao, Y., Liu, H., & Others. (2019). **Fault diagnosis of wind turbine bearing based on stochastic subspace identification and multi-kernel support vector machine**. *J. Mod. Power Syst. Clean Energy*, 7, 350--356. doi:10.1007/s40565-018-0402-8.

Conclusões

A condição ambiental atual exige mudanças urgentes, por isso, o desenvolvimento de novas tecnologias em fontes limpas de geração é tão importante. A energia eólica é uma energia renovável, amplamente utilizada em todo o mundo, e seus rápidos avanços levantam preocupações, especialmente em relação à segurança e confiabilidade. Além disso, geralmente as turbinas eólicas são instaladas em locais isolados e de difícil acesso, por isso é importante investir em monitoramento remoto. Muitas empresas e governos estão investindo recursos em estudos, pesquisas e desenvolvimentos de novas tecnologias nesse campo, como a pesquisa mais ampla do projeto, que este trabalho está vinculado.

6.1 *Conclusões*

Nesse contexto e com base nos resultados obtidos com a prospecção tecnológica, foi possível observar que o diagnóstico de falhas para turbinas eólicas é muito importante, e o desenvolvimento de novas tecnologias ainda é necessário. Isso, pode ser visto, levando em conta a crescente evolução dos depósitos de patentes ao longo dos anos. Além disso, pode-se observar que dos 636 documentos de patentes encontrados, a maioria relatou o desenvolvimento de novos métodos ou novos dispositivos, para identificar possíveis falhas e defeitos em turbinas eólicas e seus componentes.

A prospecção tecnológica, focada em documentos de patentes, tem evidenciado a importância do crescimento no desenvolvimento de: invenções, novos métodos e técnicas utilizadas para a detecção precisa de falhas em turbinas eólicas através de métodos não-destrutivos. A pesquisa apontou os principais aplicadores das tecnologias, bem como os principais inventores, destacando Vestas Wind SYS As e Wang, Rui-ming, respectivamente. Em evidência, o líder mundial no mercado de energia eólica é a China, que possui um total de 373 documentos de patentes e também é o principal mercado para essas aplicações. Os resultados encontrados neste estudo deixa claro que: inteligência artificial e análise de banco de dados, são estratégias futuras para aprimorar métodos já utilizados, especialmente tendo em vista, as peculiaridades envolvidas na manutenção e viabilidade de turbinas eólicas.

Esta pesquisa pode apresentar algumas limitações, que podem ser semelhantes a qualquer outra prospecção tecnológica, por meio da análise de patentes. As limitações podem estar relacionadas à estratégia de busca, que limitou o acesso aos documentos relacionados às palavras-chave selecionadas. No entanto, é importante ressaltar, que as palavras-chave

propostas nesta análise permitiu a apresentação e discussão de uma forma coesa e robusta, quanto ao diagnóstico de falhas de turbinas eólicas, expondo, principalmente, os desafios deste setor. Pesquisas contínuas são necessárias para contribuir com o esclarecimento das questões nesta área.

Resultados interessantes também foram encontrados analisando os dados do SCADA com ferramentas de agrupamento. Foi verificado que o processamento k-means é melhor que o EM, entretanto é necessário definir o número desejado de clusters, antes da clusterização dos dados. A partir do resultado obtido pelo EM, foram encontrados 3 clusters, que indicam possíveis comportamentos de: operação normal, pré-falha e falha, porém uma análise mais profunda será necessária, utilizando outros datasets e um mapeamento prévio ainda mais robusto, para garantir melhores resultados.

No Apêndice A, foram apresentados todos os atributos existentes no dataset utilizado, a partir da análise exploratória dos atributos ou da seleção por meio de ferramentas verificou-se, que existe muita redundância, por isso, é importante investir algum tempo nessa análise e seleção dos principais atributos, que resultará em uma economia de tempo de processamento.

O modelo construído para treinamento e reconhecimento dos clusters obteve excelente resultado, com uma acurácia acima de 98%. É importante realizar análises usando novos dados de entrada, para ter certeza da eficácia do modelo.

No Apêndice A, também, é possível, verificar outras métricas de avaliação que complementam a análise da acurácia e da matriz de confusão, já trabalhadas no artigo II. Como foi explicado no capítulo três, uma combinação de métricas, permite uma análise mais profunda, para observar o desempenho dos modelos em vários aspectos diferentes. Na análise desse dataset, a acurácia, junto com a matriz de confusão, já avaliam bem os modelos, mas quando for implementado um sistema que avalie os dados do aerogerador em tempo real, essa análise mais detalhada será relevante.

6.2 Contribuições

Os resultados observados na prospecção, podem contribuir diretamente para possíveis investimentos em pesquisa e desenvolvimento em técnicas de diagnóstico de falhas, identificando potenciais campos saturados e também os que apresentam possíveis tendências tecnológicas. Além disso, ao identificar as principais áreas e países, as empresas podem usar essa pesquisa tecnológica para ajudá-los na tomada de decisões, quando necessário. Eles também podem usar as descobertas para direcionar novas tecnologias possíveis de interesse e concentrar seus esforços no desenvolvimento de suas próprias invenções, ao

mesmo tempo em que identifica lacunas que podem ser convertidas em novas descobertas.

O projeto de P&D da planta híbrida, tem duração de quatro anos e muitos alunos e professores envolvidos, esse trabalho fez parte dos dois anos iniciais do projeto, que terá continuidade com os demais alunos de mestrado da segunda turma e de doutorado. Por isso, apesar de introdutório, o trabalho contribuirá para o desenvolvimento de um sistema de manutenção para o aerogerador da planta híbrida, além de retroalimentar a equipe de manutenção dos parques eólicos da CHESF com dados de monitoramento de condição, detecção de falhas, além de recomendações de quando e como a manutenção deverá atuar.

Outra contribuição importante é em relação às turbinas eólicas de ímã permanente, pois não existem muitos estudos desse tipo de turbina, dessa forma trabalhos como esse podem servir de referência para novos estudos e desenvolvimento para esses equipamentos.

6.3 Atividades Futuras de Pesquisa

O trabalho de prospecção pode apoiar diretamente na identificação das necessidades do mercado, que pode ser alvo de pesquisa e desenvolvimento de novas invenções baseadas na aplicação de diferentes técnicas de diagnóstico de falhas, combinando técnicas tradicionais com modelos matemáticos avançados, como inteligência artificial e aprendizado profundo, especialmente considerando a crescente importância para o desenvolvimento mundial de fontes renováveis e energia sustentável.

O trabalho de clusterização utilizando dados do aerogerador 18 limitou-se à análise de apenas um dataset, de um período específico. Desta forma, são sugeridos os seguintes tópicos para trabalhos futuros:

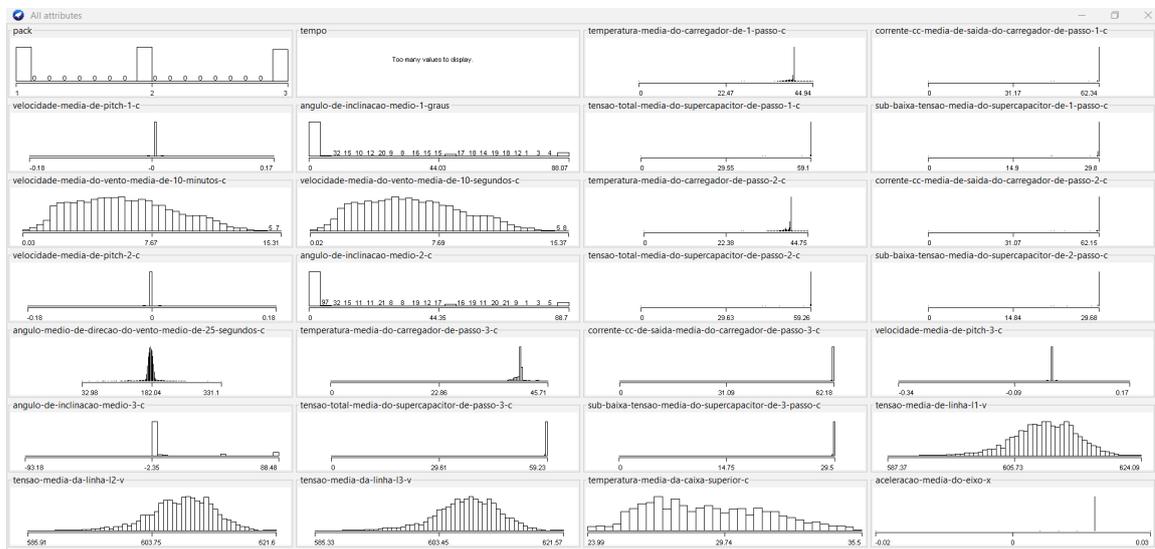
- Ampliar a base de dados analisada, buscar informações de mais equipamentos e outros parques eólicos, talvez de dados open source;
- Utilizar um dataset de falhas já identificadas, para melhorar os resultados do treinamento;
- Testar mais modelos para classificação dos dados;
- Aplicar técnicas de inteligência artificial mais avançadas, como de aprendizagem profunda;
- Estruturar um banco contendo recomendações de manutenção para cada falha diagnosticada.

Documentos

Aqui foram incluídas algumas informações, para complementar os artigos, que são importantes para um melhor entendimento das informações apresentadas neste documento.

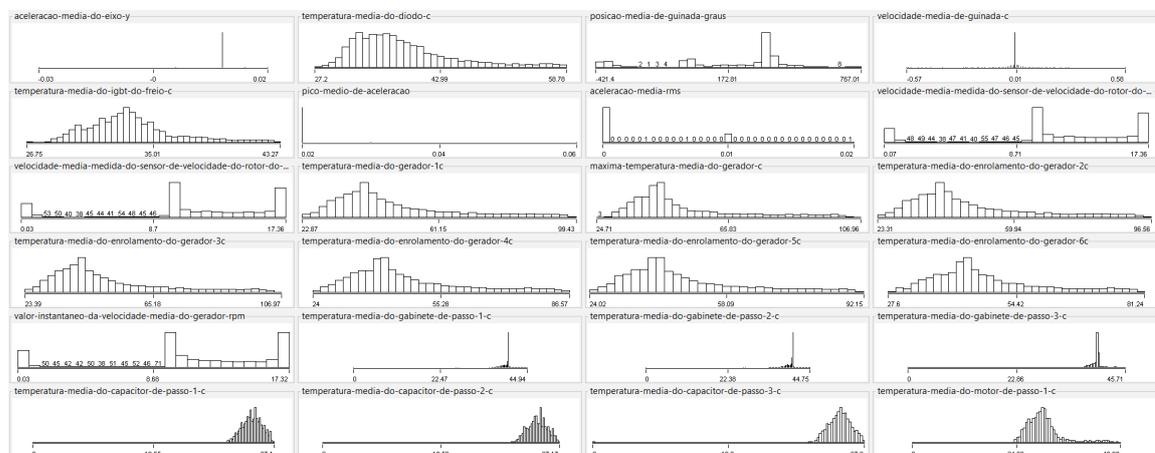
A.1 Atributos

Figura 25: Atributos



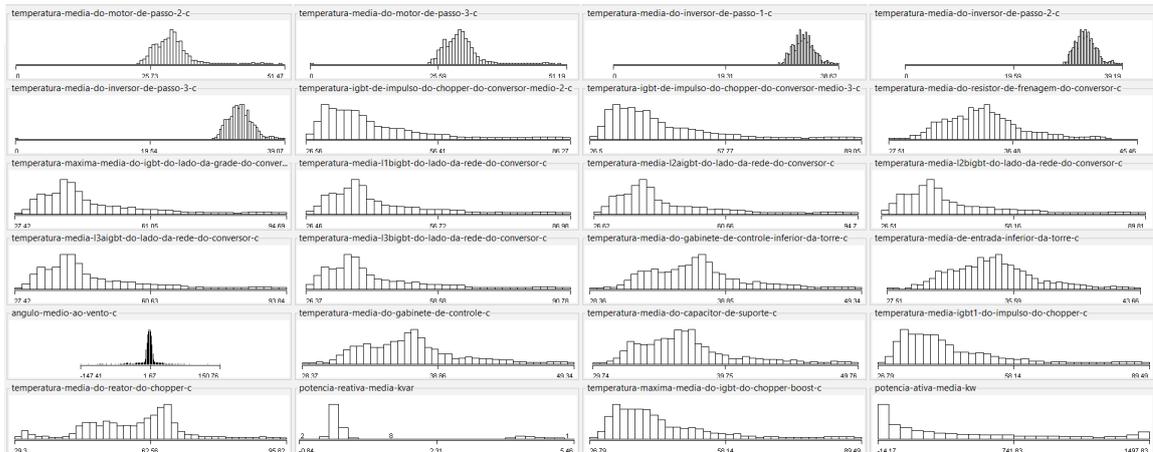
Fonte: Autoria própria.

Figura 26: Atributos



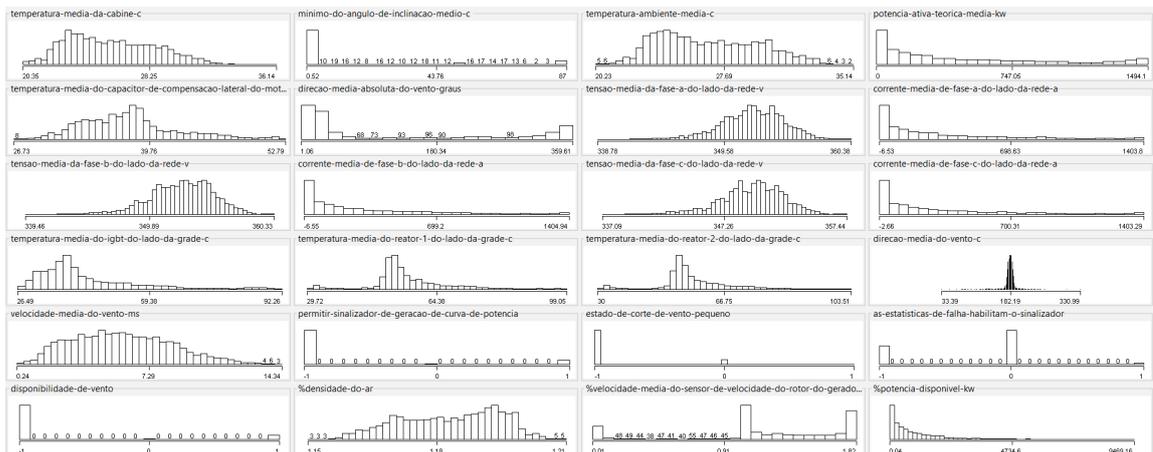
Fonte: Autoria própria.

Figura 27: Atributos



Fonte: Autoria própria.

Figura 28: Atributos



Fonte: Autoria própria.

A.2 Resultados Obtidos

Figura 29: Resultados MLP - clusterização EM

```

Correctly Classified Instances      16091          98.0322 %
Incorrectly Classified Instances    323            1.9678 %
Kappa statistic                    0.9579
Mean absolute error                0.0177
Root mean squared error           0.0965
Relative absolute error            5.6773 %
Root relative squared error       24.4303 %
Total Number of Instances         16414

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                1,000   0,000   0,998     1,000   0,999     0,999   1,000    0,995    cluster0
                0,988   0,036   0,984     0,988   0,986     0,954   0,998    0,999    cluster1
                0,941   0,011   0,954     0,941   0,947     0,935   0,997    0,988    cluster2
Weighted Avg.   0,980   0,027   0,980     0,980   0,980     0,956   0,998    0,996

=== Confusion Matrix ===

  a    b    c  <-- classified as
1928   0    0 |  a = cluster0
  0 11265  141 |  b = cluster1
  4   178 2898 |  c = cluster2
    
```

Fonte: Autoria própria.

Figura 30: Resultados MLP - clusterização K-Means - Distância de Manhattan

```

Correctly Classified Instances      16399          99.9086 %
Incorrectly Classified Instances    15             0.0914 %
Kappa statistic                    0.9972
Mean absolute error                0.0011
Root mean squared error           0.0247
Relative absolute error            0.4944 %
Root relative squared error       7.4813 %
Total Number of Instances         16414

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                0,997   0,001   0,993     0,997   0,995     0,995   1,000    0,999    cluster0
                0,999   0,001   1,000     0,999   1,000     0,997   1,000    1,000    cluster1
                0,999   0,000   0,998     0,999   0,999     0,998   1,000    0,999    cluster2
Weighted Avg.   0,999   0,001   0,999     0,999   0,999     0,997   1,000    1,000

=== Confusion Matrix ===

  a    b    c  <-- classified as
1133   3    0 |  a = cluster0
  6 13267   4 |  b = cluster1
  2    0 1999 |  c = cluster2
    
```

Fonte: Autoria própria.

Figura 31: Resultados MLP - clusterização K-Means - Distância de Euclidean

```

Correctly Classified Instances      16400          99.9147 %
Incorrectly Classified Instances    14             0.0853 %
Kappa statistic                    0.9974
Mean absolute error                0.001
Root mean squared error            0.0221
Relative absolute error             0.4412 %
Root relative squared error        6.7214 %
Total Number of Instances          16414

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
          0,996   0,000   0,998     0,996   0,997     0,997   1,000    0,999    cluster0
          0,999   0,002   1,000     0,999   1,000     0,998   1,000    1,000    cluster1
          0,998   0,000   0,997     0,998   0,998     0,997   1,000    0,999    cluster2
Weighted Avg.  0,999   0,001   0,999     0,999   0,999     0,998   1,000    1,000

=== Confusion Matrix ===

  a    b    c  <-- classified as
1112   3    1 |  a = cluster0
  1 13292   6 |  b = cluster1
  1    2 1996 |  c = cluster2

```

Fonte: Autoria própria.

Referências Bibliográficas

- ABEEÓLICA. 2023. Disponível em: <<https://abeeolica.org.br/>>. Acesso em: 22 de maio 2023. 1, 1
- BOUKHEZZAR, B.; SIGUERDIDJANE, H.; HAND, M. M. Nonlinear control of variable-speed wind turbines for generator torque limiting and power optimization. *J. Solar Energy Eng.*, v. 128, n. 4, p. 516–531, 2006. 2.1
- BP. *BP Statistical Review of World Energy*. 71st ed.: [s.n.], 2022. Disponível em: <<https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2022-full-report.pdf>>. Acesso em: 21 de maio 2023. 1
- CHATTERJEE, J.; DETHLEFS, N. Scientometric review of artificial intelligence for operations maintenance of wind turbines: The past, present and future. *Renewable and Sustainable Energy Reviews*, v. 144, p. 111051, 2021. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032121003403>>. 1
- DEMPSTER, A. P.; LAIRD, N. M.; RUBIN, D. B. Maximum likelihood from incomplete data via the em algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 39 (1), p. 1–22, 1977. 3.4
- DUAN, Y.; HARLEY, R. G. Present and future trends in wind turbine generator designs. *2009 IEEE Power Electronics and Machines in Wind Applications*, p. 1–6, 2009. 2.1
- EL-MENSHAWY, A.; GUL, Z.; EL-THALJI, I. Azure machine learning studio and SCADA data for failure detection and prediction purposes: A case of wind turbine generator. *IOP Conf. Ser.: Mater. Sci. Eng.*, v. 1201, p. 012086, 2021. 2.4
- ELIJORDE, F.; KIM, S.; LEE, J. A wind turbine fault detection approach based on cluster analysis and frequent pattern mining. *KSII TRANSACTIONS ON INTERNET AND INFORMATION SYSTEMS*, v. 8, n. 1, p. 664–677, 2014. 2.1
- EPE. *Nota Técnica: USINAS HÍBRIDAS NO CONTEXTO DO PLANEJAMENTO ENERGÉTICO*, N. EPE-DEE-NT-029/2019-r0. 2019. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/nota-tecnica-usinas-hibridas-no-contexto-do-planejamento-energetico>>. Acesso em: 28 de maio 2023. 1.1
- EZUGWU, A. E. et al. A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. *Engineering Applications of Artificial Intelligence*, v. 110, p. 104743, 2022. 3.4
- FRANK, E. et al. *The WEKA Workbench. Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques*. Fourth Edition: Morgan Kaufmann, 2016. 3.5
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>. 2.3

- GÉRON, A. *Hands-on Machine Learning with Scikit-Learn, Keras and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. 2nd ed.: CA 95472: O'Reilly, 2019. 2.3.1, 3.4
- HSU, J. Y.; WANG, Y. F.; LIN, K. C.; CHEN, M. Y.; HSU, J. H. Y. Wind turbine fault diagnosis and predictive maintenance through statistical process control and machine learning. *IEEE Access*, v. 8, p. 23427–23439, 2020. 2.4
- HUTCHINSON, M.; ZHAO, F. *GWEC - Global Wind Report 2023*. 2023. Disponível em: <<https://gwec.net/>>. Acesso em: 22 de maio 2023. 1, 1, 2.2
- IBAMA. 2023. Disponível em: <<https://www.gov.br/ibama/pt-br/assuntos/laf/consultas/mapas-de-projetos-em-licenciamento-complexos-eolicos-offshore>>. Acesso em: 28 de maio 2023. 1
- IBERDROLA. 2023. Disponível em: <<https://www.iberdrola.com/>>. Acesso em: 04 de julho 2023. 1
- KUSIAK, A.; VERMA, A. A data-mining approach to monitoring wind turbines. *IEEE Transactions on Sustainable Energy*, v. 3, n. 1, p. 150–157, 2012. 2.4
- KUSIAK, A.; ZHANG, Z.; VERMA, A. Prediction, operations, and condition monitoring in wind energy. *Energy*, v. 60, p. 1–12, 2013. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544213006579>>. 2.2
- LEE, J.; ZHAO, F. *GWEC - Global Wind Report 2022*. 2022. Disponível em: <<https://gwec.net/>>. Published: 4 April 2022. 1, 2.3
- LIU, X.; LI, M.; QIN, S.; MA, X.; WANG, W. A predictive fault diagnose method of wind turbine based on k-means clustering and neural networks. *Journal of Internet Technology*, v. 17, n. 7, p. 1521–1528, 2016. 2.4
- LLOYD, S. P. Least squares quantization in pcm. *IEEE Transactions on Information Theory*, v. 28 (2), p. 129–137, 1957. 3.4
- MACQUEEN, J. B. Some methods for classification and analysis of multivariate observations. *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability. 1. University of California Press*, p. 281–297, 1967. 3.4
- MATANATIVA. 2023. Disponível em: <<https://matanativa.com.br/>>. Acesso em: 04 de julho 2023. 1
- MITCHEL, T. M. *Machine Learning*. 1st ed.: McGraw-Hill Science/Engineering/Math, 1997. 2.3
- OLIVEIRA, J. P. J. *Geradores síncronos a imãs permanentes aplicados a aerogeradores: modelagem, obtenção de parâmetros e validação laboratorial*. Dissertação (Mestrado em Engenharia Elétrica,) — Universidade de Brasília, Brasília/DF, 2018. 2.1
- OZTURK, O.; FTHENAKIS, V.; FAULSTICH, S. Failure modes, effects and criticality analysis for wind turbines considering climatic regions and comparing geared and direct drive wind turbines. *Energies*, v. 11, n. 9, 2018. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/11/9/2317>>. 2.2
- PECHT, M. G.; KANG, M. *Prognostics and Health Management of Electronics*. 1st ed.: Wiley, 2018. 2.2

RENEWABLE. *Renewable 2022 Analysis and forecast to 2027*. 2023. Disponível em: <<https://www.iea.org/>>. Acesso em: 22 de maio 2023. 1

TURNBULL, A.; CARROLL, J.; MCDONALD, A.; KOUKOURA, S. Prediction of wind turbine generator failure using two-stage cluster-classification methodology. *Wind Energy*, p. 1–10, 2019. 2.4

ZHANG, Z.; ZHOU, Q.; KUSIAK, A. Optimization of wind power and its variability with a computational intelligence approach. *IEEE Transactions on Sustainable Energy*, v. 5, n. 1, p. 228–236, 2014. 2.4

Estudo preliminar para desenvolvimento de um sistema de manutenção em turbinas eólicas de uma planta híbrida, aplicando técnicas de IA, para clusterizar e classificar dados.

Natasha Benjamim Barbosa

Salvador, Julho de 2023.