

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS

João Victor Tonello Ribeiro

APRENDIZAGEM DE MÁQUINA APLICADA À DETECÇÃO
DE FALHAS DE ACOPLAMENTO DE ACELERÔMETROS
NO CONTEXTO DE GERAÇÃO EÓLICA

FLORIANÓPOLIS

2022

João Victor Tonello Ribeiro
APRENDIZAGEM DE MÁQUINA APLICADA À DETECÇÃO DE FALHAS
DE ACOPLAMENTO DE ACELERÔMETROS NO CONTEXTO DE GERAÇÃO
EÓLICA/ João Victor Tonello Ribeiro. – Florianópolis, 2022-
65, 30 cm.

Orientador: Prof. Dr. Eduardo Luiz Ortiz Batista

– Universidade Federal de Santa Catarina
Departamento de Engenharia Elétrica e Eletrônica , 2022.

1. Geração Eólica. 2. Análise de Vibrações. 2. *Machine Learning*. I. Universidade Federal de Santa Catarina. II. Faculdade de Engenharia Elétrica.

JOÃO VICTOR TONELLO RIBEIRO

APRENDIZAGEM DE MÁQUINA APLICADA À
DETECÇÃO DE FALHAS DE ACOPLAMENTO DE
ACELERÔMETROS NO CONTEXTO DE GERAÇÃO
EÓLICA

**Trabalho de Conclusão de Curso sub-
metido à Universidade Federal de
Santa Catarina, como requisito neces-
sário para obtenção do grau de Bacha-
rel em Engenharia Elétrica**

Florianópolis, abril de 2022

UNIVERSIDADE FEDERAL DE SANTA CATARINA

João Victor Tonello Ribeiro

Este trabalho foi julgado adequado como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica e aprovado, em sua forma final, pela Banca Examinadora

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

Banca Examinadora:

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

Prof. Dr. Richard Demo Souza
Universidade Federal de Santa Catarina

Tiago Kaoru Matsuo
AQTech Power Prognostics

Florianópolis, 14 de abril de 2022

Agradecimentos

Primeiramente agradeço a minha família, em especial meu pai e minha mãe, por estarem sempre presentes e dispostos a apoiar e motivar meus estudos e trabalho ao longo de toda minha trajetória pessoal e profissional.

Agradeço aos meus professores, e em especial meu orientador, Eduardo Luiz Ortiz Batista, por compartilharem toda sua experiência e conhecimento, tornando possível o desenvolvimento do presente trabalho.

Agradeço aos meus amigos, pela troca de experiências, conversas e debates, acadêmicos ou não.

Agradeço à AQTech Engenharia e a todos os colaboradores que contribuíram para a construção deste trabalho, sempre dispostos e prestativos sanando dúvidas, sugerindo melhorias, ou até mesmo disponibilizando ferramentas.

*"Quo me cumque rapit tempestas,
deferor hospes."
(Quinto Horácio Flaco)*

*"Se eu vi mais longe, foi por estar
sobre ombros de gigantes."
(Isaac Newton)*

Resumo

Com o crescimento exponencial da demanda por energia elétrica e busca por fontes de energia renováveis, destaca-se o crescimento da instalação de plantas eólicas no Brasil e no mundo. Com isso, surge uma grande necessidade de garantia de geração e o diagnóstico e prognóstico de falhas em aerogeradores, muitas vezes realizados através da análise de vibrações. Para atestar a qualidade da análise de vibrações, é fundamental que os sensores estejam funcionando perfeitamente, diminuindo assim a chance de inserir anomalias nos sinais à serem analisado. Nesse contexto, emerge a importância do presente trabalho, que objetiva detectar falhas no acoplamento de acelerômetros por meio de técnicas de aprendizado de máquina.

Palavras-chave: Energia eólica, aerogeradores, análise de vibrações, acelerômetros, aprendizado de máquina.

Abstract

With the exponential growth in the demand for power and the search for renewable energy sources, the growth in the installation of wind power plants in Brazil and around the world stands out. Thus, there is a need to guarantee generation and the diagnosis and prognosis of failures in wind turbines, often carried out through vibration analysis. To attest the quality of the vibration analysis, it is essential that the sensors are working perfectly, thus reducing the chance of inserting anomalies in the signals to be analyzed. In this context, the importance of this work emerges, which aims to detect failures in accelerometer coupling through machine learning techniques.

Keywords: Wind turbines, vibration analysis, accelerometer, machine learning.

Lista de ilustrações

Figura 1 – Total anual de gases emitidos por atividades antropogênicas entre 1970 e 2010.	22
Figura 2 – Contribuição na emissão de gases de efeito estufa, por setor.	23
Figura 3 – Esquema básico de funcionamento de um aerogerador.	24
Figura 4 – Gearbox Hansen	26
Figura 5 – Partes de um Aerogerador.	27
Figura 6 – Relação entre custo e número de falhas.	28
Figura 7 – Relação entre tempo e saúde da máquina.	29
Figura 8 – Resposta em frequência de um sensor Piezoelétrico.	30
Figura 9 – Modelagem eletrônica de um sensor Piezoelétrico.	31
Figura 10 – Vibração do HSS ao longo do tempo	32
Figura 11 – Arquitetura básica de um sistema de <i>machine learning</i>	33
Figura 12 – Relação de duas <i>features</i> genéricas	35
Figura 13 – Componentes ortogonais do PCA	35
Figura 14 – Esquema de exemplo de operação - <i>Random Forest</i>	36
Figura 15 – VibraOne.	39
Figura 16 – Software Visualização.	39
Figura 17 – Sensor Piezoelétrico.	40
Figura 18 – Shaker 9100D.	41
Figura 19 – Esquemático setup de medidas - shaker.	42
Figura 20 – Setup utilizado para realização de medidas com o shaker.	43
Figura 21 – Bancada de simulações.	44
Figura 22 – Esquema do setup utilizado com a bancada de simulações.	44
Figura 23 – Setup utilizado com a bancada de simulações.	45
Figura 24 – VibraOne utilizado.	45
Figura 25 – Sinal temporal à 1g/ 50Hz	47
Figura 26 – Espectro do sinal à 1g/ 50Hz	48
Figura 27 – Sinal bruto à 1g/ 50Hz - sensor frouxo	48
Figura 28 – Período do sinal bruto a 1 g/50 Hz	49
Figura 29 – Espectro do sinal à 1 g/ 50 Hz - sensor frouxo	49
Figura 30 – Sinal bruto à 2 g/ 50 Hz - sensor frouxo	50
Figura 31 – Espectro do sinal à 2 g/ 50 Hz - sensor frouxo	50
Figura 32 – Sensores acoplados a bancada e entradas analógicas correspondentes	51
Figura 33 – Sinal temporal do acelerômetro acoplado com torque nominal ao mancal de rolamento da bancada.	52

Figura 34 – Sinal temporal do acelerômetro frouxo ao mancal de rolamento da bancada.	53
Figura 35 – Espectro do sinal do acelerômetro acoplado com torque nominal ao mancal de rolamento da bancada.	53
Figura 36 – Espectro do sinal do acelerômetro frouxo acoplado ao mancal de rolamento da bancada.	53
Figura 37 – Relevância de <i>features</i> utilizando XGBoost	56
Figura 38 – Acurácia do <i>Random Forest</i> com a utilização de <i>features</i>	57
Figura 39 – Relação entre as componentes resultantes do PCA	58
Figura 40 – Acurácia do <i>Random Forest</i> com a utilização de componentes do PCA	59
Figura 41 – Diagrama de blocos do <i>pipeline</i> de utilização do método proposto.	60

Sumário

1	INTRODUÇÃO	19
1.1	Objetivo	21
1.1.1	Objetivo Geral	21
1.1.2	Objetivos Específicos	21
1.2	Organização	21
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	Geração Eólica de Energia	22
2.1.1	Princípio de funcionamento	23
2.2	O Aerogerador	24
2.2.1	Gearbox	25
2.3	Análise de Vibrações em Aerogeradores	27
2.3.1	Sensores para Análise de Vibração	29
2.3.1.1	Sensores Piezoelétricos	30
2.3.2	Impacto da Condição de Sensores	32
2.4	Aprendizado de Máquina para Análise de dados	33
2.4.1	Engenharia de <i>Features</i>	34
2.4.1.1	<i>Principal Component Analysis</i>	34
2.4.2	Classificadores	36
2.4.2.1	Random Forest	36
3	DESENVOLVIMENTO	38
3.1	Setup Utilizado	38
3.1.1	Hardware	38
3.1.2	Software	39
3.1.3	Sensor	40
3.2	Ensaio com Shaker	41
3.2.1	Shaker	41
3.2.2	Testes propostos	41
3.3	Ensaio em Bancada	42
3.3.1	Funcionamento da Bancada	43
3.3.2	Testes propostos	44
4	RESULTADOS OBTIDOS	47
4.1	Resultados com Shaker	47
4.1.1	Torque Nominal	47

4.1.2	Torque Abaixo do nominal	48
4.2	Resultados em Bancada	51
4.2.1	Análise de Registros	51
4.3	Processamento dos Dados	54
4.3.1	Relevância de <i>Features</i>	55
4.3.2	<i>Random Forest</i> utilizando <i>features</i> mais relevantes	56
4.3.3	Utilização de PCA para redução de dimensionalidade	57
5	CONCLUSÃO	61
5.1	Resultados Obtidos	61
5.2	Trabalhos Futuros	62
	REFERÊNCIAS	63

1 Introdução

Com o aumento da população e da utilização de aparelhos e equipamentos elétricos e eletrônicos, a demanda, produção e transmissão energética tiveram um crescimento significativo em escala global nos últimos anos [British Petroleum Company 2021]. Nesse contexto, é indispensável a garantia da operação e bom funcionamento das unidades geradoras responsáveis por gerar a energia elétrica necessária, visando suprir essa demanda crescente com qualidade.

Porém, com o crescimento da demanda e produção energética, também aumentam os recursos necessários para a operação e manutenção. Aliado a isso, existe a preocupação com o impacto ambiental da geração de energia, como a necessidade de áreas alagadas para a geração hidrelétrica, ou a emissão de poluentes na queima de gás natural e carvão para geração termelétrica, esta última tendo impacto em questões críticas para o ser humano como o aquecimento global.

Assim, tem-se em mente a utilização de formas de geração de energia renováveis, e que diminuam o impacto causado no ambiente e, indiretamente, na humanidade [Bhattacharya et al. 2016]. Deste modo, vê-se o crescimento da utilização de métodos que não requerem a queima de combustíveis fósseis ou que tenham um impacto muito grande sobre a fauna e flora das regiões afetadas. Dentre esses métodos, a transformação da energia cinética do vento em energia elétrica, conhecida como geração eólica de energia, tem tido o maior crescimento em termos de potência instalada dentre todas as alternativas disponíveis [Joyce Lee, Feng Zhao 2021].

A geração eólica de energia é feita por meio da instalação de aerogeradores, que utilizam pás para captar a energia cinética do vento e convertê-la em energia elétrica, através da excitação de um gerador, encontrado dentro da *nacelle*¹. O aerogerador é uma máquina complexa, com diversas interações mecânicas entre eixos e engrenagens, sendo suscetível a desgastes e falhas.

Além da complexidade intrínseca de construção dos aerogeradores, outros fatores contribuem para uma maior degradação deste tipo de unidade geradora, como a exposição a condições climáticas diversas, tais como ventos intensos, calor excessivo, chuvas e descargas atmosféricas, além da constante variação de carga à ser suportada pela máquina, que depende de variáveis naturais que podem ser modeladas por processos estocásticos. Com isso, o investimento em diminuir custos de operação e otimizar a processos de manutenção se torna essencial para garantir que a geração eólica confiável, tendo a garantia que a demanda será suprida, bem como viável economicamente para os investidores.

¹ Cabine que se encontra no topo da torre e abriga outras várias partes do aerogerador

Nesse contexto, observa-se a necessidade de instalação de sistemas específicos para o monitoramento das máquinas envolvidas na geração eólica, buscando dar ao responsável por plantas e complexos geradores as informações necessárias para a tomada de decisão ótima no que diz respeito à manutenção destes ativos, levando em consideração vários aspectos. Dentre tais aspectos, podemos destacar o *down time* da máquina para determinado tipo de reparo, custos e a possibilidade de uma piora do quadro de saúde da máquina, podendo assim acarretar em um aumento dos custos previstos e de tempo sem geração.

Existem muitas variáveis em um aerogerador que podem ser monitoradas à fim de identificar anomalias na operação da unidade geradora, dentre elas, a análise de óleo, análise de vibrações, temperatura, ruído acústico, fuga de corrente nos componentes, dentre outras. Porém, algumas delas são mais interessantes, tendo em vista que conseguem detectar certos problemas muito antes que os demais indicadores, sendo esse o caso da análise de vibração [Tchakoua et al. 2014].

No caso de análise de vibrações, são utilizados sensores indutivos, acelerômetros e proximímetros para a aquisição dos dados de interesse, bem como das variáveis de operação da máquina, como rotação, potência ativa e velocidade do vento à que a máquina está submetida. Com essas informações, é possível a utilização de técnicas de processamento de sinais para detecção de anomalias no espectro dos sinais obtidos, podendo assim identificar possíveis desgastes e não conformidades que podem vir a se tornar problemas maiores no futuro. Porém, para que essa análise possa ser realizada de forma consistente e confiável, é preciso verificar alguns aspectos contrutivos da máquina, bem como do componente específico à ser analisado, como frequências naturais e de engrenamento, frequência de rotação de eixos e engrenagens, dentre outras.

Para garantir que o sistema de monitoração forneça os dados com confiança e fiéis à realidade, para que a tomada de decisão seja a mais assertiva possível, também é preciso monitorar a condição de operação dos sensores utilizados na captura dos dados de interesse. Assim, surge a motivação do presente trabalho.

A fim de providenciar a garantia necessária da boa operação dos sensores, serão realizados testes em bancadas com excitações e sistemas conhecidos e controlados, buscando analisar os impactos de inconformidades da instalação dos sensores nos sinais obtidos. Além disso, será utilizada uma bancada de testes buscando aproximar-se da realidade de operação dos sensores utilizados, sanando dúvidas sobre a confiabilidade dos dados e economizando recursos ao dispensar verificações presenciais dos sensores em questão.

1.1 Objetivo

1.1.1 Objetivo Geral

Verificar o impacto de anomalias na instalação de acelerômetros no monitoramento da condição de aerogeradores, analisados sinais de vibração obtidos através de instrumentos específicos a fim de discernir possíveis falhas de acoplamento dos sensores em unidade geradoras.

1.1.2 Objetivos Específicos

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

- Pesquisar sobre a análise de vibrações e a utilização de acelerômetros;
- Realizar um levantamento dos principais impactos de anomalias na instalação e fabricação de sensores nos dados obtidos através do mesmo;
- Realizar testes em bancada, simulando não conformidades em sensores, analisando e documentando os resultados obtidos;
- Esboçar modelo para detecção de falhas no acoplamento de acelerômetros.

1.2 Organização

O presente trabalho está organizado da seguinte forma:

Capítulo 2: Fundamentação teórica sobre processamento digital de sinais, análise de vibrações e utilização de acelerômetros para o diagnóstico e prognóstico de aerogeradores.

Capítulo 3: Testes de acelerômetros em laboratório utilizando um *Shaker* e uma bancada de simulações a fim de analisar o impacto da instalação de acelerômetros nos sinais obtidos.

Capítulo 4: Apresentação dos resultados obtidos e emprego de técnicas de aprendizado de máquina para detecção de falhas no acoplamento dos sensores.

Capítulo 5: Conclusão e proposição de trabalhos futuros para aperfeiçoamento das análises apresentadas.


2 Fundamentação Teórica

2.1 Geração Eólica de Energia

Sem dúvida, um dos maiores problemas a ser enfrentado pela humanidade atualmente é o aquecimento global, resultado de décadas de utilização de usinas termoeletricas para a geração de energia, além de diversas atividades industriais e meios de transporte. Este método de geração de energia resulta na emissão diversos gases que contribuem para o chamado efeito estufa, sendo o dióxido de carbono, derivado da queima de combustíveis fósseis, um dos principais causadores do efeito supracitado.

As emissões de gás carbônico pela queima de combustíveis fósseis e atividades industriais representam uma contribuição de 78% do total de gases emitidos pelo ser humano entre os anos de 1970 e 2000, porcentagem similar à encontrada no período entre 2000 e 2010 segundo dados do [Masson-Delmotte V. e (eds.) 2021]. Ainda assim, apesar de diversas políticas que visam limitar a utilização de combustíveis fósseis, diversos estudos mostram que a emissão de gases que contribuem para o efeito estufa continua a crescer [Masson-Delmotte V. e (eds.) 2021].


Figura 1 – Total anual de gases emitidos por atividades antropogênicas entre 1970 e 2010.



Fonte: [Masson-Delmotte V. e (eds.) 2021]

Dentro das informações apresentadas, a área de geração de energia representa 25% dos gases emitidos, sendo assim um dos principais agentes responsáveis pela crescente emissão de gases de efeito estufa.

Figura 2 – Contribuição na emissão de gases de efeito estufa, por setor.



Fonte: [Masson-Delmotte V. e (eds.) 2021]

Nesse contexto, faz-se necessário para o ser humano recorrer a fontes de geração de energia renováveis, e que possuam baixo impacto ambiental nas áreas que sejam instaladas. Dentre as diferentes formas de geração disponíveis, a energia eólica tem se destacado nos últimos anos. Esse tipo de geração de energia é considerado renovável pois depende de um recurso "infinito", tendo em vista que utiliza apenas o movimento do ar que é gerado pela diferença de pressão atmosférica em determinadas partes do planeta. Além disso, a geração eólica não emite diretamente nenhum gás que contribui para o efeito estufa, tornando-a um excelente substituto às formas de geração de energia que consomem combustíveis fósseis.

Apesar do que foi mencionado, ainda existem desafios importantes para uma maior adoção da geração eólica. Normalmente, os parques eólicos são construídos em locais com grande incidência de ventos intensos que geralmente ficam longe dos potenciais consumidores, exigindo a construção de linhas de transmissão para transportar a energia gerada. Além disso, os aerogeradores causam poluição sonora em seus arredores, bem como têm um pequeno impacto em certas espécies de aves migratórias.

2.1.1 Princípio de funcionamento

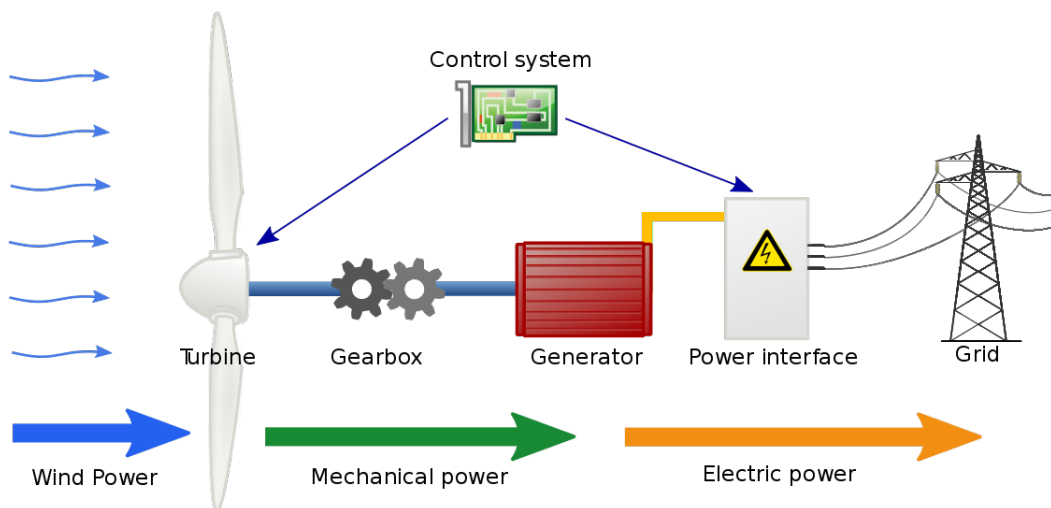
A energia eólica consiste na conversão da energia cinética do vento em energia elétrica, através da utilização de unidades geradoras denominadas aerogeradores, que possuem grandes pás no topo de uma torre e são construídas de forma que a maior quantidade possível de energia seja convertida. Esta é uma das formas de obtenção de

energia mais antigas da humanidade, e recebe esse nome em homenagem ao deus grego Éolo, guardião dos ventos.

Então, no início do processo, a energia cinética do vento é convertida em energia mecânica, representada pela rotação das pás do aerogerador. Esse torque, por sua vez, é transferido a um eixo do aerogerador que está conectado a um sistema de engrenagens chamado *gearbox*, também conhecida como caixa multiplicadora. Esse sistema existe para aumentar a velocidade de rotação do eixo conectado ao gerador, aumentando assim a energia gerada. Finalmente, a energia mecânica do eixo é transformada em energia elétrica por um gerador que se encontra dentro da nacela. Após esse processo, a energia gerada é transformada através de inversores e transformadores para que possa ser injetada na rede elétrica, e assim ser disponibilizada aos usuários da mesma.

O montante de energia elétrica gerada por um aerogerador depende de diversos fatores, como a intensidade e constância dos ventos, tamanho do aerogerador e área de cobertura das pás, por exemplo. Além disso, diversos aerogeradores já contam com sistemas de controle integrados para otimizar a produção de energia, utilizando sensores de direção e velocidade do vento para movimentar a nacela de forma que o ângulo de incidência do vento seja sempre o mais preciso em termos de conversão de energia.

Figura 3 – Esquema básico de funcionamento de um aerogerador.



Fonte: [Electricity 2022]

2.2 O Aerogerador

Nesta seção, serão discutidos com mais profundidade as partes que compõem um aerogerador, qual é o seu papel e as principais partes de interesse para a análise de vibração em uma unidade geradora como essa.

Atualmente, existem diversos tipos diferentes de aerogeradores, cada um com suas particularidades em termos de fabricação. Basicamente, podemos classificá-los em dois tipos: os de eixo horizontal e os de eixo vertical. Neste trabalho, será dado enfoque nos aerogeradores com eixo horizontal de três pás, por serem os mais utilizados no mundo todo, além de terem uma maior eficiência, o que acaba compensando seu custo mais elevado.

Um aerogerador de eixo horizontal normalmente é composto por algumas partes principais, sendo elas:

- **Pás:** As pás são as responsáveis por captar a energia do vento e transferi-la em forma de energia mecânica ao rotor do aerogerador. São projetadas de forma que a conversão de energia seja ótima através de modelos de mecânica dos fluidos, podendo também ser rotacionadas a fim de melhorar a eficiência.
- **Rotor:** O rotor é o ponto onde as pás são fixadas ao aerogerador e conectadas ao eixo de baixa velocidade.
- **Torre:** Elemento de sustentação da nacela e dos demais componentes do aerogerador. Pode ser constituída de aço ou concreto.
- **Gerador:** Gerador elétrico, capaz de transformar energia mecânica (rotação) em energia elétrica através da lei de Faraday.
- **Nacela:** A nacela é o gabinete que contém as demais partes do aerogerador, sendo fixada no topo da torre e também ao rotor da unidade geradora.
- **Gearbox:** Também conhecida como caixa multiplicadora, contém engrenagens responsáveis por converter o torque da rotação do eixo em velocidade.

2.2.1 Gearbox


No contexto de análise de vibrações para o diagnóstico e prognóstico de máquinas elétricas, a *gearbox* exerce um papel fundamental, tendo em vista a vasta quantidade de elementos mecânicos presentes nesse componente. Sua principal função é a transformação de torque em velocidade da potência mecânica absorvida pelas pás do aerogerador. Isso é realizado através de jogos de engrenagens, separados em diferentes eixos, sendo que os pontos de engrenamento se dão entre a coroa (engrenagem com maior número de dentes e menor frequência de rotação) e o pinhão (engrenagem com o menor número de dentes e maior frequência de rotação).

Essa transformação de torque em velocidade tem como principal objetivo aumentar o montante de energia gerado pelo gerador acoplado ao eixo, tendo em vista que, normalmente, a velocidade de rotação das pás de uma unidade geradora eólica é relativamente baixa.

Existem diversos fabricantes de *gearbox* e seus aspectos construtivos variam dependendo do projeto e aplicação específica para cada equipamento. Porém, normalmente os eixos de uma *gearbox* são separados em quatro partes:

- **Planetárias:** sistema de engrenagens que acopla o mancal principal aos eixos da *gearbox*, iniciando o processo de transformação de torque em velocidade.
- **LSS:** o *low speed shaft*, ou eixo de baixa velocidade, é conectado ao eixo do mancal principal através de um sistema de engrenagens planetárias.
- **IMS:** o *intermediate shaft*, ou eixo intermediário, é o eixo que acopla o eixo de baixa velocidade ao eixo de alta velocidade, servindo tendo valores médios de torque e velocidade.
- **HSS:** o *high speed shaft*, ou eixo de alta velocidade, é o eixo que acopla o eixo intermediário ao eixo que é conectado ao gerado, componente que efetivamente realiza a geração de energia elétrica.

Figura 4 – Gearbox Hansen




Fonte: [Lv e Zhao 2013] (adaptado)

Assim, todos os eixos e engrenagens existentes na *gearbox* podem ser encarados como possíveis fontes de problemas mecânicos que podem acarretar em sérios defeitos em um aerogerador. Por isso, todas essas engrenagens devem ser devidamente sensoriadas para que tais problemas possam ser descobertos com antecedência.

Além das partes citadas, o aerogerador também conta com várias outros componentes, como sistemas de lubrificação, sistemas eletrônicos de controle e sistemas de sensoriamento de velocidade e direção do vento.

Figura 5 – Partes de um Aerogerador.



Fonte: [Parker Hannifin , 2018]


2.3 Análise de Vibrações em Aerogeradores

A partir do crescimento exponencial da utilização da energia eólica em busca de uma matriz energética mais sustentável e de menor impacto, surge a necessidade de garantir o bom funcionamento e a constância de geração dos aerogeradores. Assim, torna-se imprescindível o uso de sistemas de monitoramento em unidades geradoras. Esse tipo de sistema é muito útil principalmente pelo impacto positivo na viabilidade econômica do empreendimento.

Apesar de requerer um investimento inicial significativo, a instalação de um sistema de monitoramento em aerogeradores acaba retornando o investimento feito pelo operador na forma de prevenção de possíveis falhas na unidade geradora. Além da prevenção de falhas, a detecção precoce de problemas no aerogerador é de suma importância, tendo em vista que o custo de reparo cresce com o passar do tempo. Além disso, o problema pode piorar ou se alastrar para demais partes do sistema. Assim, uma combinação de manutenção preventiva e reativa gera uma melhora significativa na disponibilidade do aerogerador, bem como traz uma boa redução de custo em termos de manutenção [Walford 2006].

Determinada a validade e necessidade dos sistemas de monitoramento para diagnóstico e prognóstico de aerogeradores, cabe agora definir qual o melhor método para a avaliação dos indicadores de saúde da máquina. Um dos métodos mais conhecidos para a realização de análise de máquinas deste tipo é a análise de vibrações, que se encontra bem

Figura 6 – Relação entre custo e número de falhas.



Fonte: [Tchakoua et al. 2014]


estabelecida nesse meio. Dentre os motivos, está a capacidade de detectar falhas em um estágio inicial, antes que métodos alternativos como análise de óleo e análise de calor, por exemplo [Madsen 2011].

O monitoramento de aerogeradores via análise de vibrações é dado por meio de sensores acoplados em diversas partes da máquina, a fim de obter dados de vibração de mancais ou rolamentos específicos. São de maior valor os sinais advindos de componentes que mais contribuam com o possível surgimento de falhas, como é o caso da *gearbox*, por ser ela munida de diversas engrenagens e pontos de contato e esforço.

As análises de vibrações de aerogeradores são orientadas pela norma ISO 10816-21:2015 [ISO10816-21 2015] que dita informações importantes nesse tipo de análise, indicando quais são os limites aceitáveis de vibração para cada componente específico do aerogerador, seja ele *gearbox*, gerador ou mancal principal. Além disso, a norma também explicita a localização de fixação dos sensores para monitorar determinado componente.

Nessas condições, é importante notar que é necessária a utilização de *software* e *hardware* adicionais para a aquisição e processamento dos dados advindos dos sensores, o que pode aumentar o custo de implementação do sistema. Além disso, a análise de sinais de baixas frequências é dificultada neste método de monitoramento [Hameed et al. 2009]. Porém, com ferramentas adicionais, é possível manipular os sinais obtidos de forma a extrair informações mais precisas e coerentes com o intuito inicial de detectar e prever possíveis falhas de operação.

Figura 7 – Relação entre tempo e saúde da máquina.



Fonte: [Tchakoua et al. 2014]

2.3.1 Sensores para Análise de Vibração

O monitoramento de aerogeradores através da análise de vibrações é realizado através da utilização de sensores como os acelerômetros. Um acelerômetro é um sensor eletrônico capaz de medir forças atuantes sobre um objeto, transformando tais forças em um sinal elétrico que possa ser analisado e manipulado.

A força medida é uma grandeza vetorial, podendo ser classificada como estática, a exemplo da força da gravidade que não varia ao longo do tempo, ou dinâmica, como as vibrações geradas por uma máquina rotatória, esta última sendo o tipo de força de interesse em um contexto de monitoramento de ativos.

Agora, a forma de conversão da variação de velocidade para um sinal elétrico varia de acordo com os aspectos construtivos de cada acelerômetro. Assim, vários são os tipos de acelerômetros disponíveis no mercado, cada um projetado para operar em um determinado ambiente. Dentre os vários tipos disponíveis, podemos destacar os sensores capacitivos, que utilizam uma variação de capacitância entre uma massa sísmica e uma placa fixa em resposta a uma aceleração aplicada, os acelerômetros piezoelétricos, que se utilizam do efeito piezoelétrico para detectar forças sobre um componente com tais propriedades e que daremos um maior enfoque no presente trabalho, e mais recentemente, os MEMS (sistemas microeletromecânicos), que possuem um tamanho microscópico e são largamente utilizados em smartphones, por exemplo.


2.3.1.1 Sensores Piezoelétricos

Como citado anteriormente, os sensores piezoelétricos atuam por meio do efeito piezoelétrico, que consiste na capacidade de acumulação de cargas em determinados materiais quando são submetidos a forças externas. Essa acumulação de cargas gera então uma diferença de potencial, que pode ser usada para calcular a força aplicada sobre o dito material.

Os sensores piezoelétricos são largamente utilizados nas mais diversas situações, principalmente por deter algumas vantagens frente à outros tipos de sensores. Dentre elas, podemos citar o baixo módulo de elasticidade de vários materiais com essas características, podendo assim ser robusto o bastante para ser submetido a forças externas sem necessariamente sofrer uma grande deformação, além de possuir uma frequência natural relativamente alta, mantendo uma resposta linear ao longo de uma grande faixa de frequência. Além disso, grande parte dos materiais piezoelétricos não são sensíveis à radiação eletromagnética [Gautschi 2013].

Outro ponto relevante na operação de sensores piezoelétricos é a resposta em frequência. Assim como outros dispositivos, os acelerômetros deste tipo possuem uma banda em que o comportamento dos mesmos pode ser considerado linear, a qual geralmente representa a região de operação do equipamento.

Figura 8 – Resposta em frequência de um sensor Piezoelétrico.




Fonte: [Omeatron 2007]

Um acelerômetro piezoelétrico pode ser considerado uma fonte de tensão associada à um filtro, composto de uma indutância associada em série e um capacitor em resistor em paralelo, além de um capacitor em série com a fonte, representando a alta impedância do sensor em condições de corrente contínua, funcionando como um filtro passa alta. A tensão gerada é proporcional à força aplicada à massa sísmica, que é então transferida ao material com propriedades piezoelétricas [Specialties].

Os materiais piezoelétricos utilizados em sensores comerciais variam e podem ser constituídos de cerâmicas com características piezoelétricas, cristais piezoelétricos, como os cristais de quartzo usados na fabricação de osciladores, além de filmes piezoelétricos. A principal diferença entre as aplicações destes materiais reside na diferença da ordem de grandeza de sensibilidade entre eles. Além disso, os materiais com uma menor sensibilidade, como é o caso dos cristais, tendem a ter uma maior longevidade quando manuseados e utilizados corretamente, enquanto que materiais fabricados, como as cerâmicas, perdem sua sensibilidade ao longo do tempo, sendo especialmente vulneráveis a grandes temperaturas.

Figura 9 – Modelagem eletrônica de um sensor Piezoelétrico.



Fonte: [Omegatron 2007]

Uma representação mais detalhada do sensor deveria levar em conta não linearidades do equipamento, bem como demais aspectos construtivos. Porém, nesse esquema simplificado, podemos atribuir a indutância L_m à massa sísmica e a própria inércia do dispositivo, a capacitância C_e é inversamente proporcional à elasticidade mecânica do sensor, C_0 representa a capacitância estática do sensor e R_i representa a dissipação de energia por vazamento de corrente. Caso houvesse uma carga ligada ao sensor, poderíamos considerar um resistor R_l adicional em paralelo com R_i , aumentando também a frequência de corte do filtro passa-alta [Omer et al. 2014].

Outro aspecto importante a ser abordado são as possíveis técnicas utilizadas para a realização do acoplamento dos sensores. Estes dispositivos podem ser fixos de diversas maneiras, podendo ser utilizadas substâncias adesivas, geralmente utilizada em montagens temporárias, bem como bases magnéticas e parafusos prisioneiros, este último sendo o método de acoplamento abordado no presente trabalho.

Independente da técnica utilizada, é importante que a face do acelerômetro seja posicionada de tal forma que a face sensível esteja perfeitamente alinhada com a superfície a ser analisada. Além disso, no caso da utilização de parafuso prisioneiro para fixação,


também existe um impacto na utilização ou não de óleos de lubrificação na hora da montagem, aspecto esse de grande interesse mas que não será abordado no trabalho para fins de redução de escopo.

2.3.2 Impacto da Condição de Sensores

Para garantir a que as técnicas de análise de dados de vibração resultem em um diagnóstico preciso das unidades geradoras monitoradas, é de suma importância a garantia da boa condição de instalação e operação dos sensores utilizados. Sensores mal instalados ou com defeitos podem gerar resultados inaccurados, sendo possível gerar falsos positivos ao medir valores de vibração maiores que o valores reais, ou mesmo mascarar possíveis problemas das máquinas.

Para ilustrar tal conceito, podemos observar um caso real em que um acelerômetro foi descolado da base que o acoplava ao aerogerador monitorado, cujas medidas de aceleração estão apresentadas na Figura 10. Mesmo ainda gerando dados, é possível observar uma mudança repentina na magnitude de vibração medida pelo sensor em questão. Neste caso, o sensor media a vibração do eixo de alta velocidade (HSS), de um mancal de rolamento.

Figura 10 – Vibração do HSS ao longo do tempo



Fonte: AQTech Power Prognostics

Esse exemplo ilustra com clareza a necessidade da diferenciação de medidas de vibração reais e de medidas geradas através de sensores mal acoplados. Neste caso, em apenas uma análise das amplitudes de vibração obtidas, não seria possível diferenciar uma vibração baixa indicando uma máquina em boas condições de um sensor mal acoplado ou com defeito, mantendo-se as mesmas condições de operação da máquina.

Além das consequências negativas relativas à detecção de possíveis problemas na operação do aerogerador monitorado, os problemas em sensores de monitoramento também impactam os custos de O&M (operação e manutenção). Isso ocorre devido ao fato que,

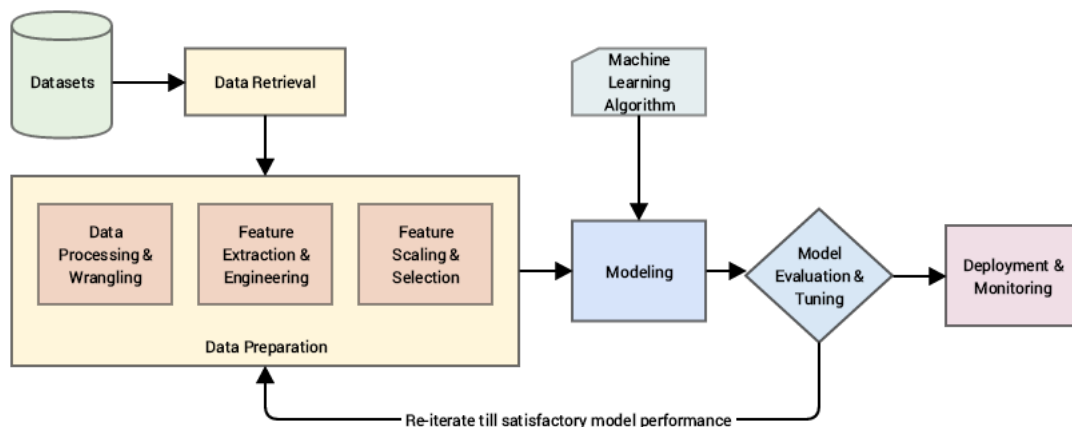
para confirmar um possível problema na montagem ou operação de sensores, é necessário uma inspeção visual no local de instalação, demandando assim recursos como tempo de deslocamento de colaboradores para realizar a inspeção, bem como o custo da energia que não foi gerada pela parada da máquina para inspeção.

Assim, o desenvolvimento de um modelo para detecção automática de falhas em sensores de monitoramento em fases iniciais se torna uma ferramenta de grande valia, tendo em vista que manutenções e correções de tais problemas poderiam ser realizadas de maneira mais assertiva, além de garantir a precisão dos diagnósticos e prognósticos que dependem dos sinais obtidos dos ditos sensores.

2.4 Aprendizado de Máquina para Análise de dados

Tendo em vista a complexidade construtiva de um aerogerador e todos as possíveis fontes de problemas a serem sensoriadas, torna-se imprescindível a utilização de ferramentas matemáticas e computacionais capazes de automatizar a análise dos registros obtidos. Nesse contexto, técnicas de aprendizado de máquina (*machine learning*) tornam-se grandes aliadas no processamento, análise e diagnóstico baseado nos dados obtidos. O aprendizado de máquina consiste na utilização de programas e algoritmos projetados para que se aperfeiçoem no reconhecimento de padrões e em tomada de decisões, baseado nos dados de treinamento disponibilizados. Tais algoritmos já são amplamente utilizados em diversas áreas da engenharia e computação, como em trabalhos de visão computacional, reconhecimento de padrões em grandes volumes de dados, aplicações biomédicas, dentre outras [Naqa e Murphy 2015].

Figura 11 – Arquitetura básica de um sistema de *machine learning*.



Fonte: [Géron 2019]

A utilização de algoritmos de aprendizado de máquina pode auxiliar sistemas de monitoração de vibrações a classificarem os registros obtidos como saudáveis ou não, baseando-se nos valores de vibração considerados aceitáveis e descritos nas normas

que tangem esse tipo de operação, bem como analisar a qualidade e confiabilidade dos mesmos [ISO10816-21 2015].

2.4.1 Engenharia de *Features*

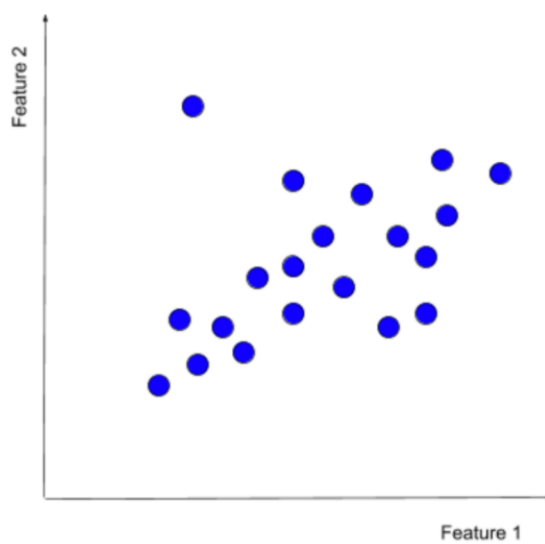
Ao projetar um sistema de *machine learning*, um dos primeiros e mais importantes passos consiste na avaliação e seleção dos indicadores a serem analisados, sendo esses indicadores denominados como *features*, ou características. Com isso, podemos definir a engenharia de features como o processo de utilização de um conhecimento específico para a extração de características relevantes para determinada aplicação [Jalal 2018]. Como apresentado na Figura 14, essas *features* serão utilizadas pelo modelo para que sejam criadas relações entre os valores calculados e as classificações obtidas em um ambiente de treinamento. Assim, temos a engenharia de *features* como parte crucial para o funcionamento correto e confiável de modelos de aprendizado de máquina, sendo a qualidade das features escolhidas diretamente proporcional a acurácia final do sistema projetado.

2.4.1.1 *Principal Component Analysis*

O PCA (Principal Component Analysis) consiste em um algoritmo utilizado em aprendizado de máquina para a redução de dimensionalidade em determinados problemas, resultando na redução do número de *features* utilizadas em uma tarefa de classificação. Nesse sentido, o PCA busca traduzir todas as features apresentadas em um conjunto de dados através de vetores que representem as informações contidas nas características apresentadas. Inicialmente é determinada uma componente principal que represente a variância das *features* apresentadas. Após isso, é gerada um segundo vetor componente ortogonal a primeira componente, buscando abranger o restante da variância das características apresentadas [Chen e Jenkins 2017]. Tais vetores são calculados a partir de um artefato chamado matriz de variâncias, que compreende a variância correspondente às características apresentadas.


Podemos tomar como exemplo um conjunto de duas *features*, contendo diversos valores calculados, conforme ilustrado na Figura 12. Tomando como base esse exemplo, podemos agora verificar como seriam os vetores calculados por um algoritmo de PCA para redução de dimensionalidade, ilustrados na Figura 13. No exemplo exposto, não é possível notar uma grande diferença entre as *features* apresentadas e os resultados do PCA, tendo em vista que ambos são dois vetores de dados que explicitam as características de um objeto de estudo. Porém, em casos onde existe um grande volume de *features*, o algoritmo do PCA é indispensável para redução da complexidade do problema.

Em teoria, o PCA produz um vetor como componente para cada característica apresentada, porém, na prática, apenas a componente principal e um número determinado

Figura 12 – Relação de duas *features* genéricas

Fonte: [Keboola 2020]

Figura 13 – Componentes ortogonais do PCA



Fonte: [Keboola 2020]

de componentes subsequentes são utilizadas, levando assim em consideração grande parte da variância das features originais reduzidas em um baixo número de vetores de dados.

2.4.2 Classificadores

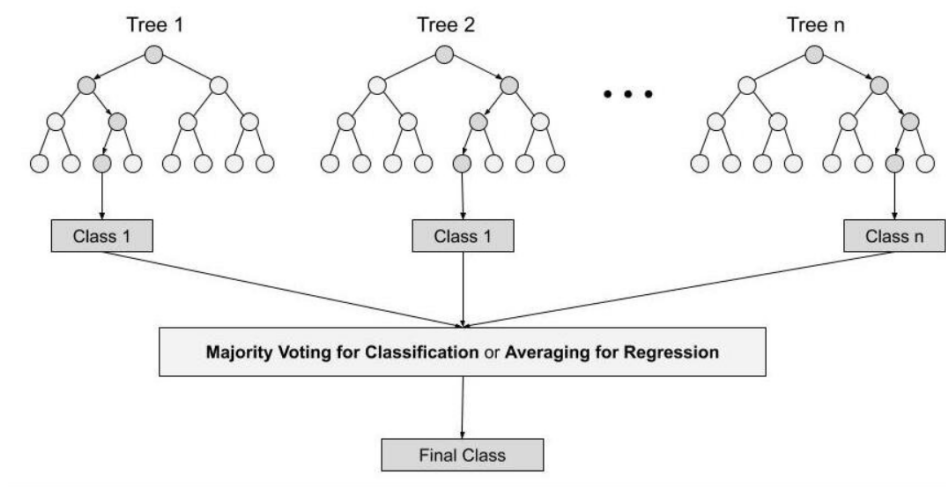
Dentre os diversos tipos de sistemas de *machine learning*, existem várias classificações que podem ser utilizadas para definir o funcionamento de cada um. Dentre as classificações, temos os modelos supervisionados e não-supervisionados, o que se refere a necessidade de treinamento a partir de dados rotulados, e em algoritmos de classificação e regressão, que diz respeito à natureza dos dados previstos (discreto ou contínuo) [Li, Sun e Wu 2010].

Tendo em vista o problema sugerido no presente trabalho, serão usados algoritmos classificadores, buscando classificar registros de sinais entre duas variáveis discretas, representando a condição de operação do sensor em relação ao seu acoplamento. A seguir, será apresentado o algoritmo utilizado.

2.4.2.1 Random Forest

Em resumo, *Random Forest* é um algoritmo de *machine learning* supervisionado, muito utilizado tanto em problemas de classificação como de regressão. Sua operação consiste na construção de árvores de decisão, que classificam os dados usados como parâmetros, a fim de obter uma classificação final baseada na maioria dos resultados advindos das árvores [Ali et al. 2012].

Figura 14 – Esquema de exemplo de operação - *Random Forest*.



Fonte: [Sruthi E R]

O funcionamento de um algoritmo *Random Forest* pode ser descrito em alguns passos que serão demonstrados a seguir, além de uma imagem (Figura 14) para auxiliar na visualização das operações:

1. Um número N de amostras aleatórias é obtida de um registro retirado do conjunto principal de dados que contém um número K de registros.
2. Árvores de decisão individuais são construídos para cada amostra analisada do registro em questão.
3. Cada uma das árvores de decisão irá resultar em uma classificação para o registro.
4. A classificação que constitui maioria será a classificação final do registro.

3 Desenvolvimento

Com o intuito de validar a operação de acelerômetros piezoelétricos usados no monitoramento de aerogeradores, a proposta no presente trabalho foi de realizar diversos ensaios com equipamentos de calibração e posteriormente em ambientes mais próximo da realidade de operação destes equipamentos. Esses ensaios consistem na realização de medidas utilizando os sensores em algumas faixas de frequência pré-selecionadas em condições normais, e então inserir erros de acoplamento, como não utilização do torque nominal na hora de parafusar o sensor na estrutura, objetivando realizar análises e comparações entre os dois casos.

Essas análises se darão em maior parte no domínio da frequência através da utilização de FFT, buscando assim detectar nuances que possam indicar problemas na operação de sensores em situações reais, além de possivelmente mascarar ou indicar falsos-positivos de possíveis falhas em aerogeradores. Estima-se que, com tal conhecimento, seja possível o desenvolvimento de técnicas de detecção de falhas em montagem de sensores automaticamente, economizando recursos consideráveis na manutenção dos aerogeradores monitorados, tendo em vista que não mais serão necessárias inspeções manuais e pausa na operação das unidades geradoras.

Como dito no capítulo anterior, para que seja possível obter os dados advindos de um acelerômetro, é preciso conectá-lo a um *hardware* capaz de interpretar os sinais elétricos gerados pelo dispositivo. Além disso, também é interessante a utilização de *softwares* capazes de apresentar os dados obtidos de uma forma legível, além da possibilidade de realizar operações e cálculos em cima dos mesmos.

Para as medidas realizadas neste trabalho, serão utilizados tanto o *hardware* quanto *softwares* proprietários da empresa AQTech Engenharia e Instrumentação, que gentilmente disponibilizou os equipamentos para que fosse possível a realização dos ensaios.

3.1 Setup Utilizado

3.1.1 Hardware

O hardware utilizado é chamado de VibraOne, e consiste em uma central de processamento de dados com 24 entradas analógicas além de 4 entradas digitais, que realizam a aquisição dos dados advindos do sensor acoplado. O *hardware* também faz a utilização de conversores analógico-digitais de 24 bits. O hardware então, operando em conjunto com os softwares da empresa, processa e apresenta os dados de maneira que podem ser interpretados e manipulados pelo usuário.

Figura 15 – VibraOne.



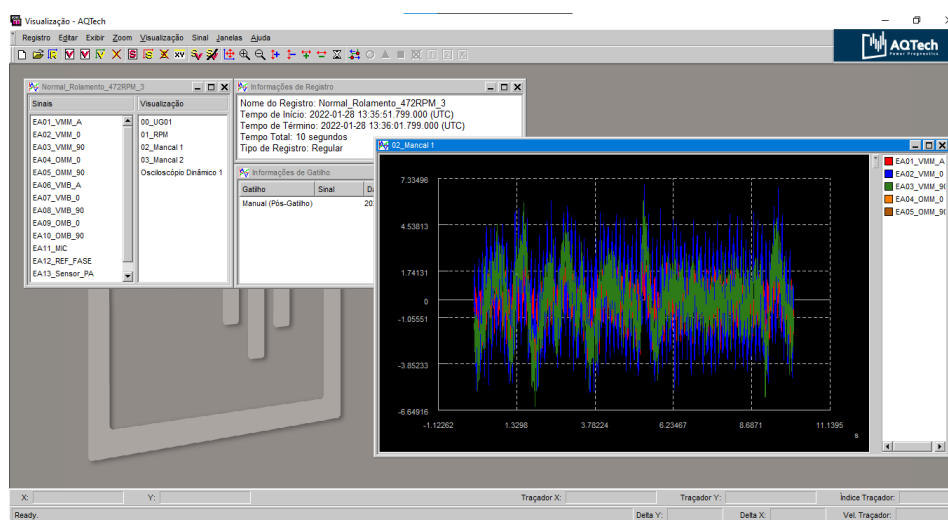
Fonte: [AQTech 2021]

O hardware é carregado com um arquivo de configuração que define parâmetros usados na operação, como a taxa de amostragem, sinais que serão utilizados em determinadas portas digitais ou analógicas, dentre outros. Em nosso caso, o acelerômetro será acoplado em uma das entradas analógicas, sendo amostrado a uma taxa de 20 kHz, buscando aproximar os testes da realidade de operação dos equipamentos.

3.1.2 Software

Operando juntamente com o VibraOne está o software Aquisição, desenvolvido a fim de analisar as leituras realizadas pelo sensor em tempo real, possibilitando a realização de cálculos importantes, também em tempo real, como uma FFT ², por exemplo. Além disso, o *software* também permite o salvamento do registro com os parâmetros determinados pelo usuário (taxa de amostragem, janela de tempo, etc) no formato proprietário .RFX, o qual pode ser aberto para análise e demais operações pelos demais *softwares* da empresa.

Figura 16 – Software Visualização.



Fonte: Do autor.


² Transformada rápida de Fourier

Além do Aquisição, também foram utilizados outros softwares proprietários da empresa, como o Compilador de Registros, Visualização, Navegação e Identificação. Esses *softwares* foram utilizados com a finalidade tanto de gerenciamento quanto para a análise em si dos registros obtidos.

3.1.3 Sensor

Os acelerômetros utilizados para todos os ensaios do presente trabalho são do modelo 601A02, da IEZOELECTRIC ICP® ACCELEROMETERS. Esse sensor pode ser classificado como um acelerômetro piezoelétrico de cisalhamento, ou seja, o cristal de detecção está posicionado entre um pino central e a massa sísmica. Então, um anel de compressão aplica uma força de pré-carga ao conjunto do elemento para garantir uma estrutura rígida e um comportamento linear.

Figura 17 – Sensor Piezoelétrico.



Fonte: [PCB Piezotronics, Inc. 2019]

Dentre as especificações técnicas relevantes deste equipamento, podemos citar a banda de frequência de operação linear, que vai de 0,17 até 10 kHz (tolerância de $\pm 10\%$), sensibilidade de 51 mV/(m/s²) no SI, ou 500 mV/g (tolerância de $\pm 20\%$), e a máxima aceleração suportada, que vai até 10 g, ou 98 m/s².

Também é importante notar que os sensores piezoelétricos utilizados para testes neste trabalho são acelerômetros unidirecionais, ou seja, apenas medem a variação de velocidade em uma direção, sendo essa direção normal a superfície em que o sensor está instalado.

Além dessas informações, também é importante pontuar a frequência de ressonância do dispositivo, sendo essa igual a 16 kHz, como indicado na figura 8. Assim, podemos ter seguranças que todas as medidas realizadas neste trabalho possuem frequências que encontram-se dentro da banda de operação linear do sensor, garantindo que nenhum efeito adicional interfira nos testes realizados.

3.2 Ensaios com Shaker

3.2.1 Shaker

Objetivando identificar os impactos de uma montagem inadequada de um sensor acelerômetro para o monitoramento de máquinas vibratórias, optou-se por iniciar os testes utilizando um Shaker comercial de modelo 9100D, da Modal Shop. Esse instrumento é utilizado justamente para calibração de acelerômetro, gerando um sinal de amplitude e frequência controlados, possibilitando a validação do sensor a ser utilizado.

O shaker 9100D possui um afaixa de operação que vai de 5 Hz até 10 kHz, podendo ser assim utilizado para diversas aplicações, com amplitudes de até 20 g em determinadas frequências. Além disso, o 9100D também disponibiliza uma entrada externa para a injeção de sinais customizados, possibilitando assim a utilização de um gerador de sinais.

Figura 18 – Shaker 9100D.



Fonte: [MTS Systems Corporation 2020]


A amplitude do equipamento é limitada para as frequências mais baixas, como as que serão utilizadas nos testes propostos no presente trabalho. Por isso, serão utilizadas amplitudes pequenas, de forma que seja possível manter um padrão ao longo dos ensaios.

3.2.2 Testes propostos

Para a realização dos testes utilizando o shaker comercial, inicialmente foi acoplado o sensor piezoelétrico na saída do equipamento, usando os sinais nativos do mesmo. Esses sinais são constituídos de senóides em uma frequência e amplitude controlada, fazendo assim

com que a excitação aplicada sobre o sensor seja conhecida. Isso implica no conhecimento do sinal esperado que será processado e lido pelo restante do setup de medidas;

Figura 19 – Esquemático setup de medidas - shaker.



Fonte: Do autor.

Para realização das medidas, o hardware VibraOne foi configurado com diversas informações que impactam na aquisição dos sinais. Dentre elas, está a frequência de amostragem, que foi configurada em 20 kHz, buscando uma proximidade com a realidade de operação destes equipamentos. Além disso, todos os registros obtidos foram salvos no formato .RFX para posteriormente serem processados e submetidos à análises no domínio da frequência.


A definição das frequências e amplitudes dos sinais gerados pelo shaker foram definidas tendo como base a realidade de operação dos sensores acoplados à aerogeradores reais. Assim, tendo em vista que a rotação média de um eixo de alta velocidade de um gerador médio supervisionado por esse sensor é de 30 Hz, foram escolhidos os valores de frequência iguais a 10 Hz, 30 Hz, 50 Hz e 100 Hz, com amplitudes de 1 g e 2 g, quando possível.

As medidas com as frequências e amplitudes mencionadas foram antes realizadas com o sensor em boas condições de operação, com o torque adequado aplicado na montagem, perfeitamente alinhado com a superfície de contato. Depois, o torque foi diminuído em aproximadamente 50%, fazendo com que o dispositivo ficasse frouxo na base, sendo assim submetido tanto ao sinal de vibração gerado pelo shaker quanto à vibração própria com a base. O setup pode ser visualizado na figura 20.

3.3 Ensaios em Bancada

A próxima etapa após a realização dos ensaios utilizando o shaker será realizar novas medidas utilizando uma bancada de ensaios construída sob medida para simular uma máquina rotatória. O *setup* proposto para a realização das medidas será utilizando os mesmos equipamentos que os testes anteriores, tendo em vista que este setup de sensores, hardware e software são utilizados para a aquisição de dados reais de aerogeradores.

Figura 20 – Setup utilizado para realização de medidas com o shaker.



Fonte: Do autor.

A frequência de operação da bancada é limitada pela frequência máxima possível de rotação. Este limite foi determinado como sendo de 900 rpm, resultando em uma frequência de rotação do eixo de 15 Hz.

Além disso, nos testes em bancada, serão utilizados 4 sensores para cada registro gerado. Isso se deve ao fato de que haverá dois acelerômetros piezoelétricos em direções diferentes, sendo um na direção radial em 0° e outro em 90° , também buscando identificar possíveis diferenças no espectro de cada um dos sinais obtidos, tanto quando acoplados de maneira correta quanto com o torque diferente do nominal.

Além dos quatro acelerômetros, será usado um tacômetro óptico para a aquisição do sinal de velocidade de rotação da máquina, a fim de garantir a frequência de rotação proposta.

3.3.1 Funcionamento da Bancada

A bancada de teste em questão, mostrada na Figura 21 consiste de um motor elétrico acoplado a vários módulos, que simulam possíveis defeitos e anomalias em diversos componentes de aerogeradores reais. Estes módulos permitem um certo tipo de personalização, possibilitando a inserção de modos de falha em cada um deles. Ela foi construída objetivando a realização de ensaios que permitam uma melhora na tecnologia e métodos utilizados para a análise da condição das unidades geradoras baseada em vibração, como o presente trabalho. Além disso, também contribui com uma melhora nas técnicas de análise de sinais e busca por falhas em máquinas rotativas através do estudo do espectro obtido

de acelerômetros.

Dentre os módulos disponibilizados estão o motor principal, o módulo principal, que simula um mancal principal de aerogerador, módulos de mancais de rolamento, mancais de deslizamento, acoplamento de engrenagens, dentre outros. Nesses módulos, podemos inserir modos de falhas como desbalanceamentos, desalinhamentos, e demais modos que respeitem as características construtivas da bancada.

Figura 21 – Bancada de simulações.




Fonte: Do autor.

3.3.2 Testes propostos

Como comentado, o setup utilizado para a realização dos testes na bancada de ensaios permanece muito semelhante ao utilizado para os ensaios com o shakers, conforme ilustrado na Figura 22. Os acelerômetros e tacômetro serão acoplados à máquina no módulo que simula o eixo de alta velocidade de um aerogerador (HSS - *High Speed Shaft*), um acelerômetro na posição radial em 0° e outro em 90° .


Figura 22 – Esquema do setup utilizado com a bancada de simulações.



Fonte: Do autor.


Os sensores serão conectados a cinco portas analógicas do VibraOne, possibilitando assim o sensoriamento em tempo real das cinco variáveis de interesse. Após a aquisição, os espectros dos sinais serão analisados buscando detectar as principais características de uma máquina saudável e sensores bem acoplados.

Figura 23 – Setup utilizado com a bancada de simulações.



Fonte: Do autor.

Figura 24 – VibraOne utilizado.



Fonte: Do autor.

Após os primeiros testes utilizando o *setup* apresentado na Figura 23 e na Figura 24, os sensores serão afrouxados para um torque abaixo do nominal, e então as medidas

serão novamente obtidas. Agora, o espectro dos sinais serão analisados e comparados com os sinais obtidos de uma máquina com os sensores devidamente acoplado, buscando características que pudessem dizer ao responsável pela O&M do ativo o estado de operação dos sensores em utilização.

Por último, foram realizados testes com o sensor frouxo, além de um modo de falha de desbalanceamento induzido nos mancais de rolamento em questão, nas mesmas frequências de rotação. Esse teste busca entender quais os impactos de um sensor mal acoplado à máquina em um espectro que possui um modo de falha. Assim, será possível perceber caso essa má instalação possa gerar falsos positivos para modos de falhas diversos ou mascarar modos de falhar que encontram-se na máquina monitorada.

4 Resultados Obtidos


Neste capítulo, serão apresentados os resultados obtidos através das medidas realizadas utilizando o *shaker* e também a bancada de simulações, tanto em situações onde o sensor encontra-se fixo de forma correta quanto em situações com problemas de acoplamento. Além disso, também serão apresentados os resultados das técnicas de processamento de dados utilizadas, abrangendo o cálculo de *features* dos registros adquiridos, utilização de algoritmos de aprendizado de máquina para classificação dos sinais e técnicas de redução de dimensionalidade para redução da complexidade do problema.

4.1 Resultados com Shaker

4.1.1 Torque Nominal

Os resultados obtidos no caso dos ensaios realizados com o sensor preso ao shaker usando o torque nominal de aperto estão apresentados na Figura 25 (domínio do tempo) e Figura 26 (domínio da frequência). Tais resultados encontraram-se dentro do esperado para os sensores acoplados de maneira correta no equipamento. Os sinais no domínio do tempo apresentaram senóides bem comportadas na frequência e amplitudes escolhidas para o sinal gerado pelo shaker, tendo um pico na frequência fundamental e valores praticamente nulos ao longo do restante na banda.

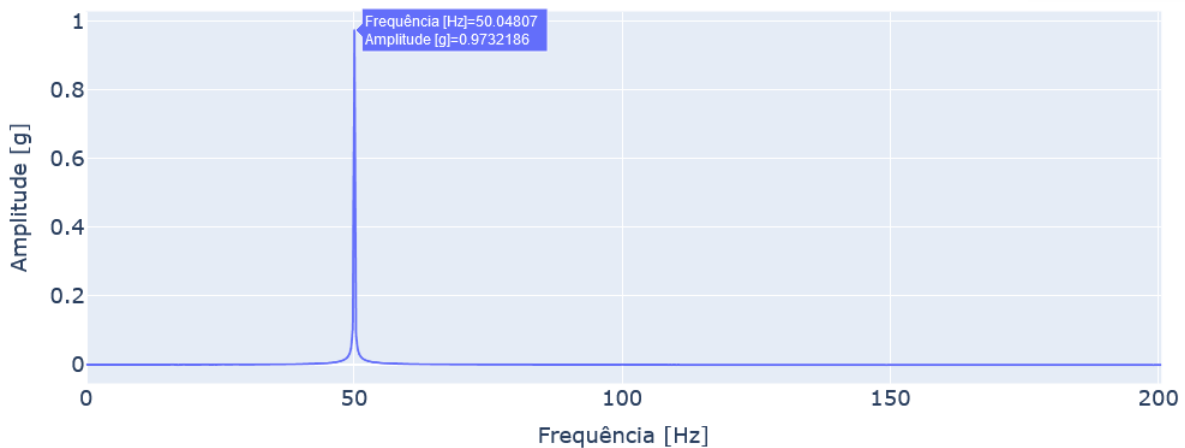
Figura 25 – Sinal temporal à 1g/ 50Hz



Fonte: Do autor.

Tais sinais podem ser usados para fins de referência, servindo como base de comparação com os sinais obtidos quando o sensor não se encontra acoplado com de maneira devida no equipamento. Tanto o sinal bruto quanto a o espectro obtido poderão ser analisados a fim de obter as principais diferenças entre as duas condições de operação.

Figura 26 – Espectro do sinal à 1g/ 50Hz




Fonte: Do autor.

4.1.2 Torque Abaixo do nominal

Entretanto, os sinais obtidos com os sensores frouxos (Figura 27) apresentaram anomalias visíveis tanto na análise temporal quanto na análise espectral. Foi possível identificar, em ambos os casos, as trepidações no sinal causadas pela vibração entre o próprio sensor e a base a qual esta acoplado.

Figura 27 – Sinal bruto à 1g/ 50Hz - sensor frouxo



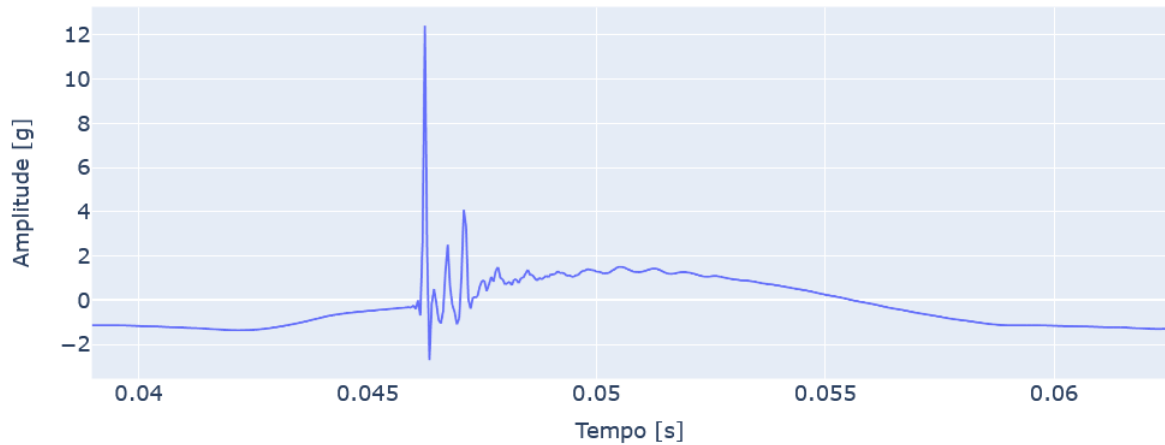
Fonte: Do autor.

Analisando mais minuciosamente os resultados obtidos, iniciando pelo sinal bruto, é possível identificar diversos picos que podem ser visto em um determinado padrão, chegando a até 12 g de amplitude, aparecendo quando a vibração medida se aproxima de zero. Tais picos são acompanhados de uma oscilação da vibração em torno de 0 g, possivelmente gerados pelo movimento do acelerômetro em torno do eixo de acoplamento, sendo possível classificá-los como um trem de impulsos.

Tal comportamento pode ser melhor analisado ao aplicarmos um *zoom* em um período do sinal bruto, conforme apresentado na Figura 28. Nessa figura, podemos verificar

com clareza as oscilações em torno de zero, iniciando no momento em que a vibração medida se aproxima do valor de 0 g.

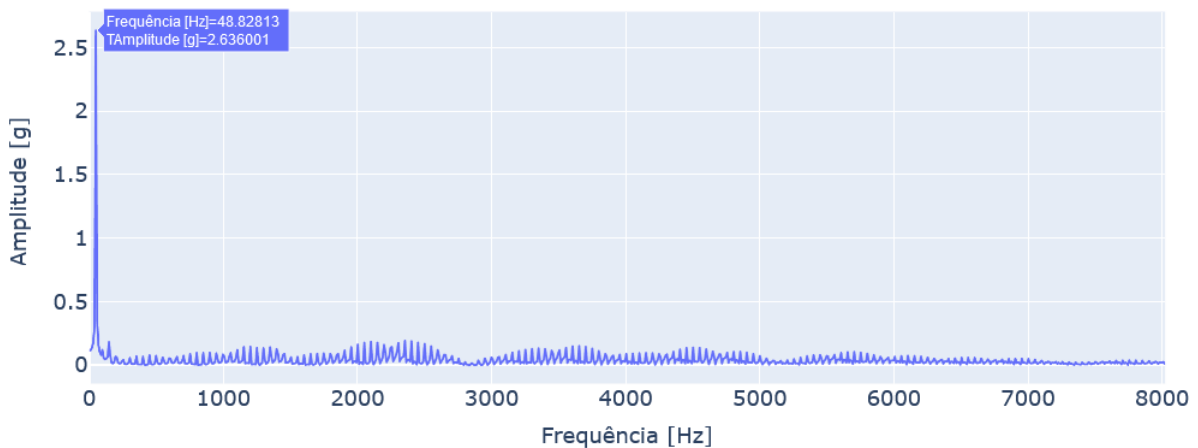
Figura 28 – Período do sinal bruto a 1 g/50 Hz



Fonte: Do autor.

Além disso, plotando o espectro do sinal obtido como na figura 29, é evidente a distribuição de energia ao longo de grande parte do espectro, podendo ser detectadas harmônicas até aproximadamente 9 kHz. Tal característica pode indicar que, possivelmente, algumas características do espectro do sinal podem ser utilizadas para identificação de sensores com problemas de acoplamento.


Figura 29 – Espectro do sinal à 1 g/ 50 Hz - sensor frouxo



Fonte: Do autor.


Além disso, foram realizados testes também em diferentes amplitudes de sinal gerados pelo *shaker*, tanto no domínio do tempo (Figura 30), quanto no domínio da frequência (Figura 31). Nelas, foi possível verificar um acentuamento das características supracitadas. Além de um aumento na amplitude do trem de impulsos no sinal temporal, também houve um aumento nas amplitudes de frequências mais altas do espectro.

Figura 30 – Sinal bruto à 2 g/ 50 Hz - sensor frouxo



Fonte: Do autor.

Figura 31 – Espectro do sinal à 2 g/ 50 Hz - sensor frouxo



Fonte: Do autor.

Como esperado, o aumento da amplitude dos picos encontrados no sinal temporal, que chegam a até 15 g, refletiu em um aumento das amplitudes em altas frequências, mantendo a amplitude na frequência de vibração constante. Tais características poderiam ser facilmente identificadas através de limites de amplitudes e distribuição da energia presente no espectro do sinal, sem a necessidade de utilização de métodos mais elaborados de análise de dados e aprendizado de máquina.

Porém, apesar das análises utilizando o *shaker* mostrarem diferenças expressivas entre os sinais obtidos utilizando sensores com torque nominal e com o sensor frouxo, tais condições estão distantes da realidade da análise de condições de aerogeradores através das análises de vibração, ignorando a inclusão de fatores cruciais para tais análises, como ruídos, interferências de demais componentes da máquina à ser monitorada, entre outros.

Por isso, agora serão apresentados os resultados obtidos através do sensoriamento

da bancada de simulações, buscando aproximar-se das condições reais de análise, além de verificar se os resultados encontrados no shaker podem ser comparados aos resultados das simulações realizadas em bancada.

4.2 Resultados em Bancada


4.2.1 Análise de Registros

Nesta seção, os resultados obtidos através de análise de bancada serão apresentados. Além da análise dos sinais em si, também serão apresentadas as metodologias para o processamento dos dados, objetivando determinar possíveis características que possam ser usadas para detecção das condições de operação dos sensores.

O objeto de estudo foi um dos módulos da bancada, que consiste em dois mancais de rolamento unidos por uma disco de metal. Nesse disco, é possível inserir massas extras, a fim de induzir um desbalanceamento na operação dos mancais.

Como citado anteriormente, o setup utilizado consistirá em 5 sensores acoplados a máquina, sendo 4 deles acelerômetros, e o por último um tacômetro óptico, a fim de controlar a frequência de rotação da máquina. À seguir, na Figura 32, é possível visualizar a instalação dos sensores utilizados, bem como as entradas analógicas do *hardware* correspondentes.

Figura 32 – Sensores acoplados a bancada e entradas analógicas correspondentes



Fonte: Do autor.

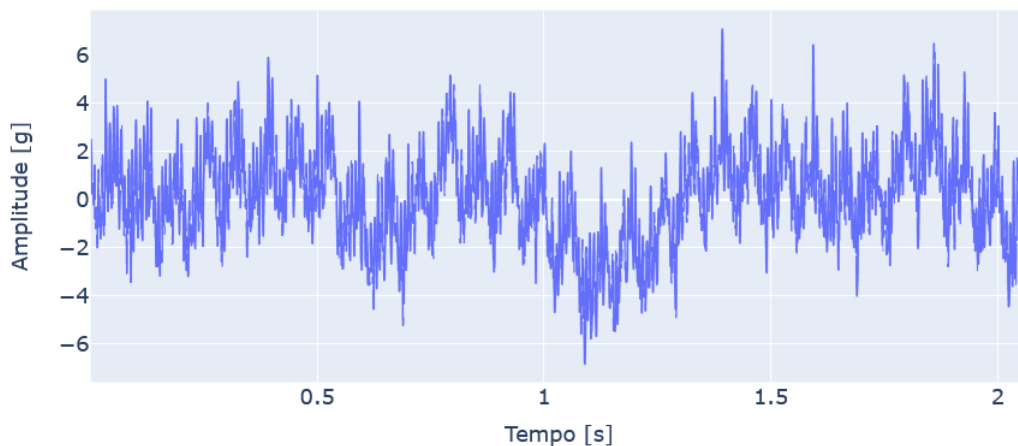
O *hardware* VibraOne foi configurado de forma a levar em consideração a sensibilidade de cada sensor, sendo essas encontradas nas cartas de calibração. Além disso, a configuração levou em conta a entrada do sensor óptico na entrada analógica 01.

Com a máquina operando em 900 rpm, ou 15 Hz, foi dado início à obtenção dos registros de sinal. Cada registro compreende um período de tempo de 10 segundos, a uma taxa de aquisição de 20 kHz. Assim, podemos esperar um espectro que compreende dados até a frequência de 10 kHz.

Os ensaios realizados foram separados em quatro casos diferentes, sendo eles as combinações possíveis entre as condições dos quatro sensores utilizados (fixos/frouxos) e condições da máquina (balanceada/desbalanceada). Para cada caso, foram realizadas 10 medidas em momentos diferentes, a fim de ampliar o número de dados disponíveis para a análise, totalizando 40 registros no total.

A seguir, tomaremos como exemplo medidas obtidas do sensor de entrada analógica 05, sendo esse o acelerômetro acoplado em 90° no primeiro mancal do módulo de mancais de rolamento, inicialmente com o sensor fixo (Figura 33) com o torque nominal e, em seguida, com o sensor frouxo (Figura 34).

Figura 33 – Sinal temporal do acelerômetro acoplado com torque nominal ao mancal de rolamento da bancada.

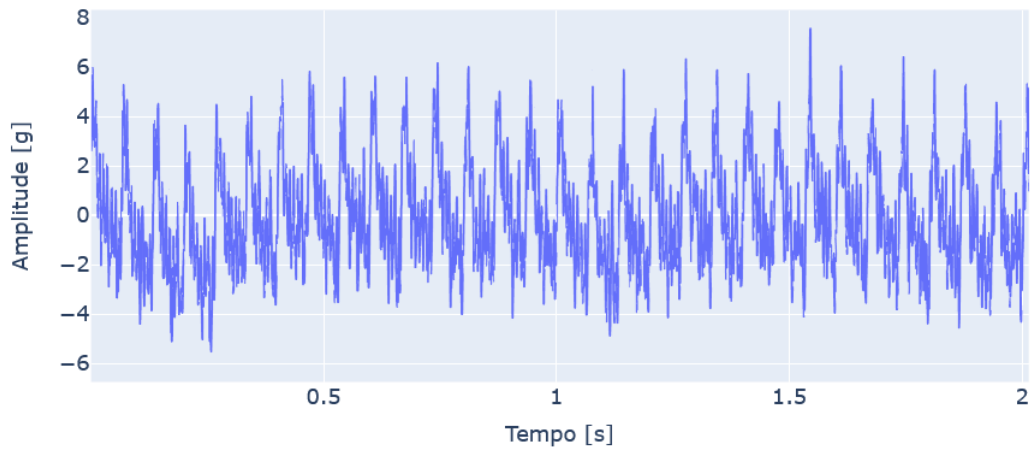


Fonte: Do autor.

Inicialmente, podemos perceber a grande discrepância entre um sinal advindo de uma máquina rotativa em relação aos sinais obtidos através do *shaker*. É possível perceber uma grande quantidade de ruído no sinal, que pode ser advindo do meio e das demais componentes da bancada. Além disso, também é possível perceber algumas diferenças entre os sinais obtidos através de um sensor instalado com torque nominal e com um sensor com problemas de acoplamento.

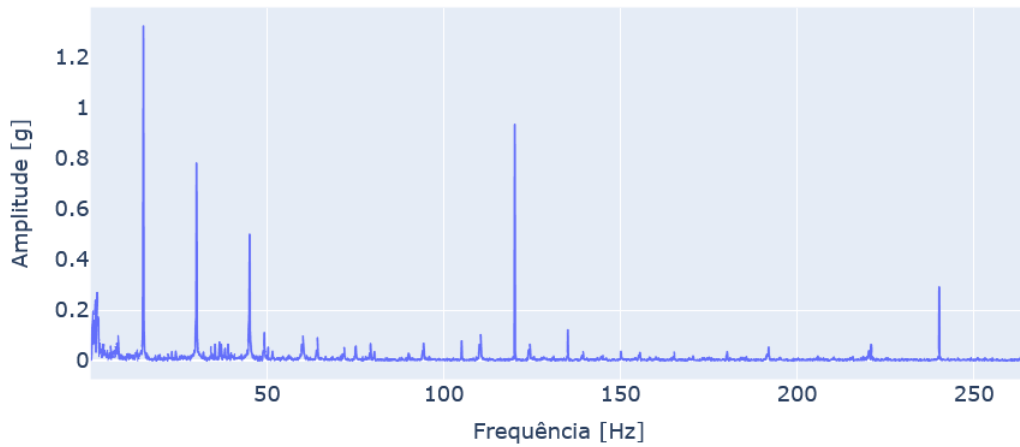
Apesar disso, diferentemente dos ensaios anteriores, não parece ser trivial definir indicadores de amplitude ou outra grandeza que possa indicar problemas na operação dos acelerômetros, indicando que, em casos reais, pode ser necessário a utilização de algoritmos mais elaborados para detecção de tal característica. A seguir, serão apresentados os espectros dos sinais apresentados com o sensor fixo (Figura 35) e com o sensor frouxo (Figura 36).

Figura 34 – Sinal temporal do acelerômetro frouxo ao mancal de rolamento da bancada.



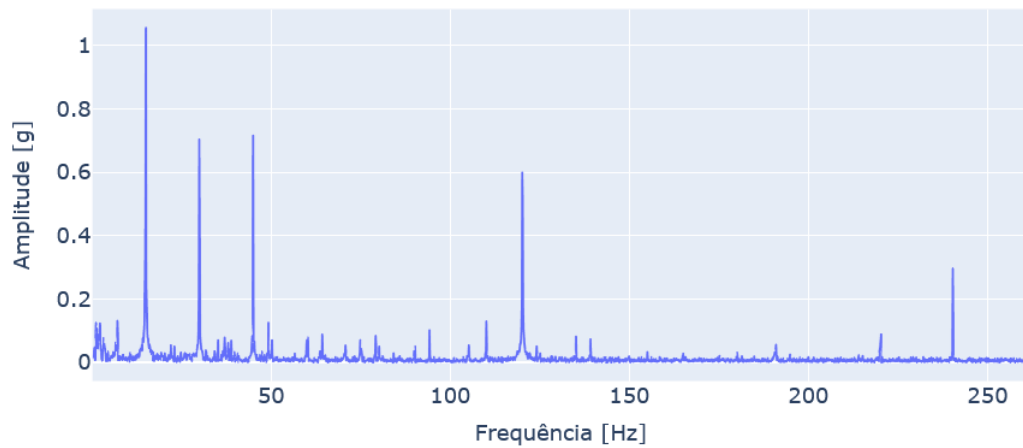
Fonte: Do autor.

Figura 35 – Espectro do sinal do acelerômetro acoplado com torque nominal ao mancal de rolamento da bancada.



Fonte: Do autor.

Figura 36 – Espectro do sinal do acelerômetro frouxo acoplado ao mancal de rolamento da bancada.



Fonte: Do autor.

Tomando como base os espectros apresentados, primeiramente podemos notar diferenças significativas em relação ao espectro dos sinais obtidos através dos ensaios utilizando o *shaker*, fazendo-se necessária a utilização de ferramentas adicionais para a detecção das anomalias do acoplamento de acelerômetros. Mesmo com o sensor acoplado com o torque nominal, estão presentes no espectro diversas componentes além da componente natural de rotação, juntamente com demais harmônicas da mesma. Além disso, é possível notar uma distribuição de energia diferente nos dois casos apresentados, podendo indicar possíveis características úteis para determinação da condição dos sensores.

Apesar disso, uma análise mais minuciosa e detalhada é necessária para garantir que tais indicadores são confiáveis para detecção de falha em sensores, além de assegurar que a diferença entre esses indicadores esta presente sempre que existam problemas nos sensores utilizados, e não estão presente apenas em medidas isoladas.

Para tais análises, serão utilizadas técnicas de processamento de dados e aprendizado de máquina, a fim de buscar indicadores confiáveis e robustos o bastante para garantir a confiança em um possível método de detecção de falhas em acelerômetros.

4.3 Processamento dos Dados

Objetivando extrair características intrínsecas dos sinais obtidos na bancada de simulação relevantes para a detecção de falha em acoplamento de sensores, foi dado início ao processamento dos dados adquiridos. Todas as análises e cálculos foram realizados utilizando o *Google Colab*, plataforma online que permite a compilação de códigos em *Python* utilizando a memória e poder de processamento de servidores da *Google*.

Inicialmente, para a determinação das features à serem utilizadas na detecção, foi empregada uma biblioteca da linguagem *Python* chamada *pyAudioAnalysis* [tyiannak 2021]. Essa biblioteca possui métodos que calculam determinadas características de sinais a partir dos registros brutos, facilitando assim a seleção das *features* mais relevantes para a solução do problema proposto. Devido a janela de tempo utilizada, foram computadas as features de curto prazo. As principais características calculadas pela biblioteca no contexto de análise de vibrações são as seguintes:

- *Zero Cross Rate* - Taxa de cruzamento do sinal em zero;
- Energia total do sinal;
- Entropia da Energia do sinal;
- Entropia Espectral;
- Centroide Espectral;

- Fluxo Espectral;
- *Roll-off* Espectral;
- Relação harmônica;
- Coeficientes das frequências de Mel (sete coeficientes);
- *Chroma-based features* (seis *features*);

Assim, todos os registros disponíveis foram submetidos aos cálculos das características supracitadas, obtendo assim uma matriz de *features* com os valores calculados. Além disso, todas as *features* foram separadas por sensor, obtendo assim um total de 136 características possíveis.

Devido ao grande número de *features*, o próximo passo da análise consiste da obtenção da relevância de cada uma das características calculadas em relação à classificação de sensor fixo e sensor frouxo.

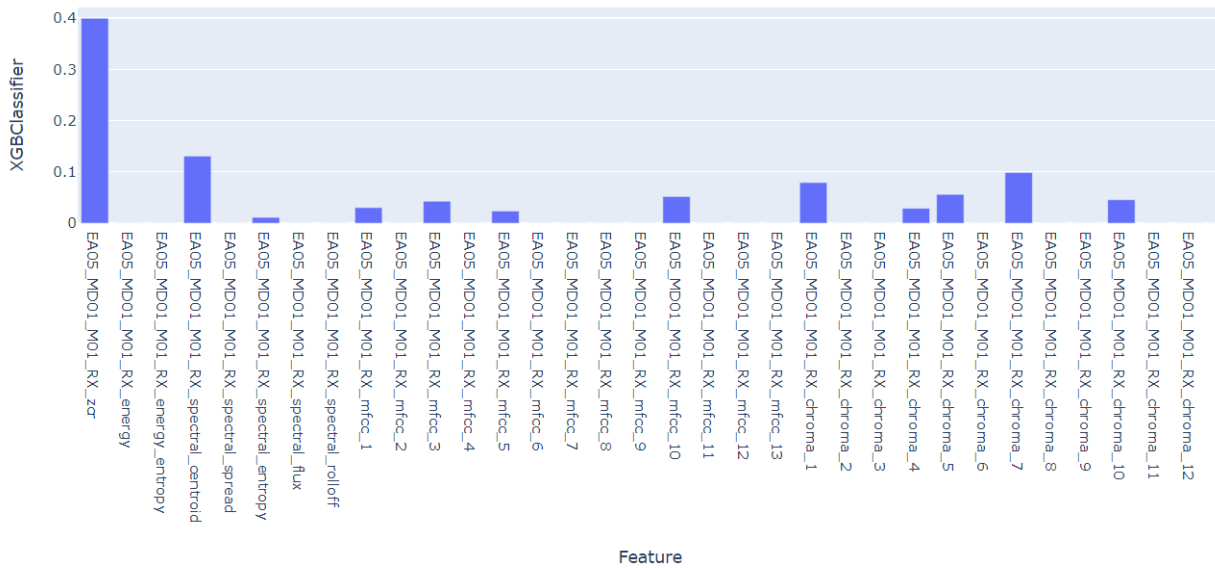
4.3.1 Relevância de *Features*

Para determinar a relevância das características obtidas, foi utilizada uma biblioteca da linguagem *Python* denominada XGBoosting (X Gradient Boosting Library). Esta biblioteca disponibiliza algoritmos de impulso paralelos para tarefas de machine learning utilizando nós de decisão, semelhante ao *Random Forest*. O cálculo de importância é realizado através de um único nó de decisão para cada característica, avaliando o impacto de cada *feature* na classificação dos registros analisados, sendo então calculada a média entre todos os nós presentes no modelo [Tibshirani Trevor Hastie 2008].

Assim, as informações sobre as *features* foram concatenadas em um arquivo *CSV*, contendo as 134 colunas referentes às *features* calculadas, bem como uma coluna adicional indicando a classificação daquele registro em específico, explicitando se o sensor encontrava-se fixo ou frouxo. Além disso, as *features* nulas foram retiradas dos dados compilados, como o fluxo espectral, que depende da comparação entre dois registros para seu cálculo.

Com os dados submetidos ao modelo de avaliação de importância das características, foi possível observar em um gráfico de barras a relação entre cada *feature* calculada e sua importância na classificação dos sinais entre as condições de acoplamento dos sensores, gráfico esse que está apresentado na Figura 37. Dos resultados, foi possível observar que os sinais advindos do sensor atrelado à entrada analógica 05 foi o mais relevante para detecção da condição de acoplamento dos sensores, e as principais *features* podem ser vistas à seguir.

Do gráfico, podemos observar a relevância calculada de cada característica calculada dos sinais advindos do sensor atrelado à entrada analógica 05, sendo esse o sensor acoplado à 0° no primeiro mancal do módulo de mancais de rolamento.

Figura 37 – Relevância de *features* utilizando XGBoost

Fonte: Do autor.

As duas *features* mais relevantes segundo o modelo são, respectivamente, a taxa de cruzamentos em zero e a centróide espectral do sinal. Tal informação está em consonância com os resultados preliminares obtidos através das medidas utilizando o *shaker*, sendo possível ver claramente as oscilações próximas a zero na Figura 28 como sendo uma das características do sinal temporal que caracterizam um sensor com problemas de acoplamento.

Com a relevância das *features* calculadas, as duas *features* mais relevantes foram selecionadas para servirem de entradas para um modelo classificador, a fim de treiná-lo para detectar possíveis falhas de acoplamento em registros futuros. Após o treinamento e teste, a acurácia do modelo será avaliada e, posteriormente, serão propostas alternativas que possam contribuir para uma melhor acurácia dos modelos na classificação dos registros.

4.3.2 *Random Forest* utilizando *features* mais relevantes

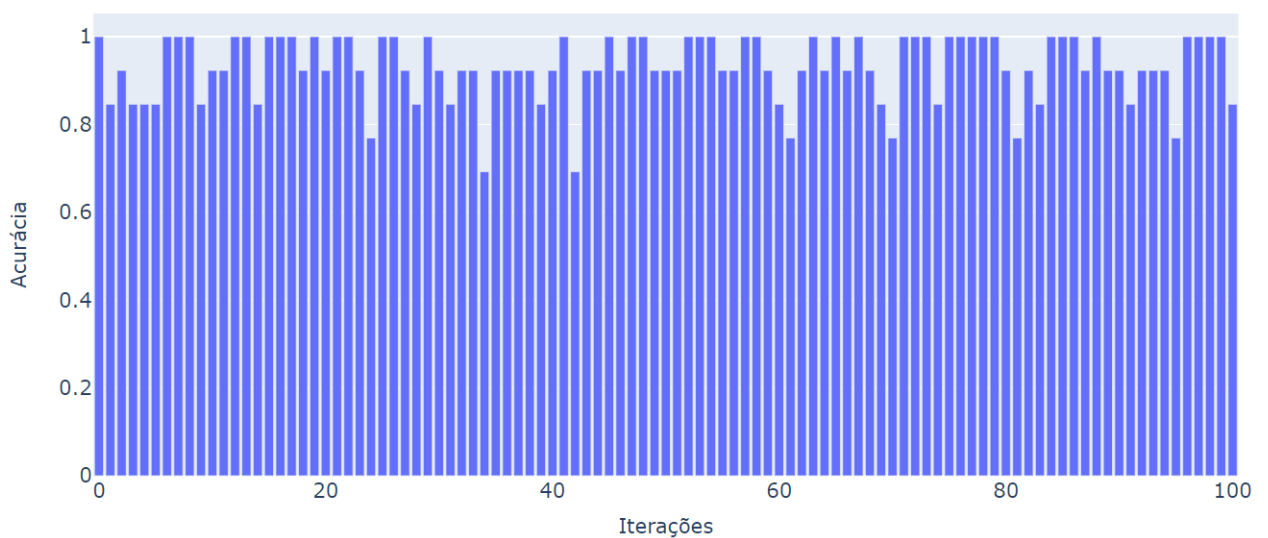
O algoritmo classificador escolhido foi o *Random Forest*, tanto pela disponibilidade quanto pela simplicidade de configuração e operação da biblioteca. Como citado na fundamentação teórica deste trabalho, esse algoritmo se baseia em "árvores" que analisam os dados de entrada e relacionam as variações de valores com as classificações disponibilizadas. No final, a classificação resultante da maioria das árvores é utilizada como classificação final do registro.

Neste caso, foram utilizados os valores calculados de taxa de cruzamento em zero e centróide espectral calculados previamente como entrada, bem como as informações de classificação dos dados analisados, tendo em vista que tal modelo é classificado como um modelo supervisionado.

Para o treinamento do modelo, o *dataset* foi separado, sendo 70% dos registros utilizados para treinamento, e os 30% restantes foram usados como teste final para avaliação de acurácia. Além disso, o modelo foi configurado com um total de 10 árvores para realizar a análise e estimação de classificação. Por fim, a acurácia é calculada comparando as respostas obtidas pelo modelo com as informações de classificação real dos registros utilizados para teste, retornando assim uma porcentagem de acerto.

Além disso, para uma melhor robustez, a rotina supracitada de treino e teste foi realizada 100 vezes, sendo que em cada iteração o conjunto de dados de treinamento e teste é embaralhado aleatoriamente, de forma que possamos avaliar o desempenho do modelo com vários conjuntos de registros diferentes usados para o treinamento do algoritmo.

Figura 38 – Acurácia do *Random Forest* com a utilização de *features*



Fonte: Do autor.

Do gráfico de barras apresentado, é possível perceber que em determinadas iterações, a acurácia do modelo chegou a atingir 100% de acerto ao classificar o conjunto de dados de testes. Porém, em algumas iterações a acurácia não pareceu tão promissora, atingindo valores de até aproximadamente 69% nos menores patamares.

Algumas hipóteses podem ser levantadas para justificar tal discrepância de resultados, sendo uma delas o conjunto específico de registros usados para o treinamento, e outra o número pequeno de registros disponíveis para treinamento e teste. No final, a acurácia média do modelo utilizando as *features* calculadas como entrada foi de aproximadamente 93,2%.

4.3.3 Utilização de PCA para redução de dimensionalidade


Buscando melhorar o desempenho do modelo de classificação para detecção de problemas de acoplamento de acelerômetros, foi empregado o uso de uma técnica de análise

de dados denominada redução de dimensionalidade, através de um algoritmo de machine learning supervisionado denominado PCA (*Principal Component Analysis*).

Para redução de dimensionalidade, foi passado como argumento o conjunto das 134 *features* calculadas anteriormente, a fim de obter duas componentes que tivessem grande relevância na classificação das condições de acoplamento dos sensores. Após o cálculo da matriz de covariância, foi possível obter tais componentes, que podem ser vistas à seguir.

No gráfico obtido, podemos identificar as duas componentes resultantes da aplicação do método nos eixos x e y, além de uma escala de cores que determina a condição de acoplamento dos sensores, sendo 1 a classificação correspondente ao sensor frouxo, e 0 a condição de sensor fixo.

Figura 39 – Relação entre as componentes resultantes do PCA



Fonte: Do autor.

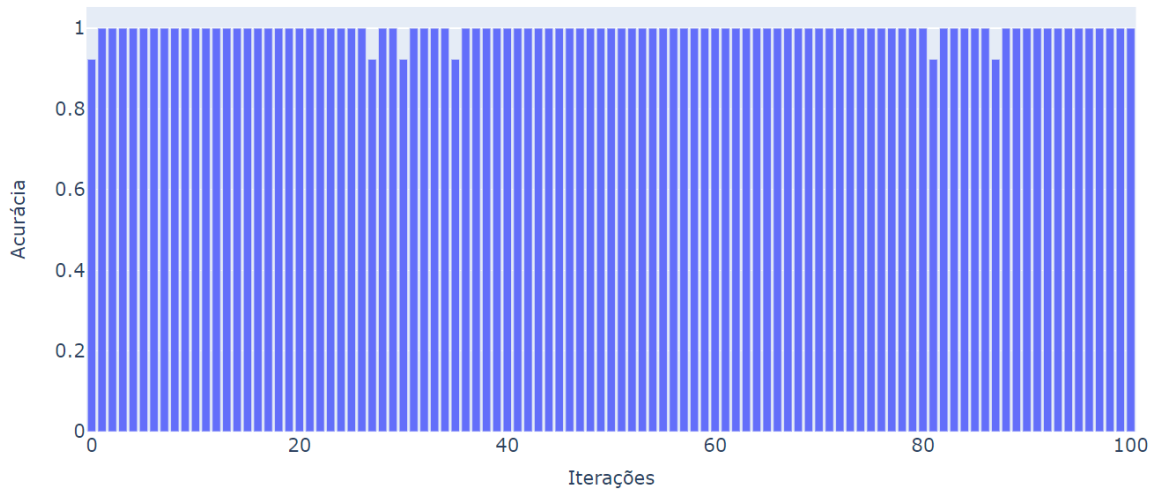
Inicialmente, apesar do número reduzido de amostrar dificultar parcialmente a formação de *clusters* de dados, podemos observar uma nítida separação entre os pontos classificados como sensor frouxo e fixo, principalmente tomando como base o eixo x, quando o valor da segunda componente é igual a zero. Isso pode indicar que as componentes resultantes do método utilizado são bons indicadores no que tange o acoplamento dos sensores.

Como próximo passo, é possível utilizar as componentes obtidas como dados de entrada no modelo de classificação *Random Forest*, a fim de verificar se houve melhora ao utilizar tais resultados frente a utilização das *features* calculadas diretamente. Portanto, os dados foram novamente organizados em um CSV contendo as duas componentes apresentadas, bem como a classificação dos registros para cada ponto de relação entre os componentes. A metodologia empregada foi a mesma, separando o conjunto de dados em 70% para treinamento e os outros 30% para teste.

Além disso, novamente foram realizadas 100 iterações, embaralhando aleatoriamente os conjuntos de treino e teste para assegurar a robustez dos resultados obtidos, e

posteriormente calculada a acurácia do modelo em cada iteração. Os resultados obtidos podem ser vistos a seguir.

Figura 40 – Acurácia do *Random Forest* com a utilização de componentes do PCA



Fonte: Do autor.

Analisando os resultados, foi possível perceber um aumento significativo da acurácia geral do modelo. Em grande parte das iterações, o modelo foi capaz de atingir 100% de acerto na classificação dos registros no que tange à condição de acoplamento dos acelerômetros, mesmo utilizando varios conjuntos de dados diferentes para o treinamento. Nesse sentido, a acurácia média do modelo nas 100 iterações foi de aproximadamente 99,5%, apresentando uma melhora de 6,3% em relação aos resultados obtidos utilizando diretamente as duas *features* classificadas como mais relevantes.

Levando em conta o ambiente controlado de execução dos testes, também é possível levantar hipóteses sobre a origem das classificações que não atingiram um patamar de acurácia máxima, tanto na utilização das *features* como na utilização das componentes principais do PCA. Algumas hipóteses para isso vem do fato do diminuto conjunto de registros utilizados para a realização dos testes, limitando os conjuntos de treinamento utilizados e assim, possivelmente, gerando alguns conjuntos de testes que não possuem os padrões necessários para detecção das falhas. Além disso, também é possível que a utilização de um baixo número de *features*/Componentes principais tenha impactado na acurácia destas repetições em específico.

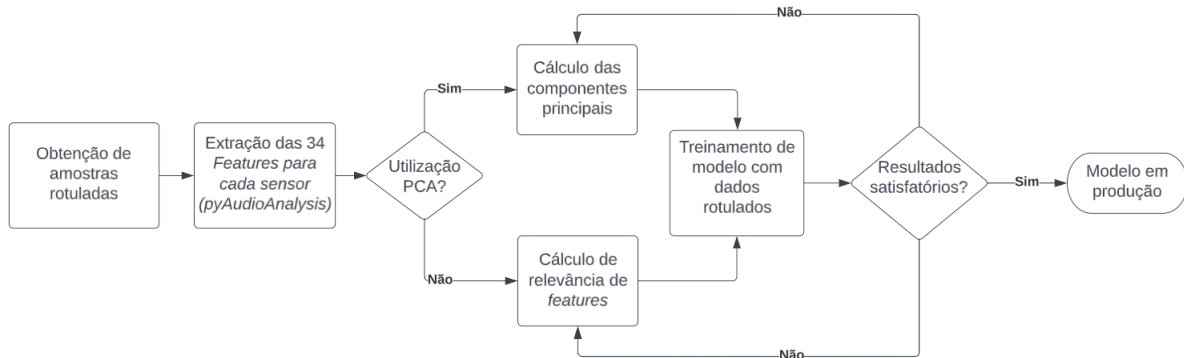
Assim, é possível afirmar que, para as condições de contorno e dados obtidos neste caso em específico, a utilização da técnica de redução de dimensionalidade foi importante para uma melhora dos resultados obtidos na utilização de algoritmos de aprendizado de máquina para classificação da condição de acoplamento de sensores.

Nesse contexto, podemos sintetizar a metodologia apresentada em alguns passos que também podem ser melhor visualizados no esquema apresentado na Figura 41, sendo

eles:

- Obtenção de sinais rotulados;
- Extração das 34 *features* do pyAudioAnalysis para cada sensor utilizado;
- Cálculo de relevância de *features*/ Componentes principais do PCA. (são necessários mais estudos para analisar a acurácia do modelo em dados reais);
- Treinamento do modelo com as características/componentes selecionadas;
- Verificação da acurácia;
- Produção.

Figura 41 – Diagrama de blocos do *pipeline* de utilização do método proposto.



Fonte: Do autor.

5 Conclusão

5.1 Resultados Obtidos

A partir do presente trabalho, além de reafirmar a importância da condição de sensores do tipo acelerômetro no monitoramento de unidades geradoras a partir de análise de vibrações, foi possível verificar a viabilidade da implementação de um sistema automatizado para a detecção de falhas no acoplamento de tais sensores.

As análises preliminares utilizando o *shaker* foram importantes para perceber possíveis impactos de problemas de acoplamento nos sinais medidos, sendo possível visualizar facilmente tais anomalias tanto no domínio do tempo, quanto no espectro de tais sinais. Além disso, apesar da distância das condições de operação de uma máquina real, umas das *features* classificadas posteriormente como relevantes para a classificação do acoplamento de sensores pode ser vista claramente no sinal temporal gerado pelo equipamento.

Mais adiante, foi possível analisar os sinais obtidos através da bancada de simulações, que busca produzir sinais mais próximos à realidade de operação dos aerogeradores, tendo em sua composição, além da componente fundamental referente a frequência de rotação da máquina, ruídos gerados pelo meio bem como a interferência da vibração das demais partes da bancada. Nesses sinais, não era possível identificar claramente as diferenças presentes nos resultados com o *shaker* e, por isso, foi necessário empregar técnicas de processamento de dados para tal tarefa.

Para essas análises, foram empregadas ferramentas de processamento de dados tanto para o cálculo das características possíveis dos sinais, bem como para sua classificação e utilização em algoritmos classificadores. Após o cálculo das características, o emprego de técnicas para análise de relevância foi também fundamental para explicitar quais delas são de fato relevantes para a solução do problema proposto. Utilizando as *features* mais relevantes como argumento para treino e teste de modelos classificadores, observou-se resultados expressivos, tendo esse método uma acurácia média superior a 90% e igual a 100% em 44 das 100 repetições, mostrando que existe a possibilidade do emprego destes métodos para esse tipo de problema.

Após o cálculo e análise de relevância das características dos sinais, também foi possível utilizar técnicas de redução de dimensionalidade para geração de componentes adicionais, sendo possível obter resultados ainda melhores na classificação de registros em relação ao acoplamento dos sensores, obtendo uma acurácia média superior a 99%, com apenas 6 repetições com a acurácia menor que 100%.

5.2 Trabalhos Futuros

O trabalho aqui apresentado serve como uma prova de conceito, podendo ser melhor lapidado em diversos aspectos. Inicialmente, é possível ampliar a massa de dados utilizados para o treinamento e teste dos modelos, tendo assim uma maior robustez e segurança nos resultados obtidos. Além disso, também é possível avaliar a utilização de diversos modelos classificadores existentes a fim de buscar algoritmos que possivelmente tenham melhores resultados.

Outro trabalho imprescindível para a continuação do do desenvolvimento da metodologia seria a utilização de dados reais advindos de aerogeradores para o treinamento e teste destes modelos, tanto para validar a relevância das *features* encontradas para a classificação do acoplamento de sensores, bem como validar os métodos utilizados, tanto de modelos classificadores quanto métodos de redução de dimensionalidade, para essa aplicação específica. Também, é interessante a utilização de dados advindos de demais equipamentos além de aerogeradores, como hidrogeradores, por exemplo.

Além disso, também é possível estender o escopo do trabalho ao analisar mais variáveis advindas de sensores buscando não só falhas de acoplamento, mas também falhas construtivas e de calibração de sensores. Tais estudos também são de suma importância para a área de análise de vibrações para o diagnóstico e prognóstico de aerogeradores, objetivando desenvolver um sistema automatizado e robusto, capaz de ser usado comercialmente.

Nesse contexto, uma análise mais aprofundada de fatores como o posicionamento de sensores (radial em 0° , 90° , e na posição axial) e o impacto dessas características são de grande valia, bem como a influência de variáveis de contexto (potência gerada, velocidade do vento...) que indiquem o ponto de operação da máquina nos resultados obtidos. Em tempo, os diferentes métodos de acoplamento de sensores também devem ser melhor avaliados, buscando tanto novas informações para detecção de sensores quando uma melhor qualidade nos sinais medidos.

Referências

- ALI, J. et al. Random forests and decision trees. *International Journal of Computer Science Issues*, v. 9, n. 5, 2012. Citado na página 36.
- AQTECH. *AQTech Engenharia e instrumentação*. 2021. Disponível em: <<https://www.aqtech.com/>>. Citado na página 39.
- BHATTACHARYA, M. et al. The effect of renewable energy consumption on economic growth: Evidence from top 38 countries. *Applied Energy*, v. 162, p. 733–741, 2016. ISSN 0306-2619. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306261915013318>>. Citado na página 19.
- British Petroleum Company. *BP statistical review of world energy*. London: British Petroleum Co., 2021. Disponível em: <<https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2021-full-report.pdf>>. Citado na página 19.
- CHEN, J.; JENKINS, W. K. Facial recognition with pca and machine learning methods. In: *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*. [S.l.: s.n.], 2017. p. 973–976. Citado na página 34.
- ELECTRICITY, F. *Importance of Electricity*. 2022. Disponível em: <<https://pointdekho.com/2022/02/08/importance-of-electricity-in-easiest-way/>>. Citado na página 24.
- GAUTSCHI, G. *Piezoelectric Sensorics: Force strain pressure acceleration and acoustic emission sensors materials and amplifiers*. [S.l.]: Springer Science Business Media, 2013. Citado na página 30.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems*. [S.l.]: O'Reilly Media, 2019. Citado na página 33.
- HAMEED, Z. et al. Condition monitoring and fault detection of wind turbines and related algorithms: A review. *Renewable and Sustainable energy reviews*, Elsevier, v. 13, n. 1, p. 1–39, 2009. Citado na página 28.
- ISO10816-21. *Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts — Part 21: Horizontal axis wind turbines with gearbox*. Geneva, CH, 2015. Citado 2 vezes nas páginas 28 e 34.
- JALAL, A. A. Big data and intelligent software systems. *International Journal of Knowledge-based and Intelligent Engineering Systems.*, 11 2018. Citado na página 34.
- Joyce Lee, Feng Zhao. *Global Wind Report 2021*. Global Wind Energy Council, 2021. Disponível em: <<https://gwec.net/wp-content/uploads/2021/03/GWEC-Global-Wind-Report-2021.pdf>>. Citado na página 19.

- KEBOOLA. *A Guide to Principal Component Analysis (PCA) for Machine Learning*. 2020. Disponível em: <<https://www.keboola.com/blog/pca-machine-learning>>. Citado na página 35.
- LI, H.; SUN, J.; WU, J. Predicting business failure using classification and regression tree: An empirical comparison with popular classical statistical methods and top classification mining methods. *Expert Systems with Applications*, v. 37, n. 8, p. 5895–5904, 2010. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417410000552>>. Citado na página 36.
- LV, Y.; ZHAO, Q. Wavelet-mathematical morphology and envelope spectrum analysis in wind power generator gearbox fault diagnosis. *2013 Ninth International Conference on Natural Computation (ICNC)*, p. 1469–1473, 2013. Citado na página 26.
- MADSEN, B. N. Condition monitoring of wind turbines by electric signature analysis. *Master's Thesis, Technical University of Denmark, Copenhagen, Denmark*, 2011. Citado na página 28.
- MASSON-DELMOTTE V., P. Z. A. P. S. C. C. P. S. B. N. C. Y. C. L. G. M. G. M. H. K. L. E. L. J. M. T. M. T. W. O. Y. R. Y.; (EDS.), B. Z. *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. [S.l.], 2021. Citado 2 vezes nas páginas 22 e 23.
- MTS SYSTEMS CORPORATION. *Model 9100 D Portable Shaker Table*. [S.l.], 2020. Rev. N. Citado na página 41.
- NAQA, I. E.; MURPHY, M. J. What is machine learning? In: _____. *Machine Learning in Radiation Oncology: Theory and Applications*. Cham: Springer International Publishing, 2015. p. 3–11. ISBN 978-3-319-18305-3. Disponível em: <https://doi.org/10.1007/978-3-319-18305-3_1>. Citado na página 33.
- OMEGATRON. *Rough sketch of piezoelectric sensor frequency response*. 2007. Disponível em: <https://commons.wikimedia.org/wiki/File:Piezoelectric_sensor_frequency_response.svg>. Citado na página 30.
- OMEGATRON. *Schematic symbol and electronic model for a piezoelectric sensor*. 2007. Disponível em: <https://commons.wikimedia.org/wiki/File:Piezoelectric_sensor_electrical_model.svg>. Citado na página 31.
- OMER, M. A. et al. Conversion of abdominal physiological motion into electrical signal using pressure sensor. *International Journal of Science and Research (IJSR)*, v. 3, p. 1868–1871, 09 2014. Citado na página 31.
- PCB PIEZOTRONICS, INC. *Low-cost Industrial ICP® Accelerometer Installation and Operating Manual*. [S.l.], 2019. Rev. E. Citado na página 40.
- SPECIALTIES, M. Interfacing piezo film to electronics application note. In: . [S.l.: s.n.]. Citado na página 30.
- TCHAKOUA, P. 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. Disponível em: <<https://www.mdpi.com/1996-1073/7/4/2595>>. Citado 3 vezes nas páginas 20, 28 e 29.

TIBSHIRANI TREVOR HASTIE, J. F. R. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition (Springer Series in Statistics)*. [S.l.]: Springer, 2008. Citado na página 55.

TYIANNAK. *A Python library for audio feature extraction, classification, segmentation and applications*. 2021. Disponível em: <<https://github.com/tyiannak/pyAudioAnalysis>>. Citado na página 54.

WALFORD, C. A. *Wind turbine reliability: understanding and minimizing wind turbine operation and maintenance costs*. [S.l.], 2006. Citado na página 27.