

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E
ELETRÔNICA**

Gustavo Grubler de Souza

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA
IDENTIFICAÇÃO DE ANOMALIAS EM GERADORES DE
ENERGIA EÓLICA**

FLORIANÓPOLIS

2023

Gustavo Grubler de Souza

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA
IDENTIFICAÇÃO DE ANOMALIAS EM GERADORES DE ENERGIA
EÓLICA**

Trabalho de Conclusão de Curso do Curso de
Graduação em Engenharia Elétrica do Centro
Tecnológico da Universidade Federal de Santa
Catarina para a obtenção do título de Engenheiro
Eletricista.
Orientador: Prof. Miguel Moreto, Dr.

Florianópolis
2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Souza, Gustavo Grubler de

Aplicação de aprendizado de máquina para identificação de anomalias em geradores de energia eólica / Gustavo Grubler de Souza ; orientador, Prof. Dr. Miguel Moreto, 2023.
69 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Elétrica. 2. Aerogeradores. 3. Vibrações.
4. Aprendizado de Máquina. 5. Detecção de Anomalias. I.
Moreto, Prof. Dr. Miguel. II. Universidade Federal de
Santa Catarina. Graduação em Engenharia Elétrica. III.
Título.

Gustavo Grubler de Souza

**Título: APLICAÇÃO DE APRENDIZADO DE MÁQUINA PARA
IDENTIFICAÇÃO DE ANOMALIAS EM GERADORES DE ENERGIA
EÓLICA**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia Elétrica” e aceito, em sua forma final pelo Curso de Graduação em Engenharia Elétrica.

Florianópolis, 04 de dezembro de 2023.

Prof. Miguel Moreto, Dr.
Coordenador do Curso de Graduação em
Engenharia Elétrica

Banca Examinadora:

Prof. Miguel Moreto, Dr.
Universidade Federal de Santa Catarina
Orientador

Prof. Nelson Jhoe Batistela, Dr.
Universidade Federal de Santa Catarina

Prof. Eduardo Luiz Ortiz Batista, Dr.
Universidade Federal de Santa Catarina

AGRADECIMENTOS

Primeiramente, agradeço a minha família, em especial a meu pai e minha mãe, que sempre fizeram de tudo para que eu conseguisse obter a melhor educação possível, desde o ensino fundamental até o ensino superior. Sem eles, eu não estaria nesta universidade escrevendo este trabalho.

Agradeço à minha namorada, por me ouvir e me apoiar durante todas as dificuldades e conquistas da graduação e deste trabalho.

Agradeço aos meus amigos, pela troca de experiências e pelas conversas, sejam elas acadêmicas ou não.

Agradeço aos meus professores, principalmente o Professor Miguel Moreto, que já fora meu orientador num projeto de iniciação científica e que aceitou novamente me orientar. Suas experiências e conhecimentos foram essenciais no desenvolvimento deste trabalho.

Por fim, agradeço à AQTech Power Prognostics e a todos os colaboradores que me auxiliaram no desenvolvimento deste trabalho. Graças a eles, que sempre estavam a disposição para tirar dúvidas e sugerir melhorias, consegui realizar um excelente trabalho.

*Este trabalho é dedicado à Maria Vanilda de Souza Peretto,
minha madrinha de batismo, minha segunda mãe,
que tanto fez por mim e pela minha família.*

RESUMO

As turbinas eólicas desempenham um papel importante na geração de energia renovável em todo o mundo. Devido à complexidade e à exposição a condições climáticas severas, tais turbinas estão sujeitas a desgastes e falhas, o que podem levar a paradas não planejadas, causando interrupções no fornecimento de energia e prejuízos financeiros. Para evitar estes imprevistos, a manutenção preditiva é essencial, envolvendo a identificação de possíveis anomalias antes que ocorram. Nesse sentido, este trabalho explora a detecção de anomalias como uma estratégia eficaz para identificar comportamentos fora do padrão nos dados vibracionais dos aerogeradores. Portanto, o intuito deste trabalho é aplicar técnicas existentes na literatura para classificar o estado dos componentes do aerogerador, comparando métodos e determinando qual apresenta os melhores resultados. Desta forma, foram aplicadas duas abordagens para extrair as características dos sinais de vibração, as quais foram avaliadas em três casos distintos.

Palavras-chave: Aerogeradores, manutenção, vibrações, aprendizado de máquina, detecção de anomalias.

ABSTRACT

Wind turbines play a significant role in renewable energy generation worldwide. Due to their complexity and exposure to severe weather conditions, these turbines are susceptible to wear and tear and failure, which can lead to unplanned downtime, causing disruptions in power supply and financial losses. To prevent these incidents, predictive maintenance is essential, involving the identification of potential anomalies before they occur. In this regard, this study explores anomaly detection as an effective strategy to identify abnormal behaviors in the vibration data of wind turbines. The purpose of this research is to apply existing techniques from the literature to classify the state of wind turbine components, comparing methods and determining which yields the best results. Thus, two approaches were employed to extract features from vibration signals, which were evaluated in three different scenarios.

Keywords: Wind turbines, maintenance, vibrations, machine learning, anomaly detection.

LISTA DE FIGURAS

Figura 1 – Produção de energia elétrica ao longo do tempo.	25
Figura 2 – Componentes de um aerogerador.	26
Figura 3 – Componentes no interior da nacelle.	27
Figura 4 – Modelo de uma caixa multiplicadora.	27
Figura 5 – Estágios da caixa multiplicadora.	29
Figura 6 – Custos associados aos tipos de manutenção.	30
Figura 7 – Importância da análise de vibrações.	31
Figura 8 – Instrumentação de um rolamento na caixa multiplicadora.	31
Figura 9 – Esquemático de dois tipos de acelerômetros.	33
Figura 10 – Principais causas de faltas nas caixas multiplicadoras.	34
Figura 11 – Frequências características de defeitos.	36
Figura 12 – Parâmetros geométricos de um rolamento.	36
Figura 13 – Sistema de comunicação utilizando SCADA.	37
Figura 14 – Assimetria positiva de um conjunto de dados.	39
Figura 15 – Assimetria negativa de um conjunto de dados.	39
Figura 16 – Sinal no domínio do tempo X domínio da frequência.	41
Figura 17 – Exemplo de uma <i>wavelet</i>	41
Figura 18 – Fluxograma geral do método proposto.	45
Figura 19 – Método proposto aplicando decomposição em três camadas.	48
Figura 20 – Arquitetura do modelo proposto.	49
Figura 21 – Processo de aprendizado do DAE.	50
Figura 22 – Exemplo de uma distribuição normal.	51
Figura 23 – Pontuação das amostras - abordagem I - caso I.	54
Figura 24 – Anomalias detectadas - abordagem I - caso I.	54
Figura 25 – Pontuação de anomalias - abordagem II - caso I.	55
Figura 26 – Anomalias detectadas - abordagem II - caso I.	55
Figura 27 – Comparativo entre as abordagens aplicadas - caso I.	56
Figura 28 – Pontuação das amostras - abordagem I - caso II.	57
Figura 29 – Anomalias detectadas - abordagem I - caso II.	58
Figura 30 – Pontuação das amostras - abordagem II - caso II.	59
Figura 31 – Anomalias detectadas - abordagem II - caso II.	59
Figura 32 – Comparativo entre as abordagens aplicadas - caso II.	60
Figura 33 – Pontuação das amostras - abordagem I - caso III.	61
Figura 34 – Anomalias detectadas - abordagem I - caso III.	61
Figura 35 – Pontuação das amostras - abordagem II - caso III.	62
Figura 36 – Anomalias detectadas - abordagem II - caso III.	62
Figura 37 – Comparativo entre as abordagens aplicadas - caso III.	63

SUMÁRIO

1	INTRODUÇÃO	21
1.1	PROBLEMÁTICA	21
1.2	OBJETIVO	22
1.2.1	Objetivo Geral	22
1.2.2	Objetivos Específicos	22
1.3	ORGANIZAÇÃO	22
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	GERAÇÃO EÓLICA DE ENERGIA	25
2.2	AEROGERADOR	26
2.2.1	Caixa multiplicadora	27
2.3	MANUTENÇÕES EM AEROGERADORES	29
2.3.1	Análise de vibrações em aerogeradores	30
2.3.1.1	Sensores para análise de vibrações	32
2.3.1.2	Análise de vibrações em rolamentos	33
2.4	PROCESSAMENTO DE SINAIS	35
2.4.1	Extração de características	37
2.4.1.1	Domínio do tempo	37
2.4.1.2	Domínio da frequência	39
2.4.2	Modelos de aprendizado de máquina	42
3	DESENVOLVIMENTO	45
3.1	FLUXOGRAMA	45
3.2	EXTRAÇÃO DE CARACTERÍSTICAS	46
3.2.1	Abordagem I	46
3.2.2	Abordagem II	47
3.3	SELEÇÃO DE CARACTERÍSTICAS RELEVANTES	48
3.4	TREINAMENTO E PREVISÃO A PARTIR DO MODELO DE IA	48
4	RESULTADOS OBTIDOS	53
4.1	CASO I	53
4.1.1	Anomalias detectadas	53
4.1.1.1	Abordagem I	53
4.1.1.2	Abordagem II	54
4.1.2	Comparativo com as abordagens aplicadas	55
4.2	CASO II	57
4.2.1	Anomalias detectadas	57
4.2.1.1	Abordagem I	57
4.2.1.2	Abordagem II	58
4.2.2	Comparativo com as abordagens aplicadas	59

4.3	CASO III	60
4.3.1	Anomalias detectadas	61
4.3.1.1	Abordagem I	61
4.3.1.2	Abordagem II	62
4.3.2	Comparativo com as abordagens aplicadas	63
5	CONCLUSÕES	65
5.1	RESULTADOS OBTIDOS	65
5.2	TRABALHOS FUTUROS	65
	REFERÊNCIAS	67

1 INTRODUÇÃO

1.1 PROBLEMÁTICA

O uso de turbinas eólicas é uma das principais formas de geração de energia renovável em todo o mundo. São equipamentos complexos, os quais consistem em diversos componentes e subcomponentes, sendo os principais o gerador, a caixa multiplicadora e o eixo principal. Além disso, estão sujeitas a variações climáticas e ambientes severos constantemente, o que leva a um desgaste maior em seus componentes, ocasionando possíveis falhas. Tais falhas são normalmente difíceis de prever e acontecem de forma inesperada, o que faz com que seja necessário realizar manutenções corretivas, que geralmente possuem um custo elevado (QIAO; LU, 2015).

Essas correções que acontecem quando já ocorreu a falha no equipamento são indesejáveis, pois um aerogerador parado pode trazer diversas consequências para a sociedade, sendo uma delas a falta de energia em uma determinada região, além de prejuízos financeiros para a concessionária. Dessa forma, faz-se necessário o uso da manutenção preditiva, ou seja, identificar uma possível falta antes dela ocorrer, fazendo com que seja possível realizar os ajustes necessários no equipamento e evitando assim a ocorrência de danos mais severos (JIANG *et al.*, 2018).

De acordo com Zhou *et al.* (2022), os diagnósticos de falha são, na maior parte dos casos, uma maneira efetiva de evitar com que a falha ocorra. No entanto, Du *et al.* (2022) enfatiza que a utilização de detectores de anomalias é uma estratégia bastante eficiente para os estágios iniciais das falhas, na qual é possível identificar possíveis anomalias com bastante antecedência, o que é o objeto de estudo deste trabalho.

Conforme os autores Lappas, Argyriou e Makris (2021), a detecção de anomalias é a prática de detectar comportamento fora do padrão nos dados, isto é, que fogem de uma distribuição específica de um comportamento esperado. Desta forma, dado que anomalias são ocasiões raras, mecanismos automatizados capazes de detectar anomalias são de extrema importância, pois têm o potencial de reduzir significativamente o tempo dos operadores humanos e, portanto, minimizar erros e custos (LAPPAS; ARGYRIOU; MAKRIS, 2021). Tais mecanismos automatizados têm sido objetos de estudo de diversos trabalhos científicos, que serão comentados com maiores detalhes nos próximos capítulos.

Na indústria, são comumente utilizados sistemas de monitoramento da condição (*Condition Monitoring Systems - CMS*), que realizam o diagnóstico de falhas e determinam um estado para os componentes do aerogerador, ou seja, a sua condição de operação. De maneira geral, existem 3 tipos de estados, sendo eles normal, atenção e alerta. Esses *status* são definidos conforme alguns limites pré-estabelecidos, ou seja, se o modo de falha possui variáveis que passam de determinados limites, é-lhe atribuído um *status*.

Dessa forma, este trabalho tem o intuito de estudar e aplicar algumas abordagens existentes na literatura no que diz respeito à detecção de anomalias, para classificar o

estado do componente analisado. Pretende-se obter resultados significativos e bastante precisos, para que seja possível comparar os métodos aplicados neste trabalho com outras abordagens, chegando às conclusões de qual método apresentou melhores resultados. A metodologia a ser seguida neste trabalho, assim como as abordagens que serão adotadas, serão explicadas nos próximos capítulos.

1.2 OBJETIVO

1.2.1 Objetivo Geral

O objetivo central deste trabalho consiste em aplicar um sistema de detecção de anomalias em geradores de energia eólica, através da utilização de aprendizado de máquinas, realizando uma classificação a partir de sinais de vibração mecânicos.

1.2.2 Objetivos Específicos

Considerando o desenvolvimento do trabalho e o objetivo geral apresentado, destacam-se os seguintes objetivos específicos:

- Obter os dados de vibração no domínio do tempo dos sinais do aerogerador e passá-lo para o domínio da frequência por meio de técnicas de processamento digital de sinais e lógicas de programação;
- Extrair as características dos sinais de vibração para serem utilizadas como parâmetro de entrada no algoritmo de inteligência artificial;
- Treinar um classificador baseado em inteligência artificial a ser aplicado com sinais de vibração saudáveis do aerogerador;
- Identificar possíveis anomalias através do modelo de inteligência artificial já treinado;
- Comparar o método desenvolvido neste projeto com métodos existentes para classificação do nível de vibração dos sinais do aerogerador.

1.3 ORGANIZAÇÃO

O presente trabalho está organizado da seguinte forma:

Capítulo 2: fundamentação teórica sobre a geração de energia eólica, análise de vibrações em aerogeradores, extração de características de um sinal de vibração e os modelos de aprendizado de máquina que poderão ser utilizados no desenvolvimento do trabalho são apresentados neste capítulo.

Capítulo 3: o desenvolvimento do método proposto, isto é, quais e como as características são extraídas do sinal, quais os modelos de aprendizados de máquina adotados para

implementar o classificador, como o treinamento e a previsão do classificador é realizada e um fluxograma geral do método proposto são apresentados neste capítulo.

Capítulo 4: os resultados do classificador desenvolvido são apresentados neste capítulo. Ainda nesta etapa, a comparação com outras abordagens é aplicada, com o intuito de identificar possíveis anomalias com a maior antecedência possível.


Capítulo 5: as conclusões deste trabalho e sugestões para trabalhos futuros são apresentadas nesta etapa.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 GERAÇÃO EÓLICA DE ENERGIA

A energia eólica tem crescido rapidamente desde os anos 2000, graças aos investimentos em pesquisa e desenvolvimento e políticas de apoio. Segundo os dados de IRENA (2022), a capacidade global de geração de energia eólica instalada - tanto em terra quanto no mar - aumentou em um fator de 98 nas últimas duas décadas, saltando de 7,5 GW em 1997 para cerca de 733 GW até 2018. A Figura 1 abaixo apresenta um gráfico indicando este aumento na produção de energia elétrica através dos ventos no Brasil.

Figura 1 – Produção de energia elétrica ao longo do tempo.




Fonte: (IRENA, 2022).

De uma maneira geral, o vento é utilizado para produzir energia elétrica convertendo a energia cinética do ar, que é um fluido em movimento, em eletricidade. Para que este processo ocorra, é necessária a existência de uma unidade de geração, conhecida também como aerogerador. Este equipamento é composto por pás ao longo de uma torre e é projetado para gerar a maior quantidade possível de energia elétrica.

De acordo com Olabi *et al.* (2021), os aerogeradores possuem mais de 8000 componentes, porém estes podem ser agrupados em três grandes macrocomponentes, que são as pás, nacelle e torre, conforme apresentado na Figura 2. Tais macrocomponentes determinam a funcionalidade dos aerogeradores. A torre é instalada, geralmente, sobre uma fundação de concreto, sustentando assim as pás e a nacelle. Dentro da nacelle, estão

situados o rotor, que irá girar conforme a velocidade do vento, acoplado no eixo principal da turbina. O eixo principal, por sua vez, é acoplado a uma *gearbox*, chamada também de caixa multiplicadora. Por fim, tem-se o gerador, que converterá parte da energia mecânica obtida neste processo em energia elétrica.

Figura 2 – Componentes de um aerogerador.



Fonte: (NĂSTASE, 2017).


2.2 AEROGERADOR

Conforme comentado na seção anterior, o aerogerador é o equipamento responsável por converter a energia cinética do vento em energia elétrica. De acordo com Năstase (2017), os aerogeradores mais modernos são projetados através de um eixo horizontal, como mostra a Figura 2. O *hub* e as pás do aerogerador são construídos com um formato aerodinâmico. Portanto, através da forma com que o vento bate nas pás, o rotor da turbina começa a girar.

O eixo principal, sustentado por um mancal acoplado ao rotor, também começa a girar, fazendo com que a energia mecânica produzida até esta etapa seja transferida para o gerador. No entanto, a velocidade do eixo principal é relativamente baixa, pois sua rotação é conforme a velocidade do vento, sendo insuficiente para a produção de energia elétrica. Desta forma, é necessário utilizar uma caixa multiplicadora entre o eixo principal e o gerador, para fazer com que a velocidade de rotação na entrada do gerador seja maior. Esta caixa multiplicadora também é conhecida como *gearbox*, e pode ser vista,

além de outros componentes como o eixo principal e o gerador, na Figura 3 abaixo. A caixa multiplicadora possui diversos subcomponentes, que serão apresentados com maiores detalhes adiante.

Figura 3 – Componentes no interior da nacelle.




Fonte: (TCHAKOUA *et al.*, 2014).

2.2.1 Caixa multiplicadora

A caixa multiplicadora pode ser representada pelo modelo visto na Figura 4.

Figura 4 – Modelo de uma caixa multiplicadora.



Fonte: (TENG *et al.*, 2014) (adaptado).


Desta forma, podemos dividir este componente em 13 partes, de acordo com a numeração indicada na imagem:

1. **Carcaça:** a carcaça da caixa multiplicadora é responsável por manter todo o conjunto de microcomponentes fixos em suas regiões, além de mantê-los isolados de poeiras e outras impurezas.
2. **Eixo do rotor:** conforme comentado anteriormente, o eixo do rotor está diretamente relacionado com as pás do aerogerador. Sua velocidade é relativamente baixa, pois gira de acordo com a velocidade do vento.
3. **Suporte planetário:** estrutura coaxial responsável por manter as engrenagens anelar, solar e planetárias rotacionando da forma correta.
4. **Engrenagem anelar:** de acordo com K.S. *et al.* (2022) esta engrenagem é a mais externa do arranjo planetário, responsável por envolver as engrenagens solar e planetárias.
5. **Engrenagem planetária:** ainda segundo K.S. *et al.* (2022), as engrenagens planetárias se encontram no interior da engrenagem anelar e giram ao redor da engrenagem solar. Normalmente o arranjo planetário é constituído por três engrenagens planetárias.
6. **Engrenagem solar:** por fim, a engrenagem solar está localizada no centro, encaixada com as engrenagens planetárias que estão conectadas com a engrenagem anelar, onde todo este arranjo está montado com a ajuda do suporte planetário.
7. **Eixo LSS:** de acordo com Feng *et al.* (2013), o eixo de baixa rotação (*Low-speed shaft* - LSS) é constituído pelos três itens comentados anteriormente. Isto é, o LSS é composto por três engrenagens planetárias que giram ao redor de uma engrenagem solar, contidas em uma engrenagem anel sob um suporte planetário. A entrada do eixo de baixa velocidade vem do movimento de acionamento do suporte planetário, que é feito através do movimento das engrenagens planetárias.
8. **Coroa do LSS:** a coroa do LSS, localizada sob o eixo de mesmo nome, é responsável por transferir a rotação obtida do arranjo planetário para a próxima engrenagem.
9. **Pinhão do IMS:** a coroa do LSS transfere a sua rotação para o pinhão do eixo de velocidade intermediária (*Intermediate-speed shaft* - IMS).
10. **Eixo IMS:** através do pinhão do IMS, que é uma engrenagem com menos dentes, o que possibilita uma maior rotação, o eixo IMS entrega uma maior velocidade para as próximas engrenagens.
11. **Coroa do IMS:** a coroa do IMS, localizada sob o eixo de mesmo nome, é responsável por transferir a rotação obtida do estágio de rotação intermediária (IMS) para a próxima engrenagem.

12. **Pinhão do HSS:** a coroa do IMS transfere a sua rotação para o pinhão do eixo de alta velocidade (*High-speed shaft* - HSS).
13. **Eixo HSS:** por fim, tem-se o eixo de alta velocidade (HSS). Neste estágio, a rotação atinge os valores necessários e é então acoplado ao eixo do gerador.

A fim de aumentar a compreensão dos itens descritos acima, a Figura 5 representa uma outra forma de visualizar todos os estágios da caixa multiplicadora.

Figura 5 – Estágios da caixa multiplicadora.



Fonte: (FENG *et al.*, 2013).

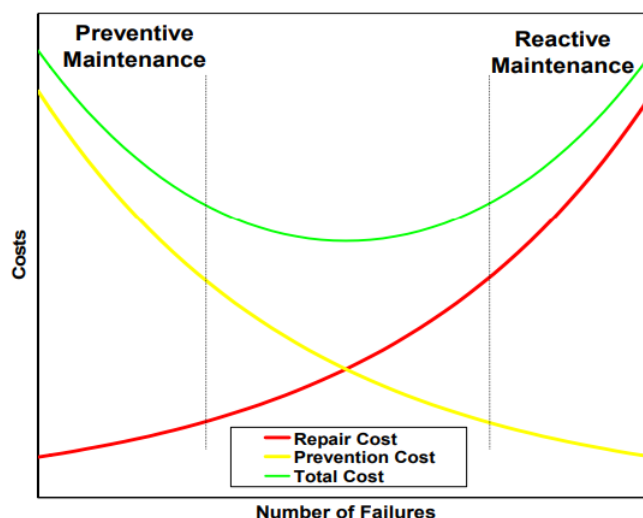
2.3 MANUTENÇÕES EM AEROGERADORES

Conforme a série de componentes e subcomponentes mecânicos apresentados anteriormente, é possível chegar a conclusão de que esses elementos estão sujeitos a faltas ou falhas inesperadas. Desta forma, estes componentes necessitam de manutenções periódicas. No entanto, por se tratar de estruturas de grande porte, os aerogeradores da atualidade estão na maior parte dos casos em regiões bastante remotas. Portanto, a rotina de manutenção destas turbinas se torna difícil e custosa (WU; CHEN, 2018).

A maneira mais simplista de realizar manutenção é quando um equipamento é posto em funcionamento até que uma falha ocorra. Este tipo de manutenção é chamado de manutenção reativa, ou manutenção corretiva, o que resulta em uma baixa confiabilidade e um alto custo devido à impossibilidade de detectar falhas antes de sua ocorrência (ORSAGH *et al.*, 2006). A Figura 6 representa os custos associados a manutenção reativa, em que o custo total de manutenção está diretamente relacionado aos reparos recorrentes da manutenção reativa.

Uma outra forma de realizar manutenção, que também é exposto na Figura 6, é a manutenção preventiva. De acordo com Orsagh *et al.* (2006), a manutenção preventiva pode prolongar a vida útil de um equipamento ao realizar revisões periódicas antes da ocorrência

Figura 6 – Custos associados aos tipos de manutenção.



Fonte: (ORSAGH *et al.*, 2006).

de alguma falha. Nesse sentido, para evitar defeitos inesperados nos equipamentos, a manutenção preventiva deve ser realizada bem antes do tempo médio esperado em que uma falha possa ocorrer. Logo, a manutenção preventiva também possuirá um certo custo, que pode ser visto no lado esquerdo do gráfico da Figura 6. No entanto, este custo está relacionado às manutenções preventivas de rotina, isto é, revisões frequentes nos equipamentos e interrupção da produção para manutenções planejadas.

Ademais, segundo Yang *et al.* (2018), a manutenção preventiva também pode levar a correções desnecessárias, já que é realizada sem analisar a condição real do equipamento, o que também se torna custoso. Para contornar este problema, tem-se a manutenção com base na condição (*Condition-based maintenance* - CBM).


Como o nome sugere, a CBM é realizada de acordo com a saúde da máquina. Quanto mais grave o estado do equipamento, maior a necessidade de realizar manutenção. Para Yang *et al.* (2018), este tipo de manutenção permite detecções de faltas em estágios iniciais, fazendo com que haja tempo hábil para realizar ajustes necessários, evitando assim que o equipamento quebre. Desta forma, os custos operacionais e de manutenção diminuem. No entanto, tal tipo de manutenção envolve outros custos, uma vez que requer o conhecimento de tecnologias específicas, como a análise de vibrações e processamento de sinais.

2.3.1 Análise de vibrações em aerogeradores

A análise de vibrações é a tecnologia mais conhecida no que diz respeito ao monitoramento da condição de máquinas rotativas. Conforme apresentado na Figura 7, a vibração é o primeiro indício de uma possível falta em um equipamento, a qual pode ser

detectada meses antes de sua quebra.


Figura 7 – Importância da análise de vibrações.



Fonte: (TCHAKOUA *et al.*, 2014).

Além disso, Wymore *et al.* (2015) enfatiza que a análise de vibrações é uma técnica fundamental para componentes como eixos de transmissão, rolamentos, caixas multiplicadoras e geradores. Para detectar vibrações nestes componentes, faz-se o uso de sensores acelerômetros, que serão posteriormente apresentados com maiores detalhes. Tais sensores podem ser acoplados em rolamentos, eixos ou carcaças, a fim de se obter as características dinâmicas do sinal de vibração. A Figura 8 apresenta como os sensores são utilizados em um rolamento de uma caixa multiplicadora.

Figura 8 – Instrumentação de um rolamento na caixa multiplicadora.



Fonte: (WYMORE *et al.*, 2015).

Os rolamentos são os principais componentes que estão sujeitos a faltas em um aerogerador. De acordo com Aikin (2023), cerca de 76% das caixas multiplicadoras apresentam anomalias em rolamentos, enquanto que 17% apresentam faltas devido a problemas nas engrenagens. A análise de vibrações em rolamentos também será apresentada mais à frente.

Para identificar que um sinal de vibração está com um comportamento anormal, é necessário utilizar-se de valores de referência para chegar a melhores conclusões. Desta forma, os sistemas de monitoramento da condição geralmente fazem uso da norma ISO 10816-21:2015 (ISO10816-21, 2015), a qual informa quais são os limites aceitáveis de vibração para cada componente do aerogerador. Ademais, a norma também indica a posição que os sensores devem ser instalados para monitorar eixos, engrenagens, rolamentos e outros componentes.

2.3.1.1 Sensores para análise de vibrações


De acordo com Victorino, Jiang e Menon (2018), os acelerômetros são uma classe de sensores que medem a aceleração de objetos em movimento, os quais são capazes de detectar a frequência e a intensidade do elemento monitorado. Os acelerômetros são empregados em diversas aplicações. No entanto, será dado enfoque aos acelerômetros mais utilizados no contexto da análise de vibrações em aerogeradores.

Nos últimos anos, foi possível observar um aumento no uso de acelerômetros baseados em sistemas microeletromecânicos (*Microelectromechanical systems* - MEMS) no campo das engenharias. Estes sistemas são conhecidos pelo seu tamanho pequeno e pelo baixo custo em comparação com os acelerômetros piezoelétricos. Além de serem capazes de monitorar vibração, os sensores do tipo MEMS também podem ser utilizados para monitorar temperatura, pressão e umidade. Ademais, estes dispositivos também podem medir não só grandezas mecânicas, mas também medidas elétricas, que é o caso dos MEMS capacitivos (VARANIS *et al.*, 2018).

O item (a) da Figura 9 apresenta o esquemático de um acelerômetro baseado na tecnologia MEMS. Quando o dispositivo é submetido a aceleração, uma força igual a massa multiplicada pela aceleração é aplicada à massa de prova, que é a massa localizada no interior do dispositivo, feita para responder a aceleração. Dessa forma, quando esta força é aplicada à massa de prova, é causado um deslocamento. Este deslocamento causa alterações no espaço entre os capacitores, o que resulta em variações na capacitância. Com isso, estas variações podem ser atribuídas à aceleração aplicada.

O item (b) da Figura 9 apresenta o esquemático de um acelerômetro piezoelétrico. Quando o sensor sofre uma aceleração, a massa sísmica referenciada na imagem faz com que o elemento piezoelétrico se flexione. Desta forma, é gerado um sinal de tensão proporcional à aceleração aplicada. O elemento piezoelétrico é mais sensível na direção em que ele foi flexionado, portanto, muitas vezes é referenciado como um sensor uniaxial. Entretanto,

Figura 9 – Esquemático de dois tipos de acelerômetros.



Fonte: (HUANG; HSU; AHN, 2022).

outras deformações também podem ocorrer em outras direções, resultando assim em sinais de aceleração. Dessa forma, este dispositivo também pode ser referenciado como um sensor onidirecional, pois detecta vibrações não somente no eixo de deformação, isto é, vertical em relação ao solo, como também em outros eixos (HUANG; HSU; AHN, 2022).

De acordo com Ghemari, Saad e Khettab (2019), os acelerômetros piezoelétricos são bastante utilizados para detectar vibrações nos diversos componentes e subcomponentes dos aerogeradores, a fim de detectar possíveis anomalias em estágios iniciais. Os autores também afirmam que um desbalanceamento, uma folga, um desalinhamento e um rolamento desgastado ou danificado podem resultar em uma variação das forças internas pelas quais a máquina passa. Por conta disso, são detectadas modificações em seu comportamento vibratório. O item que será apresentado a seguir aborda uma falha recorrente nos aerogeradores e que será um importante objeto de estudo deste trabalho.

2.3.1.2 Análise de vibrações em rolamentos

Conforme comentado anteriormente, o aerogerador é composto por diversos componentes. Dentro da nacelle, estão localizados o eixo principal, a caixa multiplicadora e o gerador, os quais possuem rolamentos e engrenagens que são bastante propensos a faltas.


De acordo com Peng *et al.* (2023), os rolamentos são componentes cruciais em turbinas eólicas, uma vez que são responsáveis por determinar o nível de fluidez de eixos e de outros elementos rotativos. Desta forma, são responsáveis também por garantir um maior tempo de vida dos aerogeradores, mantendo a eficiência e estabilidade na transmissão de torque entre os componentes da máquina.

Entretanto, tais componentes de um aerogerador operam em ambientes severos e sob condições de trabalho complexas por longos períodos de tempo. Dito isso, os rolamentos são propensos a faltas, o que causa desgastes e até mesmo quebras, comprometendo assim o funcionamento de todo o conjunto de elementos rotativos do aerogerador (PENG *et al.*,

2023).

Para enfatizar a importância de se analisar as vibrações em rolamentos, o gráfico da Figura 10 abaixo apresenta as principais causas de defeitos nas caixas multiplicadoras, com dados coletados no período de 2009 a 2016. É possível perceber que a grande maioria das faltas ocorrem devido aos rolamentos, identificados como *bearing*, na legenda da imagem abaixo.

Figura 10 – Principais causas de faltas nas caixas multiplicadoras.



Fonte: (NREL, 2016).

De acordo com Mollasalehi, Wood e Sun (2017), um rolamento que não apresenta nenhum dano normalmente produz uma vibração estacionária. No entanto, quando um rolamento apresenta anomalias, estas introduzem impulsos em frequências específicas, dependendo da região do rolamento em que a falta ocorreu. Como consequência, estes defeitos acabam amplificando a vibração em uma faixa de frequência específica.

Os impulsos que ocorrem em faixas de frequência específicas são chamadas de frequências características. As equações destas frequências podem ser encontradas no trabalho dos autores Mollasalehi, Wood e Sun (2017). Dependendo da localização da falta, estas frequências são:

1. **Frequência de passagem de esfera na pista externa:** do inglês *Ball Pass Frequency Outer Race* (BPFO), está associada aos defeitos que ocorrem na pista externa. Sua frequência pode ser encontrada pela equação abaixo:

$$BPFO = \frac{nf_r}{2} \left(1 - \frac{d}{D} \cos\alpha \right). \quad (1)$$

2. **Frequência de passagem de esfera na pista interna:** do inglês *Ball Pass Frequency Inner Race* (BPFI), está associada aos defeitos que ocorrem na pista interna. Sua frequência pode ser encontrada pela equação abaixo:

$$BPFI = \frac{n f_r}{2} \left(1 + \frac{d}{D} \cos \alpha \right). \quad (2)$$

3. **Frequência fundamental do trem (Velocidade da gaiola):** do inglês *Fundamental Train Frequency* (FTF), está associada aos defeitos na gaiola e aos defeitos em alguns dos elementos rolantes. Sua frequência pode ser encontrada pela equação abaixo:

$$FTF = \frac{f_r}{2} \left(1 + \frac{d}{D} \cos \alpha \right). \quad (3)$$

4. **Frequência de rotação da esfera:** do inglês *Ball Spin Frequency* (BSF), está associada aos defeitos nos elementos rolantes (rolos ou esferas). Sua frequência pode ser encontrada pela equação abaixo:

$$BSF = \frac{D f_r}{2d} \left(1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right). \quad (4)$$

Nas equações acima, d , D , f_r , α e n são, respectivamente, o diâmetro dos elementos rolantes, diâmetro do passo, frequência de rotação do eixo, ângulo de contato entre os elementos rolantes e a pista de rolamento e, por fim, o número de elementos rolantes (MOLLASALEHI; WOOD; SUN, 2017).


A Figura 11 apresenta a estrutura de um rolamento. Vale ressaltar que o diâmetro do passo é nada mais que a distância entre os raios de dois elementos rolantes defasados de 180° . Ademais, f_{po} , f_{pi} , f_e , f_g , representam, respectivamente os defeitos caracterizados pelas frequências BPFO, BPFI, BSF e FTF. Uma outra visão de um rolamento também pode ser vista na Figura 12.

2.4 PROCESSAMENTO DE SINAIS

Com base no que foi comentado nas seções anteriores, é importante fazer o uso de métodos avançados acerca do monitoramento da condição dos aerogeradores. Com isso, sistemas de monitoramento *online* são necessários para reduzir o tempo de inatividade das máquinas, de forma a diminuir a taxa de defeitos em seus componentes e fornecer notificações antecipadas aos sistemas de monitoramento. Como consequência, há uma maior prevenção de anomalias nos componentes do aerogerador (KUMAR *et al.*, 2021).


Um sistema de monitoramento bastante conhecido é o sistema de supervisão, controle e aquisição de dados (*Supervisory Control And Data Acquisition* - SCADA), o qual

Figura 11 – Frequências características de defeitos.



Fonte: (BASTOS; JUNIOR, 2010).

Figura 12 – Parâmetros geométricos de um rolamento.



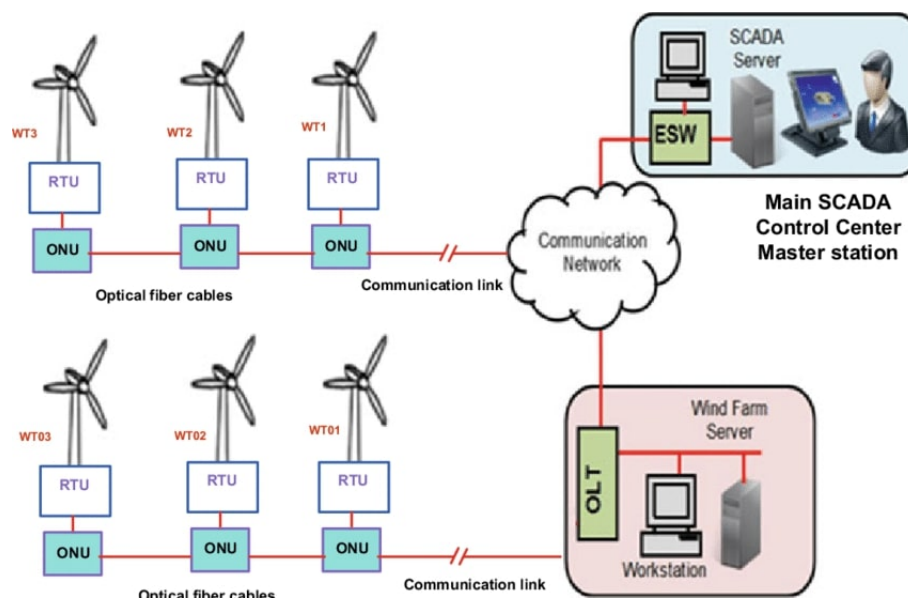
Fonte: (MOLLASALEHI; WOOD; SUN, 2017).

permite a interação do operador com um computador para visualizar e monitorar dados remotamente. Este tipo de monitoramento tem sido amplamente empregado em diversas áreas da indústria, inclusive no contexto em que os aerogeradores estão inseridos. Desta forma, é possível acompanhar o comportamento de um sinal de vibração de qualquer sensor que esteja acoplado a um componente da turbina eólica.

A Figura 13 apresenta uma arquitetura de comunicação baseada em SCADA de

um parque eólico. De um modo geral, o SCADA é responsável por coletar todos os dados adquiridos pelo equipamento de aquisição instalado em cada aerogerador. Em seguida, estes dados são enviados, através de cabos de fibra óptica, até um centro de controle, responsável pela supervisão e monitoramento (SAYED; ABO-KHALIL; ELTAMALY, 2021).

Figura 13 – Sistema de comunicação utilizando SCADA.



Fonte: (SAYED; ABO-KHALIL; ELTAMALY, 2021).

2.4.1 Extração de características

Os dados brutos adquiridos pelos equipamentos de aquisição são dificilmente utilizados para obter informações significativas para determinar a condição do componente. De acordo com Kumar *et al.* (2021), é extremamente necessário realizar técnicas de processamento de sinais para obter informações úteis de um sinal de vibração. Portanto, faz-se necessário manipular o sinal de vibração a fim de obter características importantes antes despercebidas em um sinal bruto no domínio do tempo.

Existem diversas técnicas de processamento de sinais para adquirir estas características, tanto no domínio do tempo, domínio da frequência ou até mesmo em uma combinação de ambos. Estas técnicas serão explicadas abaixo.

2.4.1.1 Domínio do tempo

Os métodos clássicos de processamento de sinais no domínio do tempo fazem parte de análises estatísticas. As principais características que podem ser extraídas de um sinal no domínio do tempo são a média, desvio padrão, variância, raiz quadrada média (*Root Mean Square* - RMS), *kurtosis* e assimetria (GUO; BAI, 2011).

A média, desvio padrão e variância são grandezas correlacionadas. Conforme apresentado no livro do autor Lane (2003), a média é a soma de todos os pontos de um conjunto de dados dividido pelo número de pontos. Já o desvio padrão é bastante utilizado para comparar a dispersão de dois conjuntos de dados distintos que possuem a mesma média. Desta forma, o conjunto de dados com menor desvio padrão apresenta uma menor dispersão de valores em torno da média. Com isso, um ponto selecionado a partir do conjunto de dados cujo desvio padrão é baixo tem uma maior probabilidade de estar próximo a média do que um ponto cujo conjunto de dados possui um desvio padrão alto. A variância, por sua vez, é uma medida de dispersão, que considera a dispersão de todos os pontos em um conjunto de dados. Em outras palavras, é a média das diferenças ao quadrado entre um ponto e a média de um conjunto de dados.

Conforme apresentado no livro dos autores Alexander e Sadiku (2006), o RMS é uma variável bastante importante na engenharia elétrica e no contexto de análise de vibrações. Dado uma forma de onda qualquer, o RMS pode informar o quanto de energia está contida neste sinal. Para um conjunto de dados contínuo, a equação do valor RMS pode ser vista abaixo.


$$RMS = \sqrt{\frac{1}{T_2 - T_1} \left(\int_{T_1}^{T_2} f(t)^2 dt \right)} \quad (5)$$

De acordo com Gawali (2021), assimetria é a medida estatística que avalia o quão assimétrica uma distribuição é. Em outras palavras, ela quantifica o grau em que os dados estão deslocados ou inclinados para um dos lados de um gráfico. De acordo com a Figura 14, a assimetria positiva indica uma cauda mais longa no lado direito do conjunto de dados. Desta forma, é possível compreender os valores atípicos de uma distribuição. Um alto nível de assimetria pode levar a resultados enganosos. Entretanto, existem algumas técnicas de manipulação de dados que ajudam a diminuir a assimetria, mas não serão abordados neste trabalho pois foge um pouco do seu escopo.

Existe também a assimetria negativa, no qual os pontos de uma distribuição estão mais para o lado direito do gráfico, enquanto que a sua cauda se estende para o lado esquerdo. A Figura 15 apresenta este comportamento.

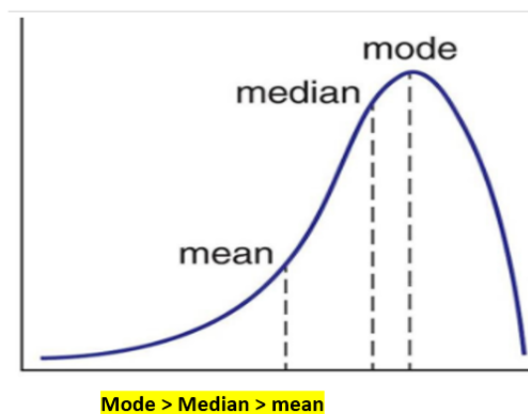
Ainda de acordo com Gawali (2021), a *kurtosis* fornece informações sobre as caudas e sobre o quão pontiaguda ou achatada é uma distribuição em comparação com uma distribuição normal. Uma *kurtosis* positiva indica caudas longas e uma distribuição mais pontiaguda, enquanto que uma *kurtosis* negativa indica uma distribuição mais achatada e caudas menores. Esta grandeza é bastante útil na análise de *outliers*, que são os valores atípicos, de um conjunto de dados.

Figura 14 – Assimetria positiva de um conjunto de dados.



Fonte: (GAWALI, 2021)

Figura 15 – Assimetria negativa de um conjunto de dados.



Fonte: (GAWALI, 2021)

2.4.1.2 Domínio da frequência

Na maior parte dos casos, a análise dos dados através do sinal no domínio do tempo não revela os comportamentos não lineares de um sinal de vibração. Isto é, para sinais que variam com o tempo, os métodos citados na seção anterior não são muito eficazes. Desta forma, existem diversos métodos no domínio da frequência capazes de extrair informações úteis de um sinal de vibração.

De acordo com Meunier e Brouaye (1998), um sinal qualquer pode ser definido como uma soma de senóides. Entretanto, um sinal sinusoidal não possui um começo e nem um fim, pois é um sinal periódico. Desta forma, é muito difícil determinar quando uma frequência em específico está presente em um sinal. No entanto, com o auxílio da Transformada de Fourier (*Fourier Transform - FT*), estas informações podem ser obtidas com uma maior facilidade. A FT é uma técnica de processamento de sinal bastante utilizada na área da engenharia elétrica, no qual é responsável por transformar um sinal

no domínio do tempo para o domínio da frequência. A equação da FT para um sinal $x(t)$ é dada por:

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (6)$$

A fórmula apresentada acima representa a FT para sinais contínuos. No entanto, existe uma ferramenta bastante útil em análises de espectros de sinais de vibração que é a Transformada Discreta de Fourier (*Discrete Fourier Transform* - DFT). A DFT pode ser dada pela seguinte fórmula:

$$X(\omega) = \sum_{n=0}^{N-1} x(t)e^{-\frac{j\omega tn}{N}} \quad (7)$$

Em outras palavras, a DFT projeta uma sequência de dados no domínio do tempo de comprimento N em senóides em N frequências. Entretanto, existe uma ferramenta ainda mais poderosa, capaz de performar a DFT de uma forma mais rápida, chamada de Transformada Rápida de Fourier (*Fast Fourier Transform* - FFT). Ambas as equações apresentadas acima podem ser encontradas no livro do autor Lathi (2009).

A FFT é um dos algoritmos mais utilizados no contexto da análise de vibrações. Esta técnica realiza a mesma operação matemática que a DFT, no entanto possui uma maior eficácia computacional. Isto é, se uma sequência de dados possui um comprimento de $N = 1024$, será necessário para a DFT realizar N^2 operações, enquanto que neste mesmo cenário a FFT realizaria $N \log_2 N$ operações (LATHI, 2009).

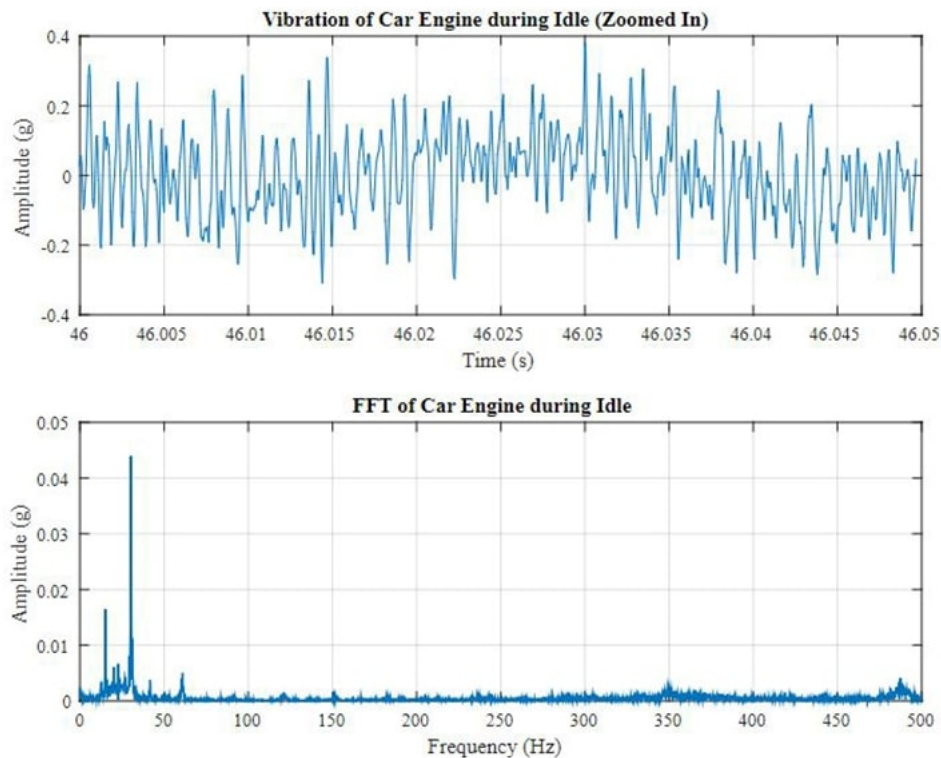
A Figura 16 apresenta uma comparação entre um sinal no domínio do tempo e um sinal no domínio da frequência utilizando o algoritmo da FFT. É possível perceber que é extremamente difícil observar o comportamento do sinal apenas analisando-o no tempo, enquanto que com o auxílio da FFT é possível perceber em quais frequências o sinal possui uma maior vibração, já que a amplitude do sinal é mais alta nestes pontos.

De acordo com Talebi (2022), uma grande desvantagem das técnicas que tem como base a FT é que elas capturam apenas as informações de frequências que estão presentes em todo o sinal de vibração, isto é, as frequências características presentes ao longo de todo o período do sinal. Estas técnicas acabam não sendo tão úteis em alguns casos, especialmente para sinais em que houveram oscilações específicas em um curto período de tempo. Uma abordagem alternativa para atender esses casos é o uso da Transformada de *Wavelet* (*Wavelet Transform* - WT), no qual decompõe o sinal em uma série de pequenas formas de onda.


Para melhor compreensão da WT, segue o exemplo da Figura 17. A *wavelet* presente nesta imagem pode ter a sua escala modificada. Em outras palavras, se a *wavelet* for estreitada, é possível obter informações de altas frequências. Caso o sinal for alargado, obtém-se informações de baixas frequências.

Uma outra técnica que deriva da WT é a *Wavelet Packet Transform* (WPT). Esta

Figura 16 – Sinal no domínio do tempo X domínio da frequência.



Fonte: (HANLY, 2018).

Figura 17 – Exemplo de uma *wavelet*.

Fonte: (TALEBI, 2022) (adaptado).

técnica é bastante poderosa, uma vez que extrai características de um sinal de vibração com um alto grau de seletividade. Além disso, o WPT oferece uma alta resolução nas análises tempo-frequência, o que possibilita a identificação de elementos transitórios de alta frequência presentes no sinal (ABURAKHIA; MYERS; SHAMI, 2022).

Ainda de acordo com Aburakhia, Myers e Shami (2022), a WPT também pode ser definida através das equações 8 e 9. A técnica é implementada através de decomposições iterativas do sinal, aplicando sequências de filtros passa-baixas $h(k)$ e passa-altas $g(k)$.

Neste caso, k representa o número de decomposições do sinal. O sinal bruto $x(t)$ representa $w_0^1(k)$, enquanto que a variável $w_i^s(k)$ representa os coeficientes da decomposição da *wavelet* no nó s na iteração i . As variáveis $w_{i+1}^{2s}(k)$ e $w_{i+1}^{2s+1}(k)$ são os coeficientes da *wavelet* nos nós $2s$ e $2s + 1$ na iteração $i + 1$, respectivamente, os quais representam as informações de baixa frequência e de alta frequência.

$$w_{i+1}^{2s}(t) = \sum_k h(k)w_i^s(2t - k) \quad (8)$$

$$w_{i+1}^{2s+1}(t) = \sum_k g(k)w_i^{s+1}(2t - k) \quad (9)$$

Existem alguns trabalhos que aplicam uma combinação das técnicas WPT e FFT em sinais de vibração, especialmente sinais obtidos através de defeitos em rolamentos, que é o caso do trabalho dos autores Aburakhia, Myers e Shami (2022). Técnicas como essa serão melhores exploradas no capítulo de Desenvolvimento.

2.4.2 Modelos de aprendizado de máquina

A integração de técnicas de extração de características no domínio do tempo e da frequência com algoritmos de aprendizado de máquina, como redes neurais e métodos baseados em árvores de decisão, tem proporcionado uma abordagem mais sofisticada e eficaz para a detecção de anomalias em aerogeradores. Nos próximos parágrafos, serão apresentados algumas destas abordagens.

Um modelo bastante utilizado é o *Deep Autoencoder*, o qual consiste em uma rede neural de múltiplas camadas cuja saída desejada é o próprio dado de entrada. Esta abordagem é composta por duas redes neurais artificiais simétricas, no qual a primeira representa a etapa de codificação e a última a de decodificação.

A primeira etapa consiste em codificar as variáveis de entrada em um conjunto chamado de espaço latente, com uma representação de menor dimensionalidade. Esta codificação permite a rede aprender as características mais relevantes dos dados de treinamento. Esta etapa pode ser representada pela seguinte equação: $h = f(x)$ (GOODFELLOW; BENGIO; COURVILLE, 2016).

Ainda de acordo com Goodfellow, Bengio e Courville (2016), a etapa de decodificação reconstrói as variáveis em equivalentes. A aprendizagem do conjunto de dados leva o *autoencoder* a reconstruir as variáveis de entrada, o que as aproxima da distribuição de probabilidade do espaço de características. A etapa de decodificação pode ser dada pela seguinte equação: $r = g(h)$.

Por fim, a formulação final do *autoencoder* está representada abaixo, onde é desejado que r esteja o mais próximo possível da entrada original x .

$$g(f(x)) = r \quad (10)$$

Um outro modelo bastante utilizado é a classificação baseada em floresta aleatória, *Random Forest Classifier*, do inglês. Esta abordagem consiste num conjunto de classificadores composto por árvores, onde cada árvore é desenvolvida de acordo com um vetor aleatório, as quais são independentes e igualmente distribuídas. Dito isso, cada árvore no conjunto vota na classe mais popular do vetor de entrada. Em síntese, este classificador estabelece um número de árvores individuais que é utilizado para prever a classe, seja ela normal ou anômala. A previsão final da classe é produzida realizando uma votação majoritária das previsões de cada classe para cada árvore (PRIMARTHA; TAMA, 2017).

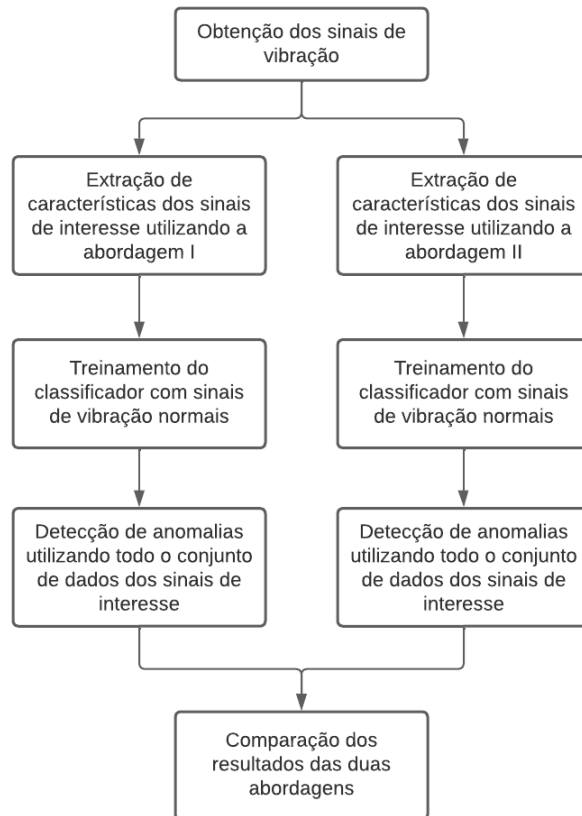
Existem diversos outros modelos de aprendizado de máquina que podem ser encontrados na literatura. Uma técnica bastante interessante consiste na análise de componentes principais (*Principal Component Analysis* - PCA), que utiliza princípios matemáticos para transformar um número possivelmente correlacionado de variáveis em um número menor de variáveis chamadas de componentes principais (SALEM; HUSSEIN, 2019). Seguindo neste mesmo princípio de seleção de características principais, também existe a técnica de eliminação recursiva de características (*Recursive Feature Elimination* - RFE), que é apresentada no trabalho dos autores Jeyauthmigha e Suganthe (2018).

3 DESENVOLVIMENTO

3.1 FLUXOGRAMA

O classificador foi elaborado seguindo algumas etapas de desenvolvimento, conforme apresenta a Figura 18.

Figura 18 – Fluxograma geral do método proposto.



Fonte: Próprio autor.

Inicialmente, são obtidos os sinais de vibração de um determinado componente do aerogerador, sendo que neste conjunto de dados estarão tanto sinais com níveis normais quanto anormais de vibração. É importante ressaltar que estes sinais de vibração são obtidos conforme algumas condições operativas do aerogerador. É considerado principalmente se a máquina está gerando no mínimo 10% de sua potência nominal e também se a sua rotação está acima de 1700 r.p.m. Em seguida, através de abordagens existentes na literatura, as características dos sinais são extraídas.

Entretanto, algumas características obtidas de um sinal de vibração podem não ser de muita relevância para o classificador. Em alguns casos, determinada característica pode estar menos relacionada com a detecção da anomalia. Como consequência, pode fazer com que o classificador se confunda na hora de apresentar o resultado, uma vez que ele foi

treinado com características que estão menos relacionadas com a anomalia. Desta forma, é importante selecionar as características mais relevantes de um sinal de vibração a fim de se obter melhores resultados.

Por fim, as últimas etapas consistem no treinamento do classificador com sinais normais de vibração. Uma vez que o classificador está treinado, ele está apto a identificar sinais com um comportamento anormal de vibração. Desta forma, todo o conjunto de dados é utilizado para identificar as anomalias. Tais etapas serão comentadas com maiores detalhes nas próximas seções.

3.2 EXTRAÇÃO DE CARACTERÍSTICAS

Conforme apresentado no capítulo anterior, a etapa de extração de características é extremamente importante na área de processamento de sinais. Desta forma, foram aplicadas duas abordagens existentes na literatura a fim de se realizar um comparativo destes dois métodos e analisar qual deles obteve um melhor comportamento.

3.2.1 Abordagem I

Nesta primeira abordagem, é realizada a extração de características a curto prazo de um sinal, ou seja, este é dividido em diversas janelas de curta duração. As características são calculadas em cada janela, sendo que no final deste procedimento é obtido um vetor contendo todas as características em todo o período do sinal de vibração. Ao longo deste processo, são obtidas 34 características, tanto no domínio do tempo quanto da frequência. Este método pode ser encontrado no trabalho de Giannakopoulos (2015), e as características obtidas estão listadas abaixo. É importante ressaltar que este método possui um foco maior em sinais de áudio, portanto, algumas características extraídas nesta abordagem podem não ser de muita relevância para um sinal de vibração.

1. **Taxa de cruzamento por zero:** pode ser definida como a taxa de cruzamento por zero de uma janela amostrada, ou seja, a taxa de mudança do sinal. É definida pelo número de vezes que o valor numérico muda de positivo para negativo e vice-versa, dividido pelo comprimento da janela.
2. **Energia:** a energia do sinal fornece informações acerca da intensidade do sinal. Esta característica pode ser definida pela soma dos quadrados dos valores do sinal, normalizado pelo respectivo comprimento da janela.
3. **Entropia:** a entropia são as energias normalizadas de uma janela. Pode ser interpretada como uma medida de mudanças abruptas.
4. **Centroide espectral:** esta característica é definida como o centro de gravidade do espectro.

5. **Espalhamento espectral:** fornece informações sobre quão amplamente distribuídas estão as diferentes frequências no espectro de um sinal.
6. **Entropia espectral:** pode ser definida como a entropia das energias espectrais normalizadas para um conjunto de janelas.
7. **Fluxo espectral:** pode ser definida como a diferença quadrática entre as magnitudes normalizadas dos espectros de duas janelas sucessivas.
8. **Declive espectral:** consiste na frequência abaixo da qual 90% da distribuição de magnitude do espectro está concentrada.
9. **Coefficientes cefálicos de frequência melódica:** consiste em 13 coeficientes que formam uma representação cepstral onde as bandas de frequência não são lineares, mas distribuídas de acordo com a escala melódica. A base teórica deste conceito está presente no trabalho dos autores Stevens e Volkman (1940).
10. **Vetor cromático:** consiste em uma representação da energia espectral do sinal feita através de um vetor de 12 elementos.
11. **Desvio cromático:** consiste no desvio padrão dos 12 coeficientes cromáticos.

3.2.2 Abordagem II

Uma outra abordagem de extração de características que será empregada é a que realiza uma combinação da WPT com a FFT, presente no trabalho dos autores Aburakhia, Myers e Shami (2022). Esta técnica, que foi mencionada no capítulo da Fundamentação Teórica, pode ser melhor representada pela Figura 19.

Com base no exemplo da Figura 19, o sinal é decomposto em três camadas, sendo que em cada decomposição é realizada um filtro passa-baixas e um passa-altas, representados pelas letras A e D, respectivamente. No final deste processo, são obtidas 2^k decomposições, onde k representa a quantidade destas segmentações. Em seguida, a FFT é aplicada em todas as 2^k formas de onda. Desta forma, é obtido um conjunto de características de tamanho $S = m \times 2^k$ para cada sinal de vibração, onde m representa a quantidade de frequências dominantes presentes no espectro de cada forma de onda.

Conforme apresenta a Figura 19, após a decomposição do sinal e a aplicação da FFT são obtidas as frequências dominantes, isto é, as frequências onde a amplitude foi máxima no espectro. Com isso, o cálculo para obter as características de cada espectro pode ser encontrado na equação abaixo:

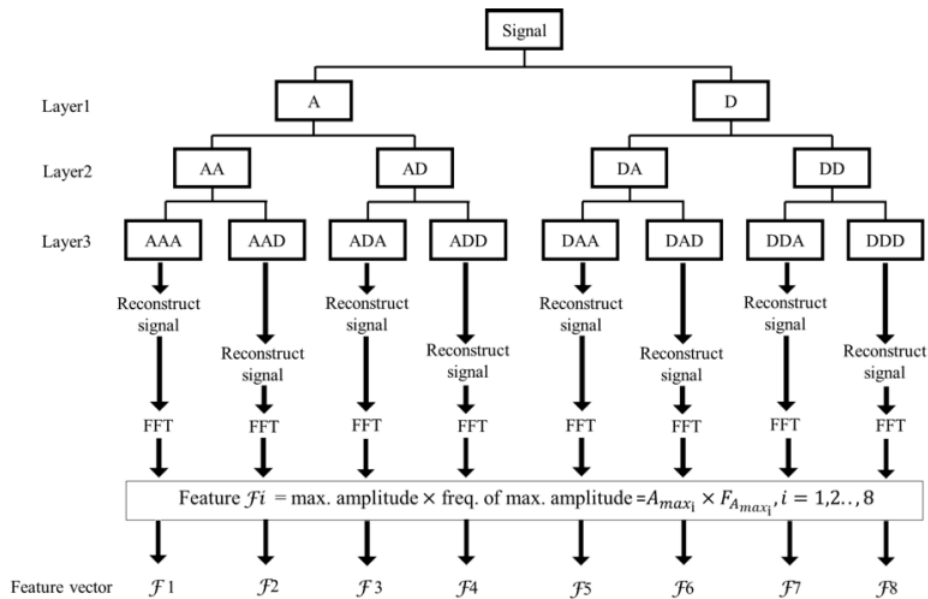
$$F_i = A_{max_i} \times F_{A_{max_i}}. \quad (11)$$

Neste caso, $i = 1, 2, \dots, 2^k$ representa as decomposições, A_{max_i} representa a máxima amplitude e $F_{A_{max_i}}$ a frequência em que ocorreu essa máxima amplitude na i ésima decomposição.

Ademais, para $m > 1$, as m frequências dominantes de cada espectro são selecionadas. Desta forma, o cálculo de cada característica é representado pela equação abaixo:

$$F_i = A1_{max_i} \times F1_{A_{max_i}}, \dots, Am_{max_i} \times Fm_{A_{max_i}}. \quad (12)$$

Figura 19 – Método proposto aplicando decomposição em três camadas.



Fonte: (ABURAKHIA; MYERS; SHAMI, 2022) (adaptado).

3.3 SELEÇÃO DE CARACTERÍSTICAS RELEVANTES


Para realizar a seleção de características mais relevantes de um sinal de vibração, uma técnica que poderá ser empregada é a correlação de Pearson. De acordo com Berman (2016), este tipo de correlação produz uma pontuação que pode variar de -1 a $+1$. Se duas variáveis possuem uma pontuação alta, isto é, próxima de $+1$, significa que estas são altamente similares. Caso duas variáveis possuem uma pontuação próxima de zero, significa que estas variáveis não estão correlacionadas. Por fim, caso duas variáveis possuem uma pontuação próxima de -1 , significa que estas variáveis estão inversamente correlacionadas.

3.4 TREINAMENTO E PREVISÃO A PARTIR DO MODELO DE IA

Nestas duas últimas etapas, o modelo de inteligência artificial a ser adotado é o *Deep Autoencoder* (DAE), cuja teoria foi descrita na seção 2.4.2. O DAE é um modelo

bastante utilizado para classificação de imagens e para detecções de anomalias, estando presente no trabalho dos autores Conradi Hoffmann *et al.* (2021). Desta forma, com base no que foi exposto anteriormente, a arquitetura do DAE pode ser representada pela Figura 20.

Figura 20 – Arquitetura do modelo proposto.



Fonte: (JIMENEZ *et al.*, 2020) (adaptado).

Na entrada do classificador, estão as características extraídas de cada sinal de vibração. A depender dos testes realizados, podem ser inseridos na entrada x sinais de vibração. Desta forma, cada sinal terá um número igual de n características. Portanto, são inseridas na entrada do classificador $x \times n$ características.

Em seguida, tem-se a etapa de codificação, representada na imagem como *encoder*, cujo modelo matemático é dado pela equação $h = f(x)$. Esta etapa é composta por duas camadas ocultas, representadas na imagem acima como *hidden layer (1)* e *hidden layer (2)*. Estas camadas têm o objetivo de reduzir a dimensionalidade dos dados de entrada, isto é, compactar os dados apenas com as informações importantes. Desta forma, as características mais importantes são capturadas e inseridas no *encoding*, também chamado

de espaço latente (GOODFELLOW; BENGIO; COURVILLE, 2016).


Ainda de acordo com Goodfellow, Bengio e Courville (2016), após a codificação é realizada a decodificação, representada na imagem como *decoder* e dada por $r = g(h)$. Esta camada tem o objetivo de descompactar os dados presentes no espaço latente e de reconstruir os dados inseridos na entrada com a mesma dimensionalidade. Desta forma, tem-se a etapa final do DAE, no qual consiste na saída do classificador. A saída do DAE é dada por $g(f(x)) = r$, o que representa dados de entrada reconstruídos.

Conforme já exposto no item 2.4.2, deseja-se que r esteja mais próximo possível da entrada original x . Portanto, quanto mais próximas são essas variáveis, menos anômala é a amostra x . Esta diferença entre a variável de entrada e a variável reconstruída na saída é chamada de erro de reconstrução. Dito isso, quanto maior o erro de reconstrução de uma amostra, mais anômala ela é (CONRADI HOFFMANN *et al.*, 2021).

No entanto, os processos de codificação e decodificação mencionado nos parágrafos anteriores são processos iterativos, isto é, é necessário realizá-los inúmeras vezes até que o erro de reconstrução das amostras seja mínimo. Para isso, o DAE conta com algumas funções de ativação que o auxiliam a identificar se a informação daquele dado de entrada é relevante ou não. Se a informação é importante, esta é armazenada no espaço latente. Caso contrário, ela é descartada (GOODFELLOW; BENGIO; COURVILLE, 2016).

Desta forma, uma vez que o erro de reconstrução é pequeno, pode-se concluir que o classificador já está treinado, pois ele conseguiu reproduzir o que foi inserido na entrada sem perder nenhuma informação relevante. A Figura 21 apresenta melhor este processo, onde é possível visualizar que o exemplo em questão conseguiu reconstruir o dado de entrada sem perdas relevantes. Neste caso, o erro de reconstrução foi baixo e o modelo foi treinado com sucesso.

Figura 21 – Processo de aprendizado do DAE.



Fonte: (DEEP LEARNING BOOK, 2022).

Por fim, é necessário definir um limite para determinar quando que a amostra é considerada anômala ou não. Para melhor compreensão de como determinar este valor, é interessante observar a Figura 22. A distribuição normal do erro de reconstrução das amostras na etapa de treinamento é bastante similar a esta imagem. Desta forma, define-se que se o erro de reconstrução de uma determinada amostra atingir as extremidades da curva de distribuição, isto é, 3 desvios padrões acima ou abaixo da média, esta amostra pode

4 RESULTADOS OBTIDOS

O método proposto, que foi apresentado no capítulo anterior, foi aplicado em três cenários distintos. Desta forma, as duas abordagens de extração de características foram empregadas em cada caso. Os resultados estão apresentados abaixo.

4.1 CASO I

Neste primeiro caso, foram analisados os níveis de vibração de um aerogerador num período entre agosto de 2020 até setembro de 2021. De acordo com os níveis de vibração estabelecidos pela norma ISO 10816-21:2015 (ISO10816-21, 2015), o aerogerador só começou a apresentar níveis anormais a partir de março de 2021. Em setembro de 2021, após meses em que a máquina esteve com altos níveis de vibração, foi realizada a troca do rolamento no eixo de alta velocidade (HSS) da caixa multiplicadora.

Com isso, foram extraídas as características de três sinais de sensores que estavam apontados para o rolamento que precisou ser trocado. Em seguida, o classificador foi treinado com as características saudáveis dos três sinais de agosto a dezembro de 2020, ou seja, com os seus níveis de vibração considerados normais.

Por fim, com o intuito de prever anomalias, todas as características obtidas dos três sinais foram inseridas no classificador, isto é, todo o conjunto de dados. Os resultados das duas abordagens de extração de características encontram-se nas seções abaixo.

4.1.1 Anomalias detectadas


Para ambas as abordagens, foram obtidas as pontuações de cada amostra, que é um valor entre 0 e 1, calculada com base nos seus respectivos erros de reconstrução, ou seja, quanto maior o erro de reconstrução, maior é a pontuação. Consequentemente, mais anômala é a amostra. A Figura 23 apresenta a pontuação das amostras utilizando a abordagem I.

Em seguida, foi realizada a identificação de anomalias de cada amostra. Para compreensão de como esta etapa é realizada, segue a explicação presente no item 3.4. A Figura 24 apresenta o resultado das anomalias detectadas.

4.1.1.1 Abordagem I


Com relação a pontuação das amostras exposta na Figura 23, é possível perceber que há uma maior concentração de valores próximos a 1 a partir do mês de dezembro de 2020, o que indica que a rotulação feita na etapa de treinamento foi bem sucedida. Além disso, é esperado que em algumas amostras não tenham sido detectadas anomalias após o período definido como normal, uma vez que os níveis vibracionais dos sinais após este período podem estar com valores próximos dos níveis normais de vibração.

Figura 23 – Pontuação das amostras - abordagem I - caso I.



Fonte: Próprio autor.

Figura 24 – Anomalias detectadas - abordagem I - caso I.



Fonte: Próprio autor.


O resultado apresentado na Figura 24 indica se houve anomalia ou não em cada amostra, o que deixa ainda mais evidente o que foi explicado no parágrafo anterior.

4.1.1.2 Abordagem II

Na segunda abordagem, o mesmo procedimento foi aplicado no item 4.1.1.

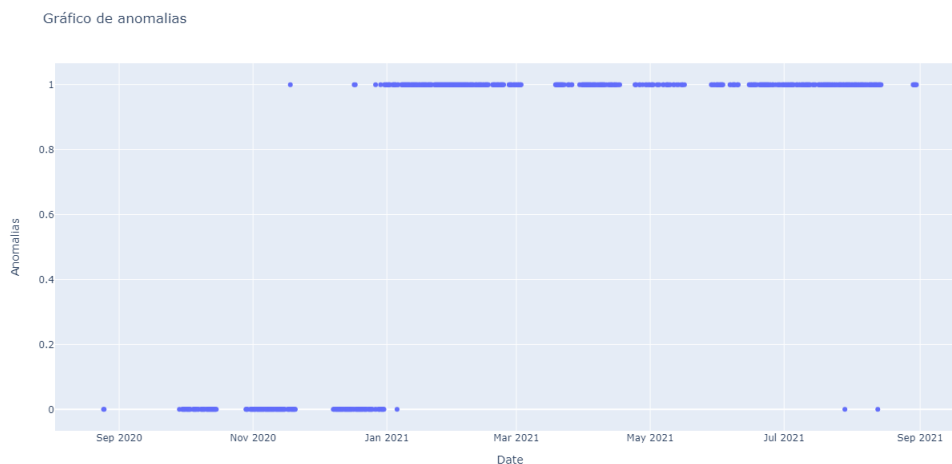
Ao analisar as Figuras 25 e 26, é possível perceber que a concentração de valores próximos a 1 a partir do mês de dezembro de 2020 é bastante evidente, algo que não fica tão claro na Figura 23. Além disso, também é possível perceber que houveram poucas amostras após o período dito como normal em que não foram detectadas anomalias, algo que também não aconteceu na abordagem I. Desta forma, é possível perceber que a

Figura 25 – Pontuação de anomalias - abordagem II - caso I.



Fonte: Próprio autor.

Figura 26 – Anomalias detectadas - abordagem II - caso I.



Fonte: Próprio autor.

abordagem II foi capaz de detectar mais anomalias, o que é algo positivo. Mais comentários a respeito dos resultados das duas abordagens podem ser encontrados no item 4.1.2.

4.1.2 Comparativo com as abordagens aplicadas

Após as detecções de anomalias das duas abordagens, foi realizada uma curva de acúmulo de anomalias ao longo do tempo. Em outras palavras, foi feito um somatório para cada amostra anômala. Caso não for detectada nenhuma anomalia em um determinado período, a curva de acúmulo é uma linha reta, uma vez que não houve anomalia neste intervalo.


Desta forma, foram geradas duas curvas de acúmulo para as abordagens I e II, que

foram colocadas num mesmo gráfico ao longo do período de agosto de 2020 a setembro de 2021. Além disso, também foram geradas as tendências de vibração dos três sinais que foram utilizados para treinamento e previsão do classificador, que pode ser visto na Figura 27.

Os sinais utilizados neste caso foram obtidos através de sensores posicionados sobre o rolamento traseiro do eixo de alta velocidade da caixa multiplicadora, nas posições radial e axial, correspondendo aos sinais VHSS-R e VHSS-A, respectivamente. Outro sinal que também foi utilizado foi obtido através do sensor posicionado radialmente sobre o rolamento traseiro do eixo intermediário da caixa multiplicadora, identificado como VIMS. Além disso, os sinais de vibração estão na unidade de g , ou seja, todos os pontos do sinal são divididos pela aceleração da gravidade, que é algo em torno de $9,807 \text{ m/s}^2$.

Por fim, linhas horizontais traçadas também foram inseridas no gráfico, indicando os níveis de atenção e alerta de vibração definidos pela norma ISO 10816-21:2015 (ISO10816-21, 2015).

Figura 27 – Comparativo entre as abordagens aplicadas - caso I.



Fonte: Próprio autor.

Ao analisar a Figura 27, é possível perceber que a abordagem II foi a que apresentou melhores resultados. Desta forma, foi possível identificar um aumento significativo de anomalias a partir de janeiro de 2021, enquanto que com a abordagem I isso só foi possível a partir de meados de fevereiro do mesmo ano. Ademais, o número de anomalias detectadas também foi maior na abordagem II. Entretanto, é importante ressaltar que ambas as abordagens obtiveram um bom desempenho ao comparar com os níveis de vibração da norma ISO 10816-21:2015, que só começou a detectar níveis anormais de

vibração na metade de março do mesmo ano.

4.2 CASO II

No segundo caso, foi analisado os níveis de vibração de um aerogerador num período entre novembro de 2022 até outubro de 2023. De acordo com os níveis de vibração estabelecidos pela norma ISO 10816-21:2015, o aerogerador só começou a apresentar níveis anormais em meados de agosto de 2023. Em setembro do mesmo ano, houve a troca do rolamento localizado no eixo do gerador.

Com isso, foram extraídas as características de dois sinais que estavam apontados para o rolamento que precisou ser trocado. Em seguida, o classificador foi treinado com as características saudáveis dos dois sinais de novembro de 2022 a março de 2023, ou seja, com os seus níveis de vibração considerados normais.


Por fim, com o intuito de prever anomalias, todas as características obtidas dos sinais foram inseridas no classificador, isto é, todo o conjunto de dados. Os resultados das duas abordagens de extração de características encontram-se nas seções abaixo, seguindo a mesma metodologia comentada no item 4.1.1.

4.2.1 Anomalias detectadas

4.2.1.1 Abordagem I

As imagens a seguir apresentam a pontuação e a detecção de anomalias em cada amostra para a primeira abordagem.


Figura 28 – Pontuação das amostras - abordagem I - caso II.



Fonte: Próprio autor.

Com relação a Figura 28, é possível perceber que a pontuação das amostras está mais dispersa. Entretanto, a partir de março de 2023, as pontuações começam a atingir

Figura 29 – Anomalias detectadas - abordagem I - caso II.



Fonte: Próprio autor.

valores próximos a 1. Tal resultado faz sentido, uma vez que para este caso o classificador foi treinado com os níveis de vibração saudáveis de novembro de 2022 a março de 2023. Entretanto, por volta do início de setembro, o rolamento em que houve a falha foi trocado. Desta forma, a partir deste período, a pontuação das anomalias deveria ser baixa, algo que não aconteceu. Tal comportamento indica a presença de possíveis falsos positivos, uma vez que após a troca do rolamento, os níveis de vibração voltam a patamares normais, ou seja, não deveriam ter sido detectadas anomalias.

Ademais, o resultado apresentado na Figura 29 indica se houve anomalia ou não em cada ponto, o que deixa ainda mais evidente o que foi explicado para a pontuação das amostras.


4.2.1.2 Abordagem II

As imagens a seguir apresentam a pontuação e a detecção de anomalias em cada amostra para a segunda abordagem.

Ao analisar os resultados das Figuras 30 e 31, é possível perceber que a pontuação das amostras também está mais dispersa, atingindo valores próximos a 1 a partir de março de 2023. De um modo geral, os resultados desta abordagem foram bastante similares aos resultados da abordagem I.


Entretanto, o diferencial desta abordagem está nos resultados das amostras a partir da troca do rolamento, no início de setembro de 2023. É possível perceber em ambas as imagens que não foram detectadas anomalias após a troca do rolamento. Tal comportamento é esperado e faz sentido, uma vez que com o componente trocado, os níveis de vibração voltam a níveis normais. Maiores comentários a respeito dos resultados das duas abordagens estão presentes no item 4.2.2.

Figura 30 – Pontuação das amostras - abordagem II - caso II.



Fonte: Próprio autor.

Figura 31 – Anomalias detectadas - abordagem II - caso II.



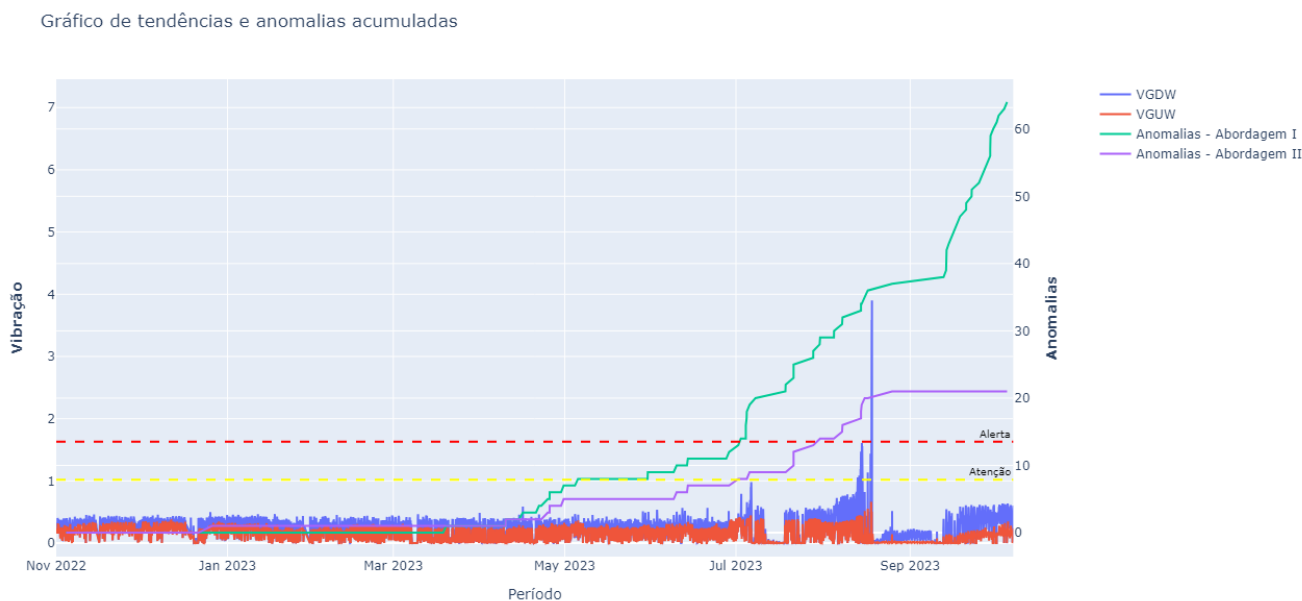
Fonte: Próprio autor.

4.2.2 Comparativo com as abordagens aplicadas

Para realizar a comparação entre as duas abordagens, o mesmo procedimento apresentado no item 4.1.2 foi aplicado neste segundo caso. O resultado das curvas de acúmulo das duas abordagens e as tendências de vibração dos sinais encontram-se na Figura 32 abaixo. Os sinais identificados como VGDW e VGUW, correspondem, respectivamente, aos sinais obtidos dos sensores posicionados sobre o rolamento traseiro e dianteiro do eixo do gerador. Além disso, os sinais de vibração estão na unidade de g , ou seja, todos os pontos do sinal são divididos pela aceleração da gravidade, que é algo em torno de $9,807 \text{ m/s}^2$.

A partir da imagem apresentada na Figura 32, é possível perceber que ambas

Figura 32 – Comparativo entre as abordagens aplicadas - caso II.



Fonte: Próprio autor.

as abordagens apresentaram bons resultados. Os níveis de vibração do rolamento deste gerador subiram de uma forma bastante abrupta. Conseqüentemente, quando os níveis de vibração estabelecidos pela norma atingiram patamares anormais, o rolamento já estava bastante corrompido. No entanto, ambas as abordagens já vinham detectando anomalias neste rolamento desde maio, ou seja, a falha poderia ter sido detectada meses antes da quebra do componente, que ocorreu em agosto de 2023.

Após a ruptura, foi realizada a troca deste rolamento. Deste modo, ao analisar novamente a Figura 32, é possível perceber que a abordagem I continuou detectando anomalias, enquanto que a abordagem II permaneceu com o número de anomalias detectadas constante. Tal comportamento indica possíveis falsos positivos na abordagem I, uma vez que mesmo com a troca do rolamento, esta continuou detectando anomalias.

4.3 CASO III

Para o último caso, foi analisado os níveis de vibração de um aerogerador num período entre dezembro de 2021 até outubro de 2023. De acordo com os níveis de vibração estabelecidos pela norma ISO 10816-21:2015, o aerogerador só começou a apresentar níveis anormais a partir de junho de 2023.

Com isso, foram extraídas as características de três sinais que estavam apontados para o rolamento que precisou ser trocado. Em seguida, o classificador foi treinado com as características saudáveis dos três sinais de dezembro de 2021 a abril de 2022, ou seja, com os seus níveis de vibração considerados normais.


Por fim, com o intuito de prever anomalias, todas as características obtidas dos três sinais foram inseridas no classificador, isto é, todo o conjunto de dados. Os resultados das duas abordagens de extração de características encontram-se nas seções abaixo.

4.3.1 Anomalias detectadas

4.3.1.1 Abordagem I


As imagens a seguir apresentam a pontuação e a detecção de anomalias em cada amostra para a primeira abordagem.

Figura 33 – Pontuação das amostras - abordagem I - caso III.



Fonte: Próprio autor.

Figura 34 – Anomalias detectadas - abordagem I - caso III.




Fonte: Próprio autor.

Ao analisar as Figuras 33 e 34, é possível perceber que os resultados desta abordagem não foram tão satisfatórios. Isto se justifica ao analisar a pontuação das amostras a partir de abril de 2022, na qual é possível observar que poucas amostras possuíam valores próximos a 1. Desta forma, foram detectadas poucas anomalias, o que fica bastante evidente na Figura 34.

4.3.1.2 Abordagem II


As imagens a seguir apresentam a pontuação e a detecção de anomalias em cada amostra para a segunda abordagem.

Figura 35 – Pontuação das amostras - abordagem II - caso III.



Fonte: Próprio autor.

Figura 36 – Anomalias detectadas - abordagem II - caso III.



Fonte: Próprio autor.


Ao analisar as Figuras 35 e 36, é possível perceber que os resultados foram bastante diferentes dos resultados obtidos na abordagem I. A partir de abril de 2022, a pontuação das amostras em alguns casos foi próxima de 1, o que indica a presença de anomalias. Portanto, pode-se concluir que os resultados da abordagem II obtiveram um melhor desempenho. Maiores comentários a respeito dos resultados das duas abordagens estão presentes no item 4.3.2.

4.3.2 Comparativo com as abordagens aplicadas

Para realizar a comparação entre as duas abordagens, o mesmo procedimento apresentado no item 4.1.2 foi aplicado neste segundo caso. O resultado das curvas de acúmulo das duas abordagens e as tendências de vibração dos sinais encontram-se na Figura 37 abaixo.

Neste último caso, também foram utilizados os sinais obtidos através de sensores posicionados sobre o rolamento traseiro do eixo de alta velocidade da caixa multiplicadora, nas posições radial e axial, correspondendo aos sinais VHSS-R e VHSS-A, respectivamente. Outro sinal que também foi utilizado foi obtido através do sensor posicionado radialmente sobre o rolamento traseiro do eixo intermediário da caixa multiplicadora, identificado como VIMS. Além disso, os sinais de vibração estão na unidade de g , ou seja, todos os pontos do sinal são divididos pela aceleração da gravidade, que é algo em torno de $9,807 \text{ m/s}^2$.

Figura 37 – Comparativo entre as abordagens aplicadas - caso III.



Fonte: Próprio autor.

Ao analisar a Figura 37, foi possível perceber novamente que a abordagem II foi a que apresentou melhores resultados. Um aumento gradual nas detecções de anomalias

começou a ser percebido a partir de dezembro de 2022. Por volta do dia 6 de junho de 2023, houve uma elevação abrupta na curva de anomalias. Entretanto, os limites de vibração da norma ISO 10816-21:2015 só detectaram um nível alto no dia 20 de junho, praticamente duas semanas após a curva da abordagem II subir repentinamente.

Com relação à abordagem I, esta detectou menos anomalias e teve um resultado considerado pior ao da abordagem II. No dia 6 de junho, a primeira abordagem apresentava apenas duas anomalias detectadas, o que indica que esta foi menos sensível a anormalidades entre dezembro de 2022 a maio de 2023, período este em que a sensibilidade da abordagem II foi maior. A partir do dia 20 de junho, a curva de anomalias da abordagem I acentuou-se. No entanto, neste mesmo dia os limites da norma ISO 10816-21:2015 também detectaram níveis altos de vibração, o que fez com que a abordagem I não fosse de tanta utilidade para este caso.

5 CONCLUSÕES

5.1 RESULTADOS OBTIDOS

Com base nos resultados obtidos nos três casos, é possível perceber que a abordagem II obteve um desempenho melhor do que a primeira. De um modo geral, o desempenho da segunda abordagem foi mais satisfatório, principalmente em variações abruptas dos sinais de vibração. Além disso, o classificador baseado nesta abordagem conseguiu obter um maior aprendizado na etapa de treinamento. Um exemplo disso é o resultado do caso II, que após a troca do rolamento, a abordagem II parou de detectar anomalias, o que não aconteceu com a primeira abordagem.

Entretanto, neste trabalho foram realizados testes em apenas três casos. É necessário realizar mais testes, em diferentes componentes do aerogerador e com diferentes sinais de vibração. Quanto maior o número de testes realizados, maior será a clareza para definir qual abordagem é a mais indicada.

Desta forma, é importante ressaltar que uma abordagem não substitui a outra, ou seja, ambas podem ser utilizadas para a detecção de anomalias. Além disso, a análise das tendências de vibração dos componentes com base na norma ISO 10816-21:2015 também não deve ser descartada. Recomenda-se utilizar as abordagens de detecção de anomalias como um complemento à análise de vibrações.

Por fim, pode-se concluir que o método proposto cumpriu com os objetivos deste trabalho. Foi possível obter diversos dados de vibração de sinais no domínio do tempo. Através de técnicas de processamento de sinais, estes dados foram passados para o domínio da frequência a fim de se obter características relevantes. O classificador desenvolvido foi testado em três casos distintos, sendo que na etapa de extração de características foram utilizadas duas abordagens com o intuito de comparar o desempenho do classificador sob estas diferentes técnicas. Ademais, foi realizada uma comparação entre estas duas abordagens e com os limites estabelecidos pela norma ISO 10816-21:2015 para sinais de vibração.

5.2 TRABALHOS FUTUROS

Com base nas conclusões extraídas dos resultados dos casos I, II e III, é importante ressaltar aspectos que não foram abordados neste trabalho, mas que desempenham um papel fundamental no desenvolvimento de algoritmos de detecção de anomalias cada vez mais sofisticados.

Dito isso, recomenda-se para trabalhos futuros realizar a extração de características relevantes dos sinais. Conforme exposto no item 3.1, algumas características obtidas podem não ser de muita relevância para o classificador. Desta forma, estas podem influenciar negativamente a tomada de decisão do classificador na identificação da anomalia. Um

método de seleção de características relevantes interessante é o que foi comentado no item 3.3. Entretanto, acabou não sendo aplicado em nenhum dos três casos.

Ao analisar novamente o comportamento da abordagem I do terceiro caso, apresentado na Figura 37, um método de seleção de características dos sinais de vibração poderia ser aplicado. Os resultados desta abordagem poderiam ter sido melhores, entretanto, por falta de tempo hábil, não foi possível realizar nenhuma melhoria nesta abordagem.

Um ponto de melhoria a ser analisado na abordagem II é o valor de m , isto é, a quantidade de frequências dominantes presentes no espectro de cada forma de onda. A depender do caso, o valor de m pode ser alterado. Neste trabalho, não foi realizado nenhum estudo aprofundado sobre o impacto de se escolher m frequências dominantes na etapa de extração de características. Entretanto, é interessante analisar este aspecto.

Outro aspecto importante para trabalhos futuros está na definição dos níveis normais de vibração para treinar o classificador. Em alguns casos, o treinamento pode ser feito com o componente já dando indícios de uma possível anormalidade. Logo, o classificador pode ficar enviesado, levando-o a não identificar anomalias com antecedência, o que compromete o componente e o conduz da falta à falha. Desta forma, é necessário realizar uma rotulação bem definida sobre o que é um sinal com vibração normal e anormal. Após este discernimento, a confiabilidade do classificador aumenta.

Além disso, também é interessante avaliar o caso de um aerogerador saudável que não tenha sido detectada nenhuma falta ou falha, com o intuito de realmente não detectar nenhuma anomalia na etapa de previsão. Desta forma, analisando um caso completamente diferente dos testes realizados neste trabalho, em que se tinham comportamentos saudáveis durante um período e logo após comportamentos anormais, seus resultados colocariam ainda mais em prova o desempenho do classificador.

Por fim, outro fator importante é o que ocorreu no caso II, visto na Figura 32. Neste caso, a abordagem I continuou a detectar anomalias mesmo após a troca do rolamento. Tal comportamento é indesejado, uma vez que com o componente novo, os níveis de vibração voltam a patamares baixos, ou seja, nenhuma anomalia deveria ter sido detectada. Desta forma, deve-se buscar métodos que visam corrigir comportamentos similares. Para trabalhos futuros, uma análise mais profunda de casos nestas situações deve ser realizada.

REFERÊNCIAS

ABURAKHIA, Sulaiman A.; MYERS, Ryan; SHAMI, Abdallah. A Hybrid Method for Condition Monitoring and Fault Diagnosis of Rolling Bearings With Low System Delay. **IEEE Transactions on Instrumentation and Measurement**, v. 71, p. 1–13, 2022. DOI: 10.1109/TIM.2022.3198477.

AIKIN, Andrea. **Bearing and gearbox failures: Challenge to wind turbines**. [S.l.: s.n.], 2023. <https://www.windsystemsmag.com/bearing-and-gearbox-failures-challenge-to-wind-turbines>. Acesso em: 16 de ago. 2023.

ALEXANDER, Charles; SADIKU, Matthew. **Fundamentals of Electric Circuits**. 3. ed. USA: McGraw-Hill, Inc., 2006. ISBN 0073301159.

BASTOS, Rodrigo José; JUNIOR, Reinaldo Borges. **Previsão de falhas em rolamentos utilizando a demodulação de sinais de vibração**. 4º Seminário de Produção Acadêmica da Anhanguera. [S.l.: s.n.], 2010. <https://repositorio.pgsscogna.com.br//handle/123456789/101>. Acesso em: 19 de ago. 2023.

BERMAN, Jules J. Chapter 4 - Understanding Your Data. *In: _____*. **Data Simplification**. Edição: Jules J. Berman. Boston: Morgan Kaufmann, 2016. P. 135–187. ISBN 978-0-12-803781-2. DOI: <https://doi.org/10.1016/B978-0-12-803781-2.00004-7>. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780128037812000047>.

CHIN, Richard; LEE, Bruce Y. Chapter 3 - Introduction to Clinical Trial Statistics. *In: _____*. **Principles and Practice of Clinical Trial Medicine**. Edição: Richard Chin e Bruce Y. Lee. New York: Academic Press, 2008. P. 43–60. ISBN 978-0-12-373695-6. DOI: <https://doi.org/10.1016/B978-0-12-373695-6.00003-X>. Disponível em: <https://www.sciencedirect.com/science/article/pii/B978012373695600003X>.

CONRADI HOFFMANN, José Luis *et al.* Anomaly Detection on Wind Turbines Based on a Deep Learning Analysis of Vibration Signals. **Applied Artificial Intelligence**, v. 35, p. 1–21, ago. 2021. DOI: 10.1080/08839514.2021.1966879.

DEEP LEARNING BOOK. **Capítulo 58 – Introdução aos Autoencoders**. 2022. Disponível em: <https://www.deeplearningbook.com.br/introducao-aos-autoencoders/>. Acesso em: 1 dez. 2023.

DU, Wenliao *et al.* From Anomaly Detection to Novel Fault Discrimination for Wind Turbine Gearboxes With a Sparse Isolation Encoding Forest. **IEEE Transactions on Instrumentation and Measurement**, v. 71, p. 1–10, 2022. DOI: 10.1109/TIM.2022.3187737.

FENG, Yanhui *et al.* Monitoring wind turbine gearboxes. **Wind Energy**, v. 16, n. 5, p. 728–740, 2013. DOI: <https://doi.org/10.1002/we.1521>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/we.1521>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/we.1521>.

GAWALI, Suvarna. **Skewness and Kurtosis: Quick Guide (Updated 2023)**. [S.l.: s.n.], 2021. <https://bit.ly/what-is-kurtosis>. Acesso em: 26 de ago. 2023.

GHEMARI, Zine; SAAD, Salah; KHETTAB, Khatir. Improvement of the vibratory diagnostic method by evolution of the piezoelectric sensor performances. **International Journal of Precision Engineering and Manufacturing**, Springer, v. 20, n. 8, p. 1361–1369, 2019.

GIANNAKOPOULOS, Theodoros. pyAudioAnalysis: An Open-Source Python Library for Audio Signal Analysis. **PloS one**, Public Library of Science, v. 10, n. 12, 2015.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. [S.l.]: MIT Press, 2016. <http://www.deeplearningbook.org>.

GUO, Peng; BAI, Nan. Wind turbine gearbox condition monitoring with AAKR and moving window statistic methods. **Energies**, MDPI, v. 4, n. 11, p. 2077–2093, 2011.

HANLY, Steve. **The Ultimate Guide to Vibration Analysis**. [S.l.: s.n.], 2018. <https://www.designworldonline.com/the-ultimate-guide-to-vibration-analysis/>. Acesso em: 28 de ago. 2023.

HUANG, Han-Ping; HSU, Francis; AHN, Andrew. **MEMS vs. Piezoelectric Accelerometer**. [S.l.: s.n.], 2022. <https://www.labfront.com/article/mems-vs-piezoelectric-accelerometer>. Acesso em: 17 de ago. 2023.

IRENA. **Wind energy**. 2022. Disponível em: <https://www.irena.org/Energy-Transition/Technology/Wind-energy>. Acesso em: 7 ago. 2023.

ISO10816-21. **Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts — Part 21: Horizontal axis wind turbines with gearbox**. [S.l.: s.n.], 2015. Acesso em: 16 de ago. 2023.

JEYAUTHMIGHA, R.K.; SUGANTHE, R.C. Recursive Feature Elimination and Clustering Technique for Network Anomaly Detection. *In*: 2018 International Conference on Current Trends towards Converging Technologies (ICCTCT). [S.l.: s.n.], 2018. P. 1–6. DOI: 10.1109/ICCTCT.2018.8551043.

- JIANG, Guoqian *et al.* Wind Turbine Fault Detection Using a Denoising Autoencoder With Temporal Information. **IEEE/ASME Transactions on Mechatronics**, v. 23, n. 1, p. 89–100, 2018. DOI: 10.1109/TMECH.2017.2759301.
- JIMENEZ, Manuel *et al.* Galaxy Image Classification Based on Citizen Science Data: A Comparative Study. **IEEE Access**, PP, p. 1–1, mar. 2020. DOI: 10.1109/ACCESS.2020.2978804.
- K.S., Sajal *et al.* Analysis of epicyclic gears with composite material for a wind turbine gearbox. **Materials Today: Proceedings**, v. 50, p. 2092–2098, 2022. 2nd International Conference on Functional Material, Manufacturing and Performances (ICFMMP-2021). ISSN 2214-7853. DOI: <https://doi.org/10.1016/j.matpr.2021.09.421>.
Disponível em:
<https://www.sciencedirect.com/science/article/pii/S2214785321063379>.
- KUMAR, Roshan *et al.* Damage detection of wind turbine system based on signal processing approach: A critical review. **Clean Technologies and Environmental Policy**, Springer, v. 23, p. 561–580, 2021.
- LANE, David. **Introduction to Statistics**. 2003. Disponível em:
<https://open.umn.edu/opentextbooks/textbooks/459>. Acesso em: 26 ago. 2023.
- LAPPAS, Demetris; ARGYRIOU, Vasileios; MAKRIS, Dimitrios. Fourier Transformation Autoencoders for Anomaly Detection. *In: ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.: s.n.], 2021. P. 1475–1479. DOI: 10.1109/ICASSP39728.2021.9415010.
- LATHI, B. P. **Linear Systems and Signals**. 2nd. USA: Oxford University Press, Inc., 2009. ISBN 0195392566.
- MEUNIER, M.; BROUAYE, F. Fourier transform, wavelets, Prony analysis: tools for harmonics and quality of power. *In: 8TH International Conference on Harmonics and Quality of Power*. Proceedings (Cat. No.98EX227). [S.l.: s.n.], 1998. 71–76 vol.1. DOI: 10.1109/ICHQP.1998.759842.
- MOLLASALEHI, Ehsan; WOOD, David; SUN, Qiao. Indicative Fault Diagnosis of Wind Turbine Generator Bearings Using Tower Sound and Vibration. **Energies**, v. 10, n. 11, 2017. ISSN 1996-1073. DOI: 10.3390/en10111853. Disponível em:
<https://www.mdpi.com/1996-1073/10/11/1853>.
- NĂSTASE, Eugen-Vlad. Influence of the material used to build the blades of a wind turbine on their starting conditions. **MATEC Web of Conferences**, v. 112, p. 10017, jan. 2017. DOI: 10.1051/matecconf/201711210017.

NREL, National Renewable Energy Laboratory. **Wind Turbine Gearbox Damage Distribution Statistics**. 2016. Disponível em: <https://grd.nrel.gov/stats>. Acesso em: 19 ago. 2023.

OLABI, Abdul Ghani *et al.* A Review on Failure Modes of Wind Turbine Components. **Energies**, v. 14, n. 17, 2021. ISSN 1996-1073. DOI: 10.3390/en14175241. Disponível em: <https://www.mdpi.com/1996-1073/14/17/5241>.

ORSAGH, Rolf F *et al.* Advanced vibration monitoring for wind turbine health management. **Impact Technologies**, <http://www.impact-tek.com>, 2006.

PENG, Han *et al.* A Review of Research on Wind Turbine Bearings; Failure Analysis and Fault Diagnosis. **Lubricants**, v. 11, n. 1, 2023. ISSN 2075-4442. DOI: 10.3390/lubricants11010014. Disponível em: <https://www.mdpi.com/2075-4442/11/1/14>.

PRIMARTHA, Rifkie; TAMA, Bayu Adhi. Anomaly detection using random forest: A performance revisited. *In: 2017 International Conference on Data and Software Engineering (ICoDSE)*. [S.l.: s.n.], 2017. P. 1–6. DOI: 10.1109/ICODSE.2017.8285847.

QIAO, Wei; LU, Dingguo. A Survey on Wind Turbine Condition Monitoring and Fault Diagnosis—Part I: Components and Subsystems. **IEEE Transactions on Industrial Electronics**, v. 62, n. 10, p. 6536–6545, 2015. DOI: 10.1109/TIE.2015.2422112.

SALEM, Nema; HUSSEIN, Sahar. Data dimensional reduction and principal components analysis. **Procedia Computer Science**, v. 163, p. 292–299, 2019. 16th Learning and Technology Conference 2019 Artificial Intelligence and Machine Learning: Embedding the Intelligence. ISSN 1877-0509. DOI: <https://doi.org/10.1016/j.procs.2019.12.111>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050919321507>.

SAYED, Khairy; ABO-KHALIL, Ahmed; ELTAMALY, Ali. Wind Power Plants Control Systems Based on SCADA System. *In: [S.l.: s.n.]*, mar. 2021. ISBN 978-3-030-64335-5. DOI: 10.1007/978-3-030-64336-2_6.

STEVENS, S. S.; VOLKMANN, J. The Relation of Pitch to Frequency: A Revised Scale. **The American Journal of Psychology**, University of Illinois Press, v. 53, n. 3, p. 329–353, 1940. ISSN 00029556. Disponível em: <http://www.jstor.org/stable/1417526>. Acesso em: 7 out. 2023.

TALEBI, Shawhin. **Fourier vs. Wavelet Transform: What’s the Difference?** [S.l.: s.n.], 2022. <https://builtin.com/data-science/wavelet-transform>. Acesso em: 29 de ago. 2023.

TCHAKOUA, Pierre *et al.* Wind Turbine Condition Monitoring: State-of-the-Art Review, New Trends, and Future Challenges. **Energies**, v. 7, n. 4, p. 2595–2630, 2014.

ISSN 1996-1073. DOI: 10.3390/en7042595. Disponível em:
<https://www.mdpi.com/1996-1073/7/4/2595>.

TENG, Wei *et al.* Pitting Fault Detection of a Wind Turbine Gearbox Using Empirical Mode Decomposition. **Strojniski Vestnik**, v. 60, p. 12–20, jan. 2014. DOI: 10.5545/sv-jme.2013.1295.

VARANIS, Marcus *et al.* MEMS accelerometers for mechanical vibrations analysis: A comprehensive review with applications. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer, v. 40, p. 1–18, 2018.

VICTORINO, M.N.; JIANG, X.; MENON, C. Chapter 7 - Wearable Technologies and Force Myography for Healthcare. *In*: TONG, Raymond Kai-Yu (Ed.). **Wearable Technology in Medicine and Health Care**. [S.l.]: Academic Press, 2018. P. 135–152. ISBN 978-0-12-811810-8. DOI:
<https://doi.org/10.1016/B978-0-12-811810-8.00007-5>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/B9780128118108000075>.

WU, Chung-Wei; CHEN, Mei. Early anomaly detection in wind turbine bolts breaking problem — Methodology and application. *In*: 2018 IEEE 3rd International Conference on Big Data Analysis (ICBDA). [S.l.: s.n.], 2018. P. 402–406. DOI: 10.1109/ICBDA.2018.8367716.

WYMORE, Mathew L. *et al.* A survey of health monitoring systems for wind turbines. **Renewable and Sustainable Energy Reviews**, v. 52, p. 976–990, 2015. ISSN 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2015.07.110>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S1364032115007571>.

YANG, Wenxian *et al.* Advanced Health Condition Monitoring of Wind Turbines. *In*: [S.l.: s.n.], mai. 2018. P. 193–218. ISBN 978-3-319-78165-5. DOI: 10.1007/978-3-319-78166-2_7.

ZHOU, Haoxuan *et al.* Construction of health indicators for condition monitoring of rotating machinery: A review of the research. **Expert Systems with Applications**, v. 203, p. 117297, 2022. ISSN 0957-4174. DOI:
<https://doi.org/10.1016/j.eswa.2022.117297>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0957417422006625>.