



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CURSO DE GRADUAÇÃO EM ENGENHARIA MECÂNICA

JOÃO PEDRO GARCIA

**DETECÇÃO DE DESALINHAMENTO EM MÁQUINAS ROTATIVAS
UTILIZANDO ANÁLISE DE VIBRAÇÃO E MODELOS DE APRENDIZADO DE
MÁQUINA**

FLORIANÓPOLIS

2024

João Pedro Garcia

**DETECÇÃO DE DESALINHAMENTO EM MÁQUINAS ROTATIVAS UTILIZANDO
ANÁLISE DE VIBRAÇÃO E MODELOS DE APRENDIZADO DE MÁQUINA**

Trabalho apresentado ao Curso de Graduação em Engenharia Mecânica da Universidade Federal de Santa Catarina como parte dos requisitos para obtenção do título de Bacharel em Engenharia Mecânica

Orientador: Prof. Julio Apolinário Cordioli, Dr. Eng.

Coorientadora: Racquel Knust Domingues, Ma. Eng.

Florianópolis

2024

João Pedro Garcia

Detecção de Desalinhamento em Máquinas Rotativas utilizando Análise de Vibração e Modelos de Aprendizado de Máquina

O presente trabalho em nível de Bacharel foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Jonny Carlos da Silva, Dr. Eng.
Universidade Federal de Santa Catarina

Prof. Pedro Veras Guimarães, Dr.
Universidade Federal de Santa Catarina

Prof. Júlio Apolinário Cordioli, Dr. Eng.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de Bacharel em Engenharia Mecânica.



Documento assinado digitalmente

Carlos Enrique Niño Bohórquez

Data: 03/12/2025 07:13:49-0300

CPF: ***.878.519-**

Verifique as assinaturas em <https://v.ufsc.br>

Prof. Carlos Enrique Niño Bohórquez, Dr.
Coordenador do Programa



Documento assinado digitalmente

Julio Apolinario Cordioli

Data: 02/12/2025 21:43:57-0300

CPF: ***.276.989-**

Verifique as assinaturas em <https://v.ufsc.br>

Prof. Julio Apolinário Cordioli, Dr. Eng
Orientador

Florianópolis, 26 de dezembro de 2024.

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Garcia, João Pedro

Detecção de desalinhamento em máquinas rotativas
utilizando análise de vibração e modelos de aprendizado de
máquina / João Pedro Garcia ; orientador, Júlio Apolinário
Cordioli, coorientadora, Racquel Knust Domingues, 2024.

70 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Mecânica, Florianópolis, 2024.

Inclui referências.

1. Engenharia Mecânica. 2. Análise de Vibração. 3.
Aprendizado de Máquina. 4. Manutenção Preditiva. 5.
Desalinhamento de Eixos. I. Apolinário Cordioli, Júlio.
II. Knust Domingues, Racquel. III. Universidade Federal de
Santa Catarina. Graduação em Engenharia Mecânica. IV. Título.

Em memória da minha educadora, professora e avó, Renilda Lisboa.

AGRADECIMENTOS

Agradeço intensamente à minha família próxima por todo o apoio durante meu processo educacional. Em especial, à minha falecida professora e avó, Renilda Geraldina Daniel Lisboa, que me educou integralmente: ensinou-me a escrever, a ler, incentivou-me a sempre ir além e, acima de tudo, mostrou-me o valor da educação na vida. Agradeço profundamente também ao meu avô, Arly Lisboa, que não poupou esforços para garantir uma vida mais tranquila à nossa família, criando-me e apoiando-me em toda minha formação. Expresso também minha gratidão aos meus pais, João Carlos Vilela Garcia e Arliana Lisboa, pelo carinho, dedicação e apoio incondicional à minha educação. Agradeço, ainda, ao meu irmão, João Vitor Lisboa Garcia, pelo constante apoio, pelas memórias compartilhadas na infância e pela inspiração que seu notório sucesso me oferece a seguir em frente com empenho e dedicação.

Manifesto meu especial agradecimento à minha parceira, Laura Silva da Costa, que me apoia em cada escolha, me escuta e me ajuda em tudo o que é possível, estando presente ativamente em todos os momentos do meu dia. Agradeço também aos meus sogros, Christian Lehmkuhl da Costa e Fernanda Silva da Costa, por todo o carinho e acolhimento ao longo desse tempo.

Sou igualmente grato aos meus colegas de laboratório. Em especial, agradeço à Racquel Knust, minha coorientadora, pela dedicação imensurável com todos ao seu redor, exercendo sua profissão com esmero absoluto. Minha gratidão também vai aos bolsistas de iniciação científica Miguel Oliva, Luiz Fonseca, Fabian Abreu e Lucas Leichtweis, não só pelo auxílio nos experimentos, mas também pelas conversas, laços e memórias criadas, que tornaram o dia a dia mais leve e divertido.

Sou muito grato à companhia dos meus colegas de vida, que me acompanharam até a faculdade, tornando a experiência muito mais prazerosa. Em especial, agradeço ao meu primo, Gabriel Lisboa, e aos meus amigos Felipe Durão, Felipe Negrão, Felipe Rossi e Luigi Doria.

Agradeço também ao professor Sérgio Luiz Gargioni, por todos os ensinamentos marcantes em suas disciplinas, por todas as oportunidades de criação de laços que o professor proporcionou, pelas mentorias e orientações de carreira e, principalmente por toda sua dedicação imensa em construir caminhos e oportunidades para toda a comunidade de estudantes de engenharia mecânica da UFSC.

Expresso minha profunda gratidão ao professor Amir Antonio Martins de Oliveira Jr. por ter me ouvido com muita atenção quando mais precisei, por me ajudar a não desistir dos meus sonhos e por sua consideração e cuidado com os alunos do departamento.

Agradeço ao meu professor orientador, Júlio Apolinário Cordioli, pela incrível oportunidade de trabalhar neste projeto e por todas as aulas marcantes nas disciplinas da universidade. Finalmente, registro minha gratidão à *Dynamox* e à Fundação de Ensino e Engenharia de Santa Catarina pelo apoio essencial à execução deste trabalho.

There are many worlds, but they share the same sky - one sky, one destiny.

Kairi

RESUMO

A detecção de desalinhamentos em máquinas rotativas é essencial para a manutenção preditiva, devido ao impacto dessa falha na produtividade e na durabilidade dos componentes. Este trabalho explorou métodos de aprendizado de máquina aplicados à análise de sinais de vibração para classificar estados de alinhamento e desalinhamento. Dados foram coletados usando uma bancada de simulação de falhas em máquinas rotativas da *SpectraQuest*, considerando variações de acoplamento, velocidade de rotação e intensidade de defeito para simular condições saudáveis e desalinhamentos paralelos e angulares. Acelerômetros triaxiais foram posicionados nos mancais de rolamento e os sinais de vibração foram medidos. Foram extraídas *features* nos domínios do tempo, orbital e de frequência para alimentar algoritmos de classificação, incluindo Regressão Logística, *SVM*, Floresta Aleatória e *XGBoost*. A otimização dos hiperparâmetros foi feita com *Stratified Group K-Fold* com a *ROC AUC* (área abaixo da curva *ROC*) como métrica de avaliação. Esses modelos foram treinados e testados em duas configurações de amostragem: a primeira com dados de vibração em direções diferentes da mesma medição em amostras separadas, resultando em 3600 amostras de 23 *features*, classificando as amostras utilizando dados uniaxiais, e a segunda com os eixos dos acelerômetros da mesma medição combinados na mesma amostra, utilizando a informação triaxial para a classificação, resultando em 1200 amostras de 69 *features*, sendo que as amostras combinadas apresentaram melhor desempenho e foram adotadas para as análises subsequentes. A divisão de treino e teste foi aleatória, com 75% e 25%, respectivamente. A comparação dos modelos foi realizada com as métricas *ROC AUC*, acurácia balanceada, acurácia e taxa de falsos positivos para um *threshold* de 90% de verdadeiros positivos. Inicialmente, o desempenho de teste apresentou o melhor desempenho com o *XGBoost*, alcançando uma *ROC AUC* de 0,80 e acurácia balanceada de 0,52 com todas as *features*. Para otimizar o desempenho, aplicou-se seleção de *features* com base em valores de *SHAP* (*SHapley Additive exPlanations*), identificando as *features* mais relevantes. Os modelos foram então retreinados com diferentes conjuntos de *features*. As *features* de órbita e estatísticas, isoladamente, mostraram-se insuficientes para a detecção, resultando em métricas abaixo da média comparado ao uso de todas as *features*. As *features* de frequência demonstraram-se mais influentes, com desempenho semelhante ao modelo completo. O melhor resultado foi obtido utilizando as 20 *features* mais importantes, combinando *features* dos domínios de frequência, órbita e tempo, indicando forte interatividade entre as *features* e atingindo *ROC AUC* de 0,90 e taxa de falsos positivos de 0,37 para o *threshold* definido. Após a seleção de *features*, foram criados três subconjuntos de dados para o treino e teste das amostras: geral, desalinhamento paralelo e desalinhamento angular. Não houve diferenças significativas de desempenho entre os três conjuntos de dados ao utilizar as 20 *features* mais relevantes. Observou-se uma alta taxa de falsos positivos, com frequentes classificações incorretas de dados saudáveis como desalinhados.

Palavras-chave: Desalinhamento de eixos, Máquinas rotativas, Análise de vibração, Aprendizado de máquina, *XGBoost*, *SHAP*.

ABSTRACT

The detection of misalignments in rotating machinery is essential for predictive maintenance, due to the impact of this fault on productivity and component durability. This work explored machine learning methods applied to vibration signal analysis to classify alignment and misalignment states. Data were collected using a *SpectraQuest* rotating machinery fault simulation testbed, considering variations in coupling, rotational speed, and defect intensity to simulate healthy conditions and parallel and angular misalignments. Triaxial accelerometers were positioned on the bearing supports, and vibration signals were measured. Features in the time, orbital, and frequency domains were extracted to feed classification algorithms, including Logistic Regression, *SVM*, Random Forest, and *XGBoost*. Hyperparameter optimization was performed using *Stratified Group K-Fold* with *ROC AUC* (area under the *ROC* curve) as the evaluation metric. These models were trained and tested in two sampling configurations: the first with vibration data in different directions from the same measurement in separate samples, resulting in 3600 samples of 23 features, classifying the samples using uniaxial data; and the second combining the axes of the accelerometers from the same measurement into a single sample, using triaxial information for classification, resulting in 1200 samples of 69 features. The combined samples showed better performance and were adopted for subsequent analyses. The training and testing split was random, with 75% and 25%, respectively. The comparison of models was carried out using *ROC AUC*, balanced accuracy, accuracy, and false positive rate metrics for a threshold of 90% true positives. Initially, the test performance showed the best results with *XGBoost*, achieving a *ROC AUC* of 0.80 and a balanced accuracy of 0.52 with all features. To optimize performance, feature selection was applied based on *SHAP* (SHapley Additive exPlanations) values, identifying the most relevant features. Models were then retrained with different feature sets. Orbital and statistical features alone were insufficient for detection, resulting in below-average metrics compared to using all features. Frequency domain features proved to be the most influential, with performance similar to the complete model. The best result was obtained using the 20 most important features, combining frequency, orbital, and time domain features, indicating strong interaction between features and achieving a *ROC AUC* of 0.90 and a false positive rate of 0.37 for the defined threshold. After feature selection, three data subsets were created for training and testing: general, parallel misalignment, and angular misalignment. No significant performance differences were observed among the three datasets when using the 20 most relevant features. A high false positive rate was noted, with frequent misclassifications of healthy data as misaligned.

Keywords: Shaft misalignment, Rotating machinery, Vibration analysis, Machine learning, *XGBoost*, *SHAP*.

LISTA DE ILUSTRAÇÕES

Figura 1 – Flexão de um eixo desalinhado com um torque de 400 Nm.	18
Figura 2 – Desalinhamento paralelo, angular e combinado.	19
Figura 3 – Sinal de desalinhamento no domínio do tempo em vermelho e de alinhamento em verde. Acoplamento espiral, 1750 rpm, eixo de 0,75 polegadas de diâmetro.	20
Figura 4 – Órbita com três dimensões, com desalinhamento angular, com velocidade de rotação de 25 Hz, com o filtro passa banda em 1X (a), 2X (b) e em ambos (c).	22
Figura 5 – Órbita com três dimensões em um sinal saudável, com velocidade de rotação de 25 Hz, com o filtro passa banda em 1X (a), 2X (b) e em ambos (c).	22
Figura 6 – Frequências de rotação para o desalinhamento angular e desalinhamento paralelo. . .	24
Figura 7 – Fluxograma de trabalho de aprendizado de máquina de classificação.	25
Figura 8 – Representação da validação cruzada (<i>K-Fold</i>).	27
Figura 9 – Representação de uma regressão logística.	27
Figura 10 – Representação de uma classificação por <i>SVM</i> . As coordenadas representadas neste gráfico são ilustrativas e têm escalas arbitrárias.	28
Figura 11 – Representação de uma árvore de decisão.	29
Figura 12 – Representação de um exemplo de uma matriz de confusão.	30
Figura 13 – Representação de uma curva <i>ROC</i> e do <i>threshold</i>	31
Figura 14 – Exemplo de análise <i>SHAP</i>	32
Figura 15 – Fluxograma do trabalho.	33
Figura 16 – <i>Machinery Fault Simulator</i> da <i>SpectraQuest</i>	34
Figura 17 – Calço metálico de 0.05 mm.	35
Figura 18 – Calços metálicos gerando o desnível no sistema.	35
Figura 19 – Vista de cima (a) e lateral (b) da <i>MFS</i>	36
Figura 20 – Relógio comparador.	36
Figura 21 – Posições dos calços na bancada.	37
Figura 22 – Acoplamento flexível e acoplamento rígido, respectivamente.	38
Figura 23 – Acelerômetro triaxial <i>DeltaTron 4525-B</i>	39
Figura 24 – Acelerômetros e <i>Dynaloggers</i> posicionados acima dos mancais e sistema de coordenadas. .	39
Figura 25 – Placa de aquisição NI-9234.	40
Figura 26 – Chassi CompactDAQ cDAQ-9174.	40
Figura 27 – Fluxo de trabalho utilizado no trabalho.	43
Figura 28 – Fluxo de análise de desempenho e seleção de <i>features</i>	46
Figura 29 – (a) Sinal saudável no domínio do tempo, com 3000 rpm, acoplamento flexível, e acelerô- metro no mancal <i>LA</i> , em azul. (b) Sinal com desalinhamento paralelo de intensidade média, nas mesmas condições, em laranja.	46

Figura 30 – Sinal saudável na frequência com 3000 rpm, acoplamento flexível e acelerômetro no mancal <i>LA features</i> , em azul (a). Sinal na frequência com desalinhamento paralelo de intensidade média, 3000 rpm, acoplamento flexível e acelerômetro no mancal <i>LA</i> , em laranja (b).	47
Figura 31 – Órbita saudável na frequência com 3000 rpm, acoplamento flexível e acelerômetro no mancal <i>LA features</i> (a). Órbita com desalinhamento paralelo de intensidade média, 3000 rpm, acoplamento flexível e acelerômetro no mancal <i>LA</i> (b).	47
Figura 32 – Análise exploratória do valor <i>RMS</i> e dos picos de frequência <i>1X</i> , <i>2X</i> e <i>3X</i> , nos eixos horizontais, verticais e axiais do acelerômetro posicionado no mancal <i>LA</i> , e a intensidade do desalinhamento variando entre saudável e alta.	48
Figura 33 – Área da órbita para os eixos axiais (<i>XZ</i>) com a variação da intensidade de desalinhamento paralelo vertical.	49
Figura 34 – <i>SDI</i> para os eixos axiais (<i>YZ</i>) com a variação da intensidade de desalinhamento paralelo vertical.	49
Figura 35 – Curva <i>ROC</i> para os algoritmos de aprendizado de máquina na configuração com eixos em amostras separadas.	50
Figura 36 – Curva <i>ROC</i> para os algoritmos de aprendizado de máquina na configuração com eixos combinados nas mesmas amostras.	51
Figura 37 – Curva <i>ROC</i> para o algoritmo de <i>XGBoost</i> com eixos combinados na mesma amostra.	52
Figura 38 – Análise <i>SHAP</i> para o algoritmo de <i>XGBoost</i> com eixos combinados na mesma amostra.	52
Figura 39 – Curva <i>ROC</i> para <i>XGBoost</i> apenas com <i>features</i> de frequência em comparação com o modelo com todas as <i>features</i>	53
Figura 40 – Análise <i>SHAP</i> do modelo de <i>XGBoost</i> com <i>features</i> de frequência.	53
Figura 41 – Curva <i>ROC</i> para <i>XGBoost</i> apenas com <i>features</i> de tempo em comparação com o modelo com todas as <i>features</i>	54
Figura 42 – Análise <i>SHAP</i> do modelo de <i>XGBoost</i> com <i>features</i> de tempo.	54
Figura 43 – Curva <i>ROC</i> para <i>XGBoost</i> apenas com <i>features</i> de órbita em comparação com o modelo com todas as <i>features</i>	55
Figura 44 – Análise <i>SHAP</i> do modelo de <i>XGBoost</i> com <i>features</i> de órbita.	55
Figura 45 – Curva <i>ROC</i> para <i>XGBoost</i> apenas com as 20 melhores <i>features</i> no subconjunto geral.	56
Figura 46 – Matriz de confusão para o <i>XGBoost</i> com apenas as 20 melhores <i>features</i> no subconjunto geral.	57
Figura 47 – Curva <i>ROC</i> para <i>XGBoost</i> no subconjunto de desalinhamento paralelo com apenas as 20 melhores <i>features</i>	57
Figura 48 – Matriz de confusão para o <i>XGBoost</i> com apenas as 20 melhores <i>features</i> no subconjunto de desalinhamento paralelo.	58
Figura 49 – Curva <i>ROC</i> para <i>XGBoost</i> no subconjunto de desalinhamento angular com apenas as 20 melhores <i>features</i>	58

Figura 50 – Matriz de confusão para o <i>XGBoost</i> com apenas as 20 melhores <i>features</i> no subconjunto de desalinhamento angular.	59
Figura 51 – Análise <i>SHAP</i> do modelo de <i>XGBoost</i> com as melhores <i>features</i> no subconjunto de desalinhamento paralelo.	60
Figura 52 – Análise <i>SHAP</i> do modelo de <i>XGBoost</i> com as melhores <i>features</i> no subconjunto de desalinhamento angular.	60

LISTA DE TABELAS

Tabela 1 – Componentes do simulador de desalinhamento.	34
Tabela 2 – Componentes e descrições da <i>MFS</i>	36
Tabela 3 – Configurações dos calços para desalinhamento paralelo vertical.	37
Tabela 4 – Configurações dos calços para desalinhamento paralelo bidirecional.	37
Tabela 5 – Configurações dos calços para desalinhamento angular.	38
Tabela 6 – Características do acelerômetro triaxial DeltaTron com TEDS Tipo 4525-B.	39
Tabela 7 – Especificações da placa de aquisição NI-9234.	40
Tabela 8 – Especificações do chassi CompactDAQ cDAQ-9174.	41
Tabela 9 – Matriz de testes.	41
Tabela 10 – Amostras a serem obtidas.	41
Tabela 11 – Features extraídas.	42
Tabela 12 – Espaço de busca de hiperparâmetros utilizados para a otimização dos modelos.	45
Tabela 13 – Cronograma de atividades do projeto.	63

LISTA DE ABREVIATURAS E SIGLAS

RMS_c - *Root Mean Square Carpet* (raiz média quadrática de uma média móvel do valor RMS).

FC - Fator de crista, razão entre o valor máximo e o RMS do sinal.

FFT - *Fast Fourier Transform* (transformada rápida de Fourier).

LVA - Laboratório de Vibrações e Acústica.

MFS - *Machinery Fault Simulator*.

pk_pk - *Peak to Peak value* (valor pico a pico).

RMS - *Root Mean Square* (valor eficaz).

ROC AUC - *Receiver Operating Characteristic Area Under Curve* (área sob a curva ROC).

SDI - Shape and Directivity Index (grau de elipsicidade da órbita).

SHAP - *SHapley Additive exPlanations* (explicações aditivas de SHapley).

SVM - *Support Vector Machine*.

UFSC - Universidade Federal de Santa Catarina.

XGBoost - *Extreme Gradient Boosting*.

LISTA DE SÍMBOLOS

Símbolos em latim

$\bar{x}$ = Média aritmética dos valores da amostra.

φ = Ângulo de inclinação do maior eixo da elipse.

a_1, a_2 = Amplitude maior e menor da órbita.

N = Número de amostras.

r_1, r_2 = Raio da amplitude menor e maior da órbita.

X_d, Y_d = Parte real dos sinais analíticos de vibração nos eixos ortogonais.

x_i = Valor da i -ésima observação de uma amostra.

X_q, Y_q = Parte imaginária dos sinais analíticos de vibração nos eixos ortogonais.

X_{max} = Pico espectral da amostra.

Símbolos em grego

β_1 = Assimetria (skewness) da distribuição da amostra.

β_2 = Curtose (kurtosis) da distribuição da amostra.

σ = Desvio padrão.

Outros símbolos

f_i = i -ésima frequência de rotação.

S = Planicidade espectral da amostra.

SUMÁRIO

1	INTRODUÇÃO	15
1.1	MOTIVAÇÃO	16
1.2	OBJETIVOS	16
1.2.1	Objetivos específicos	16
1.3	ESTRUTURA DO DOCUMENTO	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	DESALINHAMENTO DE EIXOS	18
2.1.1	Tipos de desalinhamento	19
2.2	MONITORAMENTO DE CONDIÇÃO DE DESALINHAMENTO BASEADO EM VIBRAÇÃO	19
2.2.1	<i>Features</i> no domínio do tempo	20
2.2.2	<i>Features</i> no domínio da frequência	23
2.3	APRENDIZADO DE MÁQUINA	25
2.3.1	Classificação binária	25
2.3.2	Divisão de treino, teste e validação	26
2.3.3	Regressão logística	27
2.3.4	<i>SVM</i>	28
2.3.5	Árvores de decisão e florestas aleatórias de decisão	28
2.3.6	<i>XGBoost</i>	29
2.3.7	Métricas de classificação binária	29
2.3.8	Explicações aditivas de <i>Shapley</i>	31
3	MATERIAIS E MÉTODOS	33
3.1	METODOLOGIA DE DETECÇÃO DE FALHAS DE DESALINHAMENTO DE EIXOS	33
3.2	SIMULADOR DE FALHAS EM MÁQUINAS	33
3.2.1	Configuração da bancada de testes	34
3.3	INSTRUMENTAÇÃO DA BANCADA	38
3.4	MATRIZ DE TESTES E PROCEDIMENTO EXPERIMENTAL	41
3.5	EXTRAÇÃO DE <i>FEATURES</i>	42
3.6	FLUXO DE TRABALHO DE APRENDIZADO DE MÁQUINA	42
3.6.1	Divisão de treino e teste	43
3.6.2	Otimização dos hiperparâmetros e treinamento dos modelos	44
3.6.3	Análise de desempenho e seleção de <i>features</i>	45
4	RESULTADOS E DISCUSSÃO	46
4.1	ANÁLISE EXPLORATÓRIA	46
4.2	ALGORITMOS DE APRENDIZADO DE MÁQUINA	49

4.2.1	Configurações de amostragem dos eixos	50
4.2.2	Análise e seleção de <i>features</i>	51
4.2.3	Subconjuntos das amostras	56
5	CONCLUSÕES	61
5.1	SUGESTÕES PARA TRABALHOS FUTUROS	62
5.2	CRONOGRAMA DE ATIVIDADES	62
5.3	PREVISÃO FINANCEIRA E INFRAESTRUTURA	63
	Bibliografia	64

1 INTRODUÇÃO

A indústria moderna enfrenta desafios significativos com paradas e falhas inesperadas de equipamentos, impactando diretamente a produtividade e os custos operacionais. Um problema recorrente é a ocorrência de quebras, frequentemente provocadas por vibrações, que podem resultar em paradas catastróficas e danos severos aos componentes das máquinas. Essas interrupções não planejadas geram não apenas perda de produção, mas também altos custos de reparo e manutenção (RANDALL, 2011).

O desalinhamento, em particular, representa uma das principais causas de problemas em máquinas rotativas (DYNAMOX, 2022). Máquinas desalinhadas podem ser responsáveis por até 30% do tempo de inatividade dos equipamentos, além de aumentarem os custos operacionais devido ao desgaste acelerado dos componentes críticos (GANERIWALA; LI; RICHARDSON, 2008). Por isso, é essencial que a manutenção seja realizada para corrigir ou prevenir esse defeito.

A manutenção industrial pode ser abordada por estratégias distintas, como manutenção corretiva, preventiva e preditiva (DYNAMOX, 2024). Entre essas, a manutenção preditiva se destaca por permitir a identificação antecipada de falhas com base no monitoramento de parâmetros operacionais, como temperatura, partículas em lubrificantes, emissões acústicas e vibração (RANDALL, 2011). Zonta et al. (2020) ressaltam que a manutenção preditiva reduz os custos de manutenção de componentes de máquinas industriais, além de aumentar a confiabilidade, disponibilidade e segurança dos equipamentos.

Neste contexto, a análise de vibração se destaca como uma ferramenta essencial para a manutenção preditiva, permitindo a identificação antecipada de falhas potenciais (KUNDU; DARPE; KULKARNI, 2020). A detecção de padrões anômalos de vibração em estágios iniciais possibilita intervenções planejadas, reduzindo o tempo de máquina parada e melhorando a segurança e a eficiência dos processos. Tradicionalmente, os dados de vibração utilizados para a detecção de falhas são obtidos por meio de acelerômetros (MIAN; CHOUDHARY; FATIMA, 2023), que podem ser uniaxiais ou triaxiais. Ganeriwala (2023) mostrou que as informações de apenas um eixo de vibração em um único ponto do sistema não são suficientes para a classificação do sinal de desalinhamento. É necessário utilizar dados de sensores em múltiplos pontos, abrangendo eixos horizontais, axiais e verticais, para produzir indícios confiáveis do estado de saúde do maquinário.

A detecção do desalinhamento pode ser realizada por meio da identificação de padrões nos atributos do sinal de vibração associados ao domínio do tempo e ao espectro de frequência, utilizando técnicas de processamento de sinal para criar indicadores de saúde do equipamento. Essa falha é frequentemente observada com mudanças significativas nos múltiplos pares da frequência natural de um sistema vibratório (PIOTROWSKI, 2007). Entretanto, Sawalhi, Ganeriwala e Tóth (2019) demonstra que esse comportamento nem sempre ocorre em máquinas desalinhadas, e que a análise manual das alterações desses atributos não é suficientemente confiável. Isso reforça a necessidade de metodologias robustas que utilizem múltiplas informações para a detecção do defeito.

No contexto do monitoramento de condições por vibrações, a aplicação de algoritmos de aprendizado de máquina possibilita a detecção de defeitos por meio de um modelo de classificação binária que utiliza indicadores de saúde como *features*, propriedades mensuráveis dos sinais, para categorizar amostras

como saudáveis ou defeituosas (SIKORA, 2024). O aprendizado de máquina apresenta como vantagem a capacidade de identificar padrões nos dados de vibração associados ao defeito, permitindo que o algoritmo aprenda o comportamento do maquinário a partir das *features*. A classificação por aprendizado de máquina pode ser dividida em aprendizado supervisionado, não supervisionado e por reforço (REZAZADEH; LUCA; PERFETTO, 2022). Este trabalho foca no aprendizado supervisionado, que utiliza conjuntos de dados rotulados para treinar algoritmos de classificação.

Dado o impacto do desalinhamento na indústria, este trabalho tem como objetivo desenvolver uma metodologia para a detecção de desalinhamento em máquinas rotativas utilizando análise de vibração e algoritmos de aprendizado de máquina. A metodologia proposta envolve a coleta de dados experimentais com o uso de dois acelerômetros triaxiais, a extração de *features* que caracterizam os sinais e a aplicação de modelos de aprendizado de máquina para classificar os estados de alinhamento das máquinas. Os experimentos foram realizados utilizando um simulador de falhas para a coleta de dados, localizado no Laboratório de Vibração e Acústica (LVA) da Universidade Federal de Santa Catarina (UFSC), em parceria com a empresa *Dynamox*, colaboradora do projeto.

1.1 MOTIVAÇÃO

Desalinhamentos em máquinas rotativas geram vibrações excessivas que impactam diretamente a produtividade e a durabilidade dos equipamentos. O uso de aprendizado de máquina aplicado à análise de vibração visa detectar desalinhamentos de forma preditiva, possibilitando intervenções planejadas e redução do tempo de inatividade. Dessa forma, este trabalho busca desenvolver uma metodologia mais eficiente para a detecção de desalinhamento utilizando dados de vibração coletados experimentalmente, com a principal motivação de posterior utilização desses algoritmos em indústrias, evitando falhas catastróficas e períodos prolongados de inatividade.

1.2 OBJETIVOS

O presente trabalho tem como objetivo geral o desenvolvimento de uma metodologia para a detecção de desalinhamento em máquinas rotativas, utilizando sinais de vibração e algoritmos de aprendizado de máquina. Com essa metodologia, espera-se contribuir para a manutenção preditiva, permitindo ações corretivas antes que as falhas se tornem críticas, reduzindo o tempo de parada da produção, assim como falhas catastróficas e os custos associados.

1.2.1 Objetivos específicos

Dentro da proposta principal, são identificados objetivos específicos para cada etapa do projeto. Estes são:

1. Criação de um banco de dados de desalinhamento em diversas condições, com variação de acoplamento, velocidade de rotação do eixo, tipo e intensidade de desalinhamento.
2. Extração e seleção de *features* do domínio do tempo, de órbita e do domínio da frequência, com correlação com desalinhamento.

3. Implementação de modelos de aprendizado de máquina para classificar dados de vibração entre sinais saudáveis (alinhados) e desalinhados.
4. Comparação dos resultados dos modelos de aprendizado de máquina quando treinados e testados utilizando sinais uniaxiais dos sensores com algoritmos que empregam dados triaxiais para a classificação.
5. Análise e seleção das *features* mais relevantes para a classificação.
6. Análise do desempenho dos algoritmos de aprendizado de máquina quando treinados e testados considerando diferentes subconjuntos, visando compreender a capacidade de generalização dos dados.

1.3 ESTRUTURA DO DOCUMENTO

Este trabalho está organizado em cinco capítulos, abrangendo desde a revisão bibliográfica até a apresentação dos resultados obtidos e as considerações finais, incluindo propostas para futuras pesquisas. O conteúdo do documento envolve uma discussão sobre os conceitos, métodos e análises relacionados ao desalinhamento de eixos, bem como o uso de técnicas de aprendizado de máquina para sua detecção. O capítulo 1 aborda a introdução, motivação e objetivos do trabalho.

No capítulo 2, é realizada uma revisão abrangente dos principais tópicos que fundamentam o estudo, incluindo uma revisão bibliográfica e uma explanação detalhada sobre os conceitos de desalinhamento de eixos. São também discutidas as características esperadas dos impactos do desalinhamento na vibração e as peculiaridades de um sinal desalinhado, conforme a literatura da área. Além disso, são introduzidos os diferentes domínios de análise e as *features* usadas para caracterizar os sinais dentro desses domínios. Ademais, dentro do contexto de aprendizado de máquina, é detalhado o funcionamento desses algoritmos, os conceitos de classificação de dados e de aprendizado supervisionado, as métricas avaliativas utilizadas e uma visão geral dos modelos empregados.

O capítulo 3 descreve os ensaios experimentais conduzidos, fornecendo informações sobre a configuração da bancada de testes, os sistemas de aquisição de dados e os procedimentos experimentais adotados. Também é apresentado o fluxograma metodológico utilizado ao longo da pesquisa, detalhando a metodologia empregada nas etapas de extração de dados, análise exploratória, processamento dos sinais, extração de *features*, treinamento e teste de modelos de aprendizado de máquina, comparação dos resultados, seleção e análise das *features*.

O capítulo 4 é dedicado à apresentação e discussão dos resultados obtidos. Neste capítulo, é feita uma análise exploratória dos sinais em diversos domínios e das *features* processadas, além de uma descrição dos resultados dos testes dos modelos de aprendizado de máquina treinados em diferentes configurações e divisões, bem como uma análise e seleção das *features* mais impactantes.

O capítulo 5 apresenta as conclusões do trabalho e oferece direções para pesquisas futuras, posicionando-se como um documento de referência para manutenção preditiva e detecção de desalinhamento de eixos.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo visa esclarecer os conceitos fundamentais relacionados ao desalinhamento de eixos, abrangendo os diferentes tipos de desalinhamento e os métodos de detecção envolvidos. Busca-se, assim, estabelecer uma base sólida para a discussão subsequente sobre o desenvolvimento de uma metodologia que utiliza aprendizado de máquina para a classificação entre amostras de sinais contendo alinhamento e desalinhamento de eixos.

Para esta revisão, foi conduzida uma busca detalhada de artigos científicos na base *SCOPUS*, utilizando o acesso institucional da Universidade Federal de Santa Catarina para aplicar filtros de palavras-chave específicos. Como complemento, o *Google Scholar*, *ResearchGate* e o *ScienceDirect* foram consultados para a busca de artigos e livros relacionados ao tema de desalinhamento.

2.1 DESALINHAMENTO DE EIXOS

O desalinhamento de eixos ocorre quando as linhas de centro do eixo acionador e do eixo acionado não estão alinhadas ([MANCUSO, 1985](#)). Ele é provocado normalmente por montagem imprópria, carregamento excessivo, distorção térmica, afrouxamento dos parafusos ou desgastes nos elementos de apoio, como os acoplamentos, rolamentos e mancais ([PRUFTECHNIK LTD., 2002](#)). Sendo assim, mesmo máquinas totalmente alinhadas não conseguem reter essa característica por um longo período de tempo, devido à vibração na base, sistemas de lubrificação, compressão de gases e geração de calor ([WU; CHUNG, 2009](#)). Ademais, o desalinhamento provoca o desgaste de rolamentos, deformações e flexão nos eixos (Figura 1), deformação no rotor, além de aumento de temperatura excessivo, rachaduras no eixo e danos nos mancais ([BEHERA; BEHERA; NAIKAN, 2014](#)).




Figura 1 – Flexão de um eixo desalinhado com um torque de 400 Nm.

Fonte: ([MURA; CURÀ; MOLFETTA, 2018](#)).

O desalinhamento provoca diversas consequências no sistema vibratório afetado. Uma significativa mudança na matriz de rigidez do sistema provocada pelo desalinhamento pode ser observada no maquinário desalinhado ([REZAZADEH; LUCA; PERFETTO, 2022](#)). Isso ocorre porque o momento fletor nos eixos depende da rigidez, que varia durante a revolução devido ao desalinhamento, provocando deflexões flutuantes ao longo do eixo. Dessa maneira, dependendo do tipo de desalinhamento, este defeito pode provocar também um aumento nas vibrações axiais no sistema, sendo uma característica do desalinhamento angular ([RANDALL, 2011](#)).

2.1.1 Tipos de desalinhamento

O desalinhamento pode ser classificado entre paralelo, angular e combinado, como visto na Figura 2. O desalinhamento paralelo pode ocorrer horizontalmente e verticalmente, caracterizando-se pelo afastamento paralelo das linhas centrais dos eixos (DYNAMOX, 2022). Esse tipo de desalinhamento pode manifestar-se de forma bidirecional, quando ocorre simultaneamente nas direções horizontal e vertical. Da mesma forma, o desalinhamento angular é o resultado de um desvio angular entre as linhas centrais dos eixos. Em geral, o desalinhamento angular causa a degradação do acoplamento, enquanto o desalinhamento paralelo provoca o desgaste de rolamentos (JESSE et al., 1999).




Figura 2 – Desalinhamento paralelo, angular e combinado.

Fonte: (DYNAMOX, 2022).

2.2 MONITORAMENTO DE CONDIÇÃO DE DESALINHAMENTO BASEADO EM VIBRAÇÃO

Esta seção descreve as metodologias de manutenção industrial e as técnicas de processamento de sinais com o objetivo de monitorar a condição de alinhamento dos eixos, através da extração de *features* que caracterizam as amostras como defeituosas ou saudáveis, assim como descrever os domínios de análise de sinais de vibração. As três principais formas de manutenção aplicadas na indústria são a corretiva, preventiva e preditiva. A primeira consiste no conserto de componentes e maquinários após a ocorrência da falha. Já a preventiva é baseada em manutenções programadas em intervalos fixos pré-definidos, com o objetivo de evitar falhas e degradações dos equipamentos. A principal diferença entre a manutenção preventiva e a preditiva é que esta é baseada na necessidade de correções devido ao estado real do maquinário, obtido por monitoramento de condições (SETHIYA, n.d.). Dessa forma, o monitoramento de condições é essencial para a estratégia de manutenção preditiva, para que a revisão e possível correção dos maquinários seja efetuada em tempo otimizado.

Normalmente, a vibração é amplamente utilizada para o monitoramento de condição em ativos devido à sua capacidade de fornecer informações sobre o estado operacional das máquinas, com resposta ao defeito mais imediata do que outras ferramentas, como análise de temperatura ou análise de lubrificante (GUPTA; GUPTA; PERFETTO, 2019). De maneira tradicional, o mapeamento dos defeitos em máquinas rotativas por análise de vibração é efetuado com reconhecimentos manuais de mudanças nos padrões dos sinais provocados pelas falhas nos sistemas e subsistemas, com a visualização de gráficos no domínio do tempo e o espectro da frequência (JARDINE; LIN; BANJEVIC, 2006). Entretanto, a detecção manual necessita de profissionais qualificados e, muitas vezes, carece de confiabilidade. Dessa maneira, para

automatizar a detecção de falhas, como o desalinhamento, são extraídas *features* dos sinais de vibração, que são indicadores de condição de saúde dos componentes analisados. Essas *features* podem ser utilizadas posteriormente para treinar modelos de aprendizado de máquina para a classificação dos dados (KORBICZ et al., 2004).

2.2.1 Features no domínio do tempo

O domínio temporal de um sinal de vibração, que representa a variação do nível de vibração ao longo do tempo, pode ser utilizado para a detecção de desalinhamento em sistemas rotativos. No entanto, a análise do sinal bruto no domínio do tempo isoladamente não permite a distinção clara entre condições de alinhamento e desalinhamento, como ilustrado na Figura 3. Isso ocorre porque a resposta do sinal de vibração ao desalinhamento depende de múltiplos fatores, incluindo o grau e tipo do desalinhamento, o desgaste do acoplamento, a velocidade de rotação, a carga aplicada, o diâmetro do eixo e a rigidez dinâmica, que varia conforme o tipo de acoplamento utilizado (BAI; GANERIWALA; SAWALHI, 2019). Além disso, há uma dificuldade em isolar a informação característica do defeito a partir do sinal bruto, o que dificulta a detecção de falhas em máquinas rotativas quando apenas essas informações são utilizadas (KIM et al., 2021).




Figura 3 – Sinal de desalinhamento no domínio do tempo em vermelho e de alinhamento em verde. Acoplamento espiral, 1750 rpm, eixo de 0,75 polegadas de diâmetro.

Fonte: Bai, Ganeriwala e Sawalhi (2019).

Dessa forma, a extração de *features*, que são características específicas, mensuráveis e calculáveis do sinal, torna-se uma abordagem útil, pois a variação dessas *features* pode indicar desalinhamento dos eixos em um contexto de classificação. No domínio do tempo, a maioria dessas *features* consiste em métricas estatísticas do sinal, como descrito por (JANG et al., 2023), Yang, Mathew e Ma (2003) e Sikora (2024).

- **Valor *RMS*:** valor eficaz de um sinal, que representa a intensidade de energia de um sinal de vibração. Essa *feature* é definida como

$$X_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}, \quad (2.1)$$

em que N é a quantidade de pontos total do sinal e x_i é o i -ésimo ponto.

- **Valor pico a pico (*pk_pk*):** valor máximo do sinal menos o valor mínimo, sendo uma métrica de amplitude do sinal. Esse valor pode ser calculado como

$$pk_pk = \max(x) - \min(x), \quad (2.2)$$

em que x é o sinal no domínio do tempo.

- **Desvio padrão (σ):** grau de dispersão de um sinal, e pode ser calculado como

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad (2.3)$$

em que N é a quantidade de pontos, x_i é o valor do i -ésimo ponto e $\bar{x}$ é a média aritmética dos valores do sinal, calculada como

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i. \quad (2.4)$$

- **Assimetria (β_1 ou skewness):** mede a assimetria da distribuição de um sinal. A assimetria é definida como

$$\beta_1 = \frac{\frac{1}{N} \sum_{i=1}^N x_i^3}{\sigma^3}, \quad (2.5)$$

em que N é a quantidade de pontos, x_i é o valor do i -ésimo ponto e σ é o desvio padrão do sinal.

- **Curtose (β_2 ou kurtosis):** mede a altura e a largura da distribuição de um sinal, e é calculada como

$$\beta_2 = \frac{\frac{1}{N} \sum_{i=1}^N x_i^4}{\sigma^4}, \quad (2.6)$$

em que N é a quantidade de pontos, x_i é o valor do i -ésimo ponto e σ é o desvio padrão do sinal.

- **Fator de crista (FC ou crest factor):** divisão entre o pico máximo de amplitude e o valor RMS do sinal. Esta métrica é a medida em que a amplitude de pico de uma forma de onda excede o valor RMS ou a média. Este fator é calculado como

$$FC = \frac{\max |x|}{X_{\text{RMS}}}, \quad (2.7)$$

em que N é a quantidade de pontos e x_i é o valor do i -ésimo ponto.

- **Fator de forma (shape factor):** razão entre o RMS e a média do sinal absoluto. Dessa forma, ele é definido por

$$\text{Fator de forma} = \frac{X_{\text{RMS}}}{\frac{1}{N} \sum_{i=1}^N |x_i|}, \quad (2.8)$$

em que N é a quantidade de pontos e x_i é o valor do i -ésimo ponto.

- **Fator de impulso (impulse factor):** caracteriza a espinhosidade de um sinal, identificando transientes e impulsos de alta energia. Dessa forma, o fator de impulso é calculado como

$$\text{Fator de impulso} = \frac{\max |x|}{\frac{1}{N} \sum_{i=1}^N |x_i|}, \quad (2.9)$$

em que N é a quantidade de pontos e x_i é o valor do i -ésimo ponto.

- **Fator de folga (clearance factor):** razão entre o valor máximo absoluto do sinal e o quadrado da média das raízes quadradas dos valores absolutos. Fornece informações sobre sua distribuição de amplitude, e é calculado como

$$\text{Fator de folga} = \frac{\max |x_i|}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right)^2}, \quad (2.10)$$

em que N é a quantidade de amostras e x_i é o valor da i -ésima observação da amostra.

Ademais, a análise de órbita pode facilitar a detecção de desalinhamento (MONTE; VERBELEN; VERVISCH, 2014). A órbita consiste em uma representação gráfica em formato de elipse, em duas ou três dimensões, da vibração de um eixo rotacional, permitindo a relação das informações dos eixos. Para a detecção de desalinhamento, conforme definido por Jalan, Patil e Mittal (2020), é comum utilizar um filtro passa-banda nas componentes de frequência de primeira e segunda harmônicas ($1X$ e $2X$), que são múltiplos inteiros da frequência fundamental de rotação do sistema rotativo. Assim, o desalinhamento altera o formato da órbita, e na Figura 4 é possível observar que o desalinhamento aparece como um formato de "número oito" (JORDAN, 1993), enquanto um sinal saudável costuma apresentar um formato elíptico (Figura 5).




Figura 4 – Órbita com três dimensões, com desalinhamento angular, com velocidade de rotação de 25 Hz, com o filtro passa banda em $1X$ (a), $2X$ (b) e em ambos (c).

Fonte: Jalan, Patil e Mittal (2020).




Figura 5 – Órbita com três dimensões em um sinal saudável, com velocidade de rotação de 25 Hz, com o filtro passa banda em $1X$ (a), $2X$ (b) e em ambos (c).

Fonte: Jalan, Patil e Mittal (2020).

É possível extrair as seguintes *features* da geometria da órbita em duas dimensões, que Bachschmid, Pennacchi e Vania (2004) define:

- **Amplitude maior e menor (a_1 e a_2 , respectivamente):** amplitude máxima e mínima da elipse formada pela órbita, definida como

$$a_1, a_2 = \sqrt{\frac{2(x_q y_d - x_d y_q)^2}{y_q^2 + y_d^2 + x_q^2 + x_d^2 \pm \sqrt{(y_q^2 + y_d^2 - x_q^2)(y_q^2 + y_d^2 - x_d^2)}}}, \quad (2.11)$$

em que X_d e Y_d representam a parte real dos sinais analíticos¹ de vibração em eixos ortogonais num ponto, e X_q e Y_q representam a parte imaginária.

¹ O sinal analítico é uma representação complexa de um sinal real $x(t)$, obtida a partir do mesmo sinal real $x(t)$ acrescido de sua transformada de Hilbert $\mathcal{H}\{x(t)\}$ como a parte imaginária, definido por Shin e Hammond (2008).

- **Shape and Directivity Index (SDI)**: grau de elipsicidade da órbita, calculada como

$$SDI = \frac{a_1}{a_2}, \quad (2.12)$$

em que a_1 é a amplitude menor e a_2 é a amplitude maior. Um valor de SDI próximo de 1 indica que a órbita tem formato elíptico, enquanto valores próximos de 0 indicam que a órbita se assemelha a uma linha.

- **Ângulo de Inclinação (φ)**: ângulo do maior eixo da elipse em relação ao eixo X , definida como

$$\varphi = \frac{1}{2} \tan^{-1} \frac{2(x_d y_d + x_q y_q)}{x_d^2 + x_q^2 - y_d^2 - y_q^2}, \quad (2.13)$$

em que X_d e Y_d representam a parte real dos sinais analíticos de vibração em eixos ortogonais num ponto, e X_q e Y_q representam a parte imaginária.

- **Área da órbita**: área da elipse formada pela órbita, calculada como

$$\text{Área da órbita} = \pi r_1 r_2, \quad (2.14)$$

em que r_1 é o raio da amplitude menor e r_2 é o raio da amplitude maior.

2.2.2 Features no domínio da frequência

A análise do domínio da frequência é uma ferramenta fundamental no monitoramento de vibrações. O espectro de um sinal pode ser obtido com o uso da Transformada Rápida de Fourier (*FFT*), que é um algoritmo computacional otimizado que computa a Transformada Discreta de Fourier (*DFT*) de maneira eficiente. A *DFT* é uma transformada que permite converter um sinal discreto no domínio do tempo para o domínio da frequência, decompondo um sinal em suas componentes de frequência. [Shin e Hammond \(2008\)](#) define a *DFT* como

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j \frac{2\pi}{N} nk}, \quad (2.15)$$

em que $e^{-j \frac{2\pi}{N} nk}$ representa a exponencial complexa, que decompõe o sinal em suas componentes de frequência, $x(n)$ é o sinal no domínio do tempo em cada ponto, N é a quantidade de pontos e k é a frequência. Dessa forma, [\(SHIN; HAMMOND, 2008\)](#) define a magnitude do espectro como

$$|X(k)| = \sqrt{\text{Re}(X(k))^2 + \text{Im}(X(k))^2}, \quad (2.16)$$

em que $|X(k)|$ é a magnitude na componente de frequência, que representa a intensidade ou amplitude de vibração da frequência k no sinal original, $\text{Re}(X(k))$ é a parte real da componente $X(k)$, correspondendo à contribuição da onda cossenoide para essa frequência, e $\text{Im}(X(k))$ é a parte imaginária da componente $X(k)$, representando a contribuição da onda senoide para essa frequência.

Em máquinas rotativas, aplicando-se a transformada de Fourier, em geral, o espectro de vibração desses maquinários é caracterizado pelas componentes associadas à frequência de rotação, os harmônicos. Normalmente, espera-se que um aumento na segunda harmônica ($2X$) ocorra para o desalinhamento paralelo, enquanto no desalinhamento angular é esperada uma resposta na primeira frequência de rotação

(1X) na direção axial (LEES, 2007), como visto na Figura 6. Entretanto, essa generalização, apesar de ser amplamente aceita, não é adequada (SAWALHI; GANERIWALA; TÓTH, 2019). Isso porque casos em que essas componentes não se destacam como resposta ao desalinhamento são extremamente frequentes. Dessa forma, Ganeriwala (2023) sugere que, para a detecção de desalinhamento, é ideal utilizar informações triaxiais de vibração, porque as informações de apenas um eixo não são suficientes para a classificação.




Figura 6 – Frequências de rotação para o desalinhamento angular e desalinhamento paralelo.

Fonte: Alsalaet (2015).

Assim como no domínio do tempo, é possível extrair *features* do domínio da frequência para a caracterização do sinal. Sikora (2024) define:

- **Pico das harmônicas 1X, 2X, 3X, 4X e 5X (*harmonic_peaks*)**: magnitude do espectro da frequência, conforme equação (2.16), ou seja, $|X(F_i)|$, em que F_i representa a i -ésima frequência de rotação, definida como

$$F_i = \frac{\text{RPM}}{60} \cdot i. \quad (2.17)$$

- **Pico espectral (X_{max} ou *spectral peak*)**: valor máximo do espectro da magnitude, definido como

$$X_{max} = \max(X(k)), \quad (2.18)$$

em que X_{max} é o pico espectral e $X(k)$ representa a magnitude do espectro em função da frequência k .

- **Planicidade espectral (S)**: é a razão entre a média geométrica e a média aritmética do espectro da magnitude. Pode ser calculada como

$$S = \frac{\sqrt[N]{x_1 x_2 \cdots x_N}}{\frac{1}{N} \sum_{i=1}^N x_i}, \quad (2.19)$$

em que S representa a planicidade espectral, x_i é o i -ésimo ponto da magnitude espectral, e N é o número total de pontos. Essa métrica é utilizada para avaliar o quão semelhante a um ruído é o sinal. Um valor de planicidade espectral igual a um indica que o espectro do sinal se assemelha ao de um ruído branco (DUBNOV, 2004).

- **RMS Carpet (RMS_c)**: raiz média quadrática do valor RMS , sendo calculado como

$$RMS_c = \sqrt{\frac{1}{N} \sum_{j=1}^N |X_j|^2}, \quad (2.20)$$

em que RMS_c representa o valor *RMS carpet*, X_j é o j -ésimo ponto no domínio da frequência, e N é o número total de pontos.

2.3 APRENDIZADO DE MÁQUINA

Aprendizado de máquina é um campo da inteligência artificial que permite que sistemas computacionais aprendam e se aprimorem com base em dados, sem serem explicitamente programados, com o objetivo de desenvolver algoritmos de reconhecimento de padrões, que façam previsões ou classificações baseadas em dados de entrada (CARBONELL; MICHALSKI; MITCHELL, 1983). O presente trabalho é focado no desenvolvimento de um algoritmo de classificação binária.

2.3.1 Classificação binária

A classificação binária consiste na categorização de uma amostra de uma população em duas classes. Dessa forma, um modelo de classificação binária segue a estruturação de um fluxo de trabalho. Esse fluxo estruturado (Figura 7) descreve o processo de classificação, passando pela obtenção de dados que compõem o banco de dados, a extração de *features*, a implementação e configuração dos modelos de aprendizado de máquina, o treinamento dos algoritmos, a classificação das amostras e a análise das *features* e do desempenho através das métricas geradas pelo modelo (TAMASCELLI; PALTRINIERI; COZZANI, 2020).




Figura 7 – Fluxograma de trabalho de aprendizado de máquina de classificação.

Fonte: Tamascelli, Paltrinieri e Cozzani (2020).

Ademais, o aprendizado de máquina supervisionado é uma abordagem em que um modelo é treinado utilizando um conjunto de dados rotulado, ou seja, cada amostra de dados é acompanhada por um rótulo (*label*) que indica a classe correspondente. Diversos algoritmos de aprendizado supervisionado estão disponíveis em bibliotecas de *Python* de código aberto (*open source*) (SCIKIT-LEARN, 2024b), como a regressão logística, as máquinas de vetores de suporte (*SVM*), as florestas aleatórias de classificação (*Random Forest*) e o *XGBoost*.

2.3.2 Divisão de treino, teste e validação

O treino de um algoritmo de aprendizado de máquina de aprendizagem supervisionada é o processo no qual um modelo é alimentado com dados rotulados para aprender padrões e fazer previsões ou classificações com base nesses dados. Para o treino e avaliação de um modelo de aprendizado de máquina, o banco de dados é dividido em conjuntos de treino, teste e validação (GÉRON, 2019). O conjunto de treino é utilizado para treinar o modelo, permitindo que o algoritmo aprenda as relações entre características e rótulos. Este conjunto deve compreender a maior parte dos dados, geralmente entre 60% e 80% das amostras. Uma maior quantidade de dados disponíveis para o treino aumenta a capacidade do modelo de capturar padrões complexos e de generalização para novos dados, evitando o *overfitting*, que é o ajuste excessivo do algoritmo aos dados de treinamento. Isso ocorre porque, com mais dados, o modelo é exposto a uma maior diversidade de exemplos, reduzindo a influência de padrões específicos presentes em amostras isoladas.

Ademais, o conjunto de validação é empregado para ajustar hiperparâmetros e decidir sobre a arquitetura do modelo. Hiperparâmetros são configurações externas de um modelo de aprendizado de máquina que não são aprendidas diretamente a partir dos dados, mas que precisam ser definidas antes do treinamento, influenciando diretamente o desempenho do modelo (KUHN; JOHNSON, 2013). Esse conjunto fornece uma avaliação intermediária do desempenho do modelo durante o treinamento, contribuindo para a mitigação do *overfitting*. Normalmente, o conjunto de validação representa cerca de 10% a 20% dos dados.

A validação cruzada *K-Fold*, representada na Figura 8, é uma técnica que visa aprimorar a avaliação do modelo e otimizar a utilização dos dados disponíveis. Para isso, o conjunto de dados é dividido em K subconjuntos (*folds*) de tamanhos aproximadamente iguais. O modelo é treinado K vezes, utilizando $K - 1$ subconjuntos como dados de treino e o subconjunto restante como dados de validação (JAMES et al., 2013). Durante esse processo, os hiperparâmetros do modelo podem ser ajustados utilizando técnicas de busca, como o *GridSearch* ou *RandomSearch*, que exploram diferentes combinações de hiperparâmetros para encontrar a configuração que otimiza o desempenho do modelo. Após as iterações, os melhores hiperparâmetros são encontrados e são utilizados no teste para o cálculo das métricas de desempenho.

Também, é possível utilizar o *Stratified Group K-Fold*, uma variante desse método, que garante que todos os dados da mesma amostra estejam alocados no mesmo conjunto, evitando vazamento de informações entre treino, teste e validação. Além disso, essa abordagem cria *folds* com a mesma proporção entre as classes, o que é vantajoso quando se lida com dados com classes desbalanceadas. Isso assegura que o modelo seja treinado e validado de forma representativa, sem viés em relação a uma classe minoritária (PEDREGOSA et al., 2024). Além disso, o conjunto de teste é utilizado para avaliar o desempenho final do modelo. Os dados deste conjunto não devem ter sido utilizados nas fases anteriores e, comumente, possuem um número de amostras semelhante ao do conjunto de validação.




Figura 8 – Representação da validação cruzada (*K-Fold*).

Fonte: [Scikit-learn \(2024a\)](#).

2.3.3 Regressão logística

A regressão logística é um modelo estatístico utilizado para prever a probabilidade de um determinado evento ocorrer. Dessa maneira, ela aplica uma combinação linear das *features* em uma função sigmoideal para mapear a saída linear do modelo em um intervalo de 0 a 1, o que representa a probabilidade de pertencimento a uma das classes ([BISHOP, 2006](#)). Define-se a função sigmoideal:

$$\sigma(z) = \frac{1}{1 + e^{-(x_i - \mu)/s}}, \quad (2.21)$$

em que μ é a média da distribuição da probabilidade, x_i é a i -ésima *feature* de entrada e s é um parâmetro de escala. Um limiar (*threshold*) é estabelecido ao longo da curva sigmoideal (Figura 9). Esse limiar serve como um ponto de decisão que determina a classificação final das amostras entre as classes ([RAJ, 2023](#)).




Figura 9 – Representação de uma regressão logística.

Fonte: [Raj \(2023\)](#).

2.3.4 SVM

O *SVM* é um algoritmo de aprendizado de máquina supervisionado que classifica as amostras identificando o hiperplano que melhor separa as classes no espaço de *features*. Esse hiperplano é escolhido de forma a maximizar a margem entre as classes, representada pela distância mínima entre o hiperplano e os pontos de cada classe mais próximos a ele, conhecidos como vetores de suporte, como visto na Figura 10. Ao maximizar essa margem, reduz-se o risco de erro na classificação, aumentando a generalização do modelo (SMOLA; SCHÖLKOPF, 2004). Para casos em que os dados não são linearmente separáveis, o *SVM* utiliza *kernels* (SCHÖLKOPF et al., 2000), que transformam os dados para um espaço de dimensão superior, em que a separação linear pode se tornar viável. Os *kernels* podem ter comportamentos linear, polinomial, radial (RBF) ou sigmoidal.




Figura 10 – Representação de uma classificação por *SVM*. As coordenadas representadas neste gráfico são ilustrativas e têm escalas arbitrárias.

Fonte: [scikit-learn developers \(2024\)](#).

2.3.5 Árvores de decisão e florestas aleatórias de decisão

Árvores de decisão (Figura 11) são algoritmos de aprendizado supervisionado que utilizam uma estrutura hierárquica para dividir os dados em grupos com base em regras de decisão simples. O modelo é composto por nós internos e terminais, onde cada nó interno representa uma *feature* usada para realizar uma divisão, e cada ramo indica um possível resultado dessa divisão. O processo de divisão continua até atingir um nó terminal, representado por uma folha, que define a classificação final. Embora seja um método bastante eficiente, árvores de decisão simples podem se ajustar demais aos dados de treino, o que limita sua capacidade de generalização (SCIKIT-LEARN, 2024b).




Figura 11 – Representação de uma árvore de decisão.

Fonte: Sarker (2021).

O algoritmo de Random Forest utiliza várias árvores de decisão para obter previsões, criando subgrupos aleatórios dos dados e treinando uma árvore de decisão em cada amostra. As previsões de todas as árvores são combinadas por meio de votação majoritária no caso da classificação, o que resulta em um modelo mais preciso e com melhor capacidade de generalização em comparação às árvores de decisão individuais (SCIKIT-LEARN, 2024a). No entanto, isso eleva consideravelmente os custos computacionais em relação a outros algoritmos (IBM, 2024). A floresta aleatória emprega uma técnica de *ensemble*, especificamente o *bagging*, em que múltiplos modelos são treinados de forma independente e suas previsões são combinadas para melhorar a performance (DEVELOPERS, 2024). O *boosting*, outro método de *ensemble*, será abordado na próxima seção, relacionada ao algoritmo de *XGBoost*.

2.3.6 XGBoost

O algoritmo de *XGBoost* (*Extreme Gradient Boosting*) utiliza a técnica de *ensemble* de *boosting*, treinando modelos sequencialmente, onde cada modelo subsequente foca na correção dos erros do modelo anterior (CHEN; GUESTRIN, 2016). Esse modelo reduz o *overfitting* através de um processo de otimização da função de perda utilizando gradiente descendente (KWIATKOWSKI, 2021). A função de perda quantifica a discrepância entre as previsões do modelo e os valores reais, sendo minimizada durante o treinamento (WALD, 1950). Dessa maneira, o diferencial desse algoritmo está na forma como esses elementos são aplicados na construção das árvores sequenciais, com ênfase na correção progressiva dos erros.

2.3.7 Métricas de classificação binária

As definições de métricas utilizadas neste trabalho foram retiradas de (CARVALHO; PEREIRA; CARDOSO, 2019). Os verdadeiros positivos (*TP*) referem-se a instâncias em que o modelo corretamente classifica uma amostra como pertencente à classe positiva, enquanto os verdadeiros negativos (*TN*) são

aqueles em que o modelo corretamente identifica uma amostra como pertencente à classe negativa. Por outro lado, os falsos positivos (FP) ocorrem quando o modelo classifica erroneamente uma amostra negativa como positiva, e os falsos negativos (FN) são casos em que o modelo não consegue identificar uma amostra positiva, classificando-a incorretamente como negativa.

Dessa forma, essas métricas podem ser representadas em uma matriz de confusão (Figura 12), que é uma ferramenta comum para avaliar o desempenho de modelos de classificação. A matriz de confusão apresenta uma tabela que compara as previsões do modelo com os valores reais, permitindo visualizar o número de classificações corretas e incorretas feitas pelo modelo em cada classe.

A taxa de verdadeiros positivos (TPR), também conhecida como sensibilidade, representa a proporção de instâncias positivas corretamente classificadas como positivas. Esta taxa é dada por:

$$TPR = \frac{TP}{TP + FN}, \quad (2.22)$$

em que TP é o número de verdadeiros positivos e FN é o número de falsos negativos.

Já a taxa de falsos positivos (FPR) indica a proporção de instâncias negativas incorretamente classificadas como positivas. Esta taxa é calculada como:

$$FPR = \frac{FP}{FP + TN}, \quad (2.23)$$

em que FP é o número de falsos positivos e TN é o número de verdadeiros negativos.




Figura 12 – Representação de um exemplo de uma matriz de confusão.

Fonte: Ruback, Avila e Cantero (2021).

A acurácia de um modelo de aprendizado de máquina é uma métrica que mede a proporção de classificações corretas, tanto para classes positivas quanto negativas, em relação ao total de amostras. Ela é dada por:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}. \quad (2.24)$$

No entanto, a acurácia pode ser enganosa, especialmente em conjuntos de dados desbalanceados. Isso leva à definição da acurácia balanceada, que pondera a contribuição de cada classe para a métrica, calculada como

$$\text{Acurácia balanceada} = \frac{TPR + FPR}{2}. \quad (2.25)$$

A curva *ROC* (*Receiver Operating Characteristic*), exemplificada na Figura 13, é uma ferramenta visual que ilustra a relação entre a taxa de verdadeiros positivos e a taxa de falsos positivos para diferentes limiares de decisão (*thresholds*) do classificador (THOMA, 2018). A área sob a curva *ROC* (*AUC* - *Area Under the Curve*) fornece uma medida única do desempenho do modelo. Valores mais altos de *AUC* indicam que o modelo tem uma melhor capacidade de discriminar entre as classes, pois quanto maior a *AUC*, maior a área sob a curva, o que significa que o modelo tem uma maior taxa de verdadeiros positivos e uma menor taxa de falsos positivos em uma ampla gama de limiares.




Figura 13 – Representação de uma curva *ROC* e do *threshold*.

Fonte: Prates (2020).

2.3.8 Explicações aditivas de *Shapley*

Os valores de *Shapley* (*SHAP*), fundamentados na teoria dos jogos (HART, 1989), quantificam a contribuição de cada característica para a previsão de um modelo, sendo, portanto, ferramentas úteis para a seleção de *features*. Esses valores são aditivos, pois são calculados considerando todas as combinações possíveis de características (LUNDBERG; LEE, 2021). Dessa forma, é possível realizar uma análise *SHAP*, como exemplificado na Figura 14.

No gráfico, a densidade dos pontos ao longo do eixo *X* a frequência com que valores *SHAP* específicos de uma *feature* aparecem nos dados. Um agrupamento denso de pontos em uma direção sugere que as previsões são influenciadas de maneira consistente por aquela característica. O eixo *Y* representa as *features* do modelo organizadas em ordem de influência, enquanto o eixo *X* mostra a contribuição de cada característica para a previsão entre as duas classes no modelo. Esses valores podem ser positivos ou negativos, indicando, respectivamente, a contribuição da *feature* para a predição da classe positiva ou da classe negativa. Neste trabalho, a classe positiva é o desalinhamento, enquanto a classe negativa representa a condição alinhada.

As cores no gráfico variam do vermelho, indicando valores altos da característica, ao azul, representando valores baixos. Por exemplo, um valor *SHAP* positivo destacado em vermelho indica que essa *feature* aumenta a probabilidade de o algoritmo classificar a amostra como desalinhada. No entanto, é importante

ressaltar que os valores *SHAP* não avaliam o desempenho geral do modelo, mas apenas quantificam a contribuição de cada *feature* para a previsão realizada.




Figura 14 – Exemplo de análise *SHAP*.

Fonte: [Lundberg e Lee \(2021\)](#).

3 MATERIAIS E MÉTODOS

Neste capítulo, serão apresentados os equipamentos, sensores, sistemas de captação de dados, simuladores e outras ferramentas experimentais utilizadas, bem como a metodologia empregada na obtenção dos dados, no treinamento dos modelos de aprendizado de máquina e na avaliação dos resultados. Todo o processo foi realizado no Laboratório de Vibração e Acústica (LVA) da Universidade Federal de Santa Catarina.

3.1 METODOLOGIA DE DETECÇÃO DE FALHAS DE DESALINHAMENTO DE EIXOS

A metodologia empregada para a detecção de falhas de desalinhamento de eixos neste trabalho segue uma estrutura (Figura 15) com três etapas principais. A primeira etapa, de extração de dados, consiste na coleta de sinais de vibração por meio de acelerômetros em uma bancada de simulação de falhas em máquinas rotativas, onde foram realizadas a definição da matriz de testes dos experimentos e a instrumentação da bancada. A segunda etapa envolve o processamento dos sinais e a extração de *features* com *scripts* em *Python*, permitindo a obtenção de informações no domínio do tempo e da frequência para posterior aplicação nos modelos de aprendizado de máquina. Na terceira etapa, a detecção de falhas foi realizada através de algoritmos de aprendizado de máquina, que classificam as amostras de forma binária em classes desalinhada (positiva) e saudável (negativa), utilizando as *features* extraídas como fonte de informação para a tomada de decisão.




Figura 15 – Fluxograma do trabalho.

Fonte: Autor.

3.2 SIMULADOR DE FALHAS EM MÁQUINAS

Com o objetivo de obter dados de vibração experimentalmente, foi utilizado o simulador *Machinery Fault Simulator (MFS)* da *SpectraQuest*. O *MFS* (Figura 16) é capaz de simular a interação dinâmica entre diversos defeitos por meio de experimentos controlados, permitindo a inserção de falhas como desalinhamento, desbalanceamento e engrenamentos defeituosos no sistema, viabilizando o estudo do comportamento de diferentes componentes de máquinas ([SPECTRAQUEST, s.d.](#)). Por ser um sistema modular, os componentes do simulador são substituíveis, possibilitando a troca de rolamentos, mancais, acoplamentos e outros ativos, bem como a inserção de polias, correias e caixas de engrenagem. Contudo, este trabalho se concentra na detecção de desalinhamento, e, por isso, esses elementos e defeitos adicionais não foram inseridos no sistema.

O simulador opera por meio de um inversor de frequência que aciona um motor elétrico responsável pelo controle da velocidade do sistema. Dois mancais de rolamentos sustentam um eixo conectado ao motor por um acoplamento. Os componentes desse simulador estão descritos na Tabela 1.




Figura 16 – *Machinery Fault Simulator* da *SpectraQuest*.

Fonte: Autor.

Tabela 1 – Componentes do simulador de desalinhamento.

Fonte: Autor.

Componentes do simulador de desalinhamento	
Componente	Especificação
Motor	Indução trifásico, 1 HP
Inversor	Frequência variável
Eixo	Aço torneado, retificado e polido, 3/4 pol. diâmetro
Mancais	Alumínio com rolamentos selados, elementos esféricos
Tacômetro	Display LCD, saída analógica 1 pulso/rev
Acoplamento	Flexível ou rígido

3.2.1 Configuração da bancada de testes

Para garantir o alinhamento inicial do simulador e obter uma intensidade precisa do desalinhamento adicionado, o sistema conta com dois pinos de alinhamento que impedem o movimento lateral da base, evitando o desalinhamento. Além disso, possui quatro manípulos para o controle do desalinhamento horizontal e dois para o ajuste do movimento axial da base. Parafusos adicionais fixam a base do mancal ao suporte da bancada. Dessa forma, o desalinhamento é introduzido no simulador utilizando calços metálicos, como mostrado na Figura 17. Esses calços, quando inseridos sob a base que sustenta os mancais (Figura 18), desnivelam o eixo acionado em relação ao eixo acionador do motor, gerando desalinhamento paralelo ou angular, dependendo do posicionamento dos calços.

O procedimento indicado por (SPECTRA QUEST, INC., 2010) foi seguido para inserir o desalinhamento nos experimentos e todos os itens descritos são representados nas Figuras 19 e 20, além de serem enumerados na Tabela 2. Define-se esse procedimento, que foi utilizado para todos os experimentos, com a diferença na posição e quantidade de calços metálicos :



Figura 17 – Calço metálico de 0.05 mm.

Fonte: Autor.




Figura 18 – Calços metálicos gerando o desnível no sistema.

Fonte: Autor.

1. Dois relógios comparadores foram utilizados para mensurar o desalinhamento residual na máquina, que deve estar dentro do limite de 0,002 mm.
2. Remoção os pinos de alinhamento.
3. Quatro manípulos de movimentação lateral e dois de movimentação axial foram girados até que a linha de índice coincida com a marca zero.
4. Parafusos da base foram levemente afrouxados para fornecer uma folga mínima para levantar ou abaixar a base do rotor, evitando ao máximo perturbar o ajuste horizontal.
5. Definição do nível de desalinhamento do experimento.
6. A base do rotor foi levemente levantada e foram inseridos uma quantidade de calços pré-determinada nos cantos da base. A quantidade e posição dos calços determina o tipo de desalinhamento.
7. Parafusos foram apertados.
8. A tampa protetora foi fechada.
9. O motor foi energizado, acionando a *MFS*. Dados de vibração foram coletados.
10. O realinhamento dos eixos foi feito removendo os calços adicionados.




Figura 19 – Vista de cima (a) e lateral (b) da *MFS*.

Fonte: Autor.



Figura 20 – Relógio comparador.

Fonte: Autor.

Tabela 2 – Componentes e descrições da *MFS*.

Fonte: Autor.

Componente	Descrição
1	Pino de alinhamento
2	Manípulo de movimentação lateral
3	Parafuso de fixação da base
4	Manípulo de movimentação axial
5	Tampa protetora

Com o objetivo de aumentar a diversidade dos dados disponíveis para os modelos de aprendizado de máquina e melhorar a generalização dos algoritmos, foi necessário obter informações sobre desalinhamentos paralelo e angular. Para isso, foram definidas as posições lado do acionamento frontal (LA_1), lado do acionamento posterior (LA_2), lado oposto ao acionamento frontal (LOA_1) e lado oposto ao acionamento posterior (LOA_2), conforme representado na Figura 21. Nessas posições, calços foram inseridos em quantidades e dimensões variáveis para criar diferentes desalinhamentos, categorizados em intensidades A (baixa), B (média) e C (alta), conforme descrito nas Tabelas 3, 4 e 5. Essas configurações definem o desalinhamento paralelo vertical, o desalinhamento paralelo bidirecional e o desalinhamento angular utilizados neste estudo.




Figura 21 – Posições dos calços na bancada.

Fonte: Autor.

Tabela 3 – Configurações dos calços para desalinhamento paralelo vertical.

Fonte: Autor.

Desalinhamento paralelo vertical			
Posição dos calços	Intensidade A (mm)	Intensidade B (mm)	Intensidade C (mm)
LA 1	0.05	0.3	0.55
LA 2	0.05	0.3	0.55
LOA 1	0.05	0.3	0.55
LOA 2	0.05	0.3	0.55

Tabela 4 – Configurações dos calços para desalinhamento paralelo bidirecional.

Fonte: Autor.

Desalinhamento paralelo bidirecional			
Posição dos calços	Intensidade A (mm)	Intensidade B (mm)	Intensidade C (mm)
LA 1	0.05	0.3	0.55
LA 2	0	0.05	0.3
LOA 1	0.05	0.3	0.55
LOA 2	0	0.05	0.3

Tabela 5 – Configurações dos calços para desalinhamento angular.

Fonte: Autor.

Desalinhamento angular			
Posição dos calços	Intensidade A (mm)	Intensidade B (mm)	Intensidade C (mm)
LA 1	0	0	0
LA 2	0	0	0
LOA 1	0.05	0.3	0.55
LOA 2	0.05	0.3	0.55

Dessa forma, o desalinhamento paralelo vertical foi obtido por meio da elevação vertical da base. Já o desalinhamento paralelo bidirecional, além da elevação vertical da base, apresentou um desnível entre o lado anterior e o posterior, resultando no deslocamento horizontal do eixo. Por fim, o desalinhamento angular foi criado ao introduzir um desnível entre o lado do acionamento e o lado oposto ao acionamento. Segundo [Krajňák et al. \(2021\)](#), o uso de acoplamentos flexíveis visa reduzir o nível de vibração no sistema. Além disso, [Bai, Ganeriwala e Sawalhi \(2019\)](#) destaca que o *design* ou tipo de acoplamento é um parâmetro fundamental para a vibração causada pelo desalinhamento. Portanto, neste estudo, foram utilizados dois tipos de acoplamentos, rígido e flexível (Figura 22), com o objetivo de diversificar as amostras e aumentar a capacidade de generalização dos modelos de aprendizado de máquina.



Figura 22 – Acoplamento flexível e acoplamento rígido, respectivamente.

Fonte: Autor.

3.3 INSTRUMENTAÇÃO DA BANCADA

Para obter os dados de vibração, foram utilizados dois acelerômetros triaxiais (Figura 23), com suas características informadas na Tabela 6. Eles foram posicionados acima dos mancais, sendo o primeiro no lado do acionamento e o segundo no lado oposto ao acionamento (Figura 24), e foram calibrados antes dos experimentos. Os sinais gerados pelos acelerômetros foram recebidos em duas placas de aquisição da *National Instruments NI-9234* (Figura 25), com características descritas na Tabela 7, dispostas em um chassi da mesma fabricante *cDAQ-9174* (Figura 26), com características dispostas na Tabela 8. Os dois acelerômetros triaxiais foram conectados, no total, em seis canais das placas. Dessa maneira, os dados foram comunicados para um computador através de um *script* em *Python*, que extrai os dados e gera as

informações obtidas. Foram também utilizados em todas as medições sensores de vibração da Dynamox, os *Dynaloggers*, cujos dados obtidos não foram aplicados neste trabalho, mas que serão utilizados em futuras pesquisas.

Tabela 6 – Características do acelerômetro triaxial DeltaTron com TEDS Tipo 4525-B.

Fonte: (B&K, 2024).

Características do acelerômetro triaxial DeltaTron com TEDS Tipo 4525-B	
Dimensão	21,1 mm (entrada do cabo) × 12,2 mm × 12,2 mm
Peso	6 g
Temperatura operacional	54 °C ≤ T ≤ 121 °C
Sensibilidade no eixo X	9,897 mV/g (1,009 mV/m/s²)
Sensibilidade no eixo Y	10,58 mV/g (1,079 mV/m/s²)
Sensibilidade no eixo Z	10,19 mV/g (1,039 mV/m/s²)
Faixa de frequência (±10%)	até 10 kHz
Faixa dinâmica	±500 g



Figura 23 – Acelerômetro triaxial *DeltaTron 4525-B*.

Fonte:(B&K, 2024).




Figura 24 – Acelerômetros e *Dynaloggers* posicionados acima dos mancais e sistema de coordenadas.

Fonte: Autor.



Figura 25 – Placa de aquisição NI-9234.
Fonte: Autor.

Tabela 7 – Especificações da placa de aquisição NI-9234.
Fonte: (NATIONAL INSTRUMENTS, 2023b).

Características da placa de aquisição NI-9234	
Número de Canais	4
Faixa Dinâmica	102 dB
Frequência máxima de amostragem	51.200 amostras/s



Figura 26 – Chassi CompactDAQ cDAQ-9174.
Fonte: Autor.

Tabela 8 – Especificações do chassi CompactDAQ cDAQ-9174.

Fonte: (NATIONAL INSTRUMENTS, 2023a).

Características do chassi CompactDAQ cDAQ-9174	
Peso	574 g
Dimensões	159.5 mm × 88.1 mm × 58.9 mm
Temperatura Operacional	-20 °C a 55 °C
Proteção de Ingresso	IP 30
Alimentação de Entrada	9 a 30 V
Consumo Máximo de Potência	15 W
Interface de Barramento	USB 2.0 Hi-Speed
Altitude Máxima	5.000 m

3.4 MATRIZ DE TESTES E PROCEDIMENTO EXPERIMENTAL

O experimento envolveu a medição de vibrações utilizando dois acelerômetros triaxiais instalados no *MFS*, operando em cinco velocidades distintas (500, 1000, 2000, 3000 e 4000 rpm). As medições foram realizadas com uma taxa de aquisição de 25600 Hz e duração de 30 segundos, gerando 768000 pontos por eixo. Os testes foram conduzidos com dois tipos de acoplamento (flexível e rígido) e em quatro condições de saúde: bancada alinhada, desalinhamento paralelo vertical, desalinhamento paralelo bidirecional e desalinhamento angular. Para cada tipo de desalinhamento, foram avaliadas três intensidades, conforme descrito nas Tabelas 3, 4 e 5. No total, foram realizadas 100 medições, sendo 10 em condições saudáveis e 30 para cada tipo de desalinhamento, resultando em 600 amostras. A Tabela 9 apresenta a matriz de testes, enquanto a Tabela 10 detalha as amostras coletadas.

Tabela 9 – Matriz de testes.

Fonte: Autor.

Desalinhamento	Intensidade	Acoplamento	Velocidades (rpm)	Acelerômetros
Saudável	0	Flexível, Rígido	500, 1000, 2000, 3000, 4000	<i>LA</i> e <i>LoA</i>
Paralelo Vertical	A, B, C	Flexível, Rígido	500, 1000, 2000, 3000, 4000	<i>LA</i> e <i>LoA</i>
Paralelo Bidirecional	A, B, C	Flexível, Rígido	500, 1000, 2000, 3000, 4000	<i>LA</i> e <i>LoA</i>
Angular	A, B, C	Flexível, Rígido	500, 1000, 2000, 3000, 4000	<i>LA</i> e <i>LoA</i>

Tabela 10 – Amostras a serem obtidas.

Fonte: Autor.

Desalinhamento	Número de Amostras	Freq. Aquisição (Hz)	Tempo de Medição (s)
Saudável	10 (<i>LA</i>) e 10 (<i>LoA</i>)	25600	30
Paralelo Vertical	30 (<i>LA</i>) e 30 (<i>LoA</i>)	25600	30
Paralelo Bidirecional	30 (<i>LA</i>) e 30 (<i>LoA</i>)	25600	30
Angular	30 (<i>LA</i>) e 30 (<i>LoA</i>)	25600	30

3.5 EXTRAÇÃO DE *FEATURES*

Esta seção descreve o processo de extração de *features* utilizado neste trabalho. Os sinais foram processados tanto no domínio do tempo quanto no domínio da frequência, obtendo-se *features* estatísticas de tempo, *features* de órbita e *features* de frequência, por meio de *scripts* desenvolvidos em *Python*. Para melhorar o desempenho dos modelos de aprendizado de máquina e lidar com o desbalanceamento das classes, os sinais foram segmentados em janelas de 5 segundos, aumentando em seis vezes o número de amostras no conjunto de dados, o que contribui para evitar o *overfitting*. A transformação para o domínio da frequência foi realizada utilizando a *FFT*. Para as *features* de órbita, foram gerados os planos orbitais *XY*, *XZ* e *YZ* a partir dos sinais no domínio do tempo dos eixos horizontal (*Y*), vertical (*Z*) e axial (*X*) dos acelerômetros. A Tabela 11 apresenta as *features* extraídas para este estudo.

Tabela 11 – Features extraídas.

Fonte: Autor.

Features de tempo	Features de frequência
RMS, Pico a Pico, Fator de Crista, Assimetria, Fator de Forma, Fator de Impulso, Fator de Folga, Desvio Padrão, Amplitude Maior e Menor da Órbita (<i>XY</i> , <i>XZ</i> , <i>YZ</i>), <i>SDI</i> (<i>XY</i> , <i>XZ</i> , <i>YZ</i>), Área da Órbita (<i>XY</i> , <i>XZ</i> , <i>YZ</i>), Ângulo de Inclinação da Órbita (<i>XY</i> , <i>XZ</i> , <i>YZ</i>)	RMS Carpet, Planicidade Espectral, Pico Espectral, Pico das Frequências de Rotação (1X, 2X, 3X, 4X, 5X)

A partir desses dados, foi realizada uma análise exploratória dos sinais de vibração nos diferentes domínios. Essa análise buscou identificar padrões nos sinais de vibração e nas *features* extraídas nos domínios do tempo, orbital e frequência. Para tanto, os dados foram avaliados considerando a variação da intensidade e do tipo de desalinhamento, enquanto os demais parâmetros foram mantidos fixos, comparando-os com os dados das condições saudáveis. O objetivo dessa análise é identificar, de forma preliminar, as *features* que podem ser mais influentes para a classificação das amostras entre as classes.

3.6 FLUXO DE TRABALHO DE APRENDIZADO DE MÁQUINA

Esta seção descreve o fluxo de trabalho de aprendizado de máquina utilizado para a classificação binária no presente estudo (Figura 27). Foram definidos três subconjuntos principais de amostras, cada um com características específicas. O primeiro, denominado subconjunto geral, inclui todos os dados obtidos pelos acelerômetros na bancada de simulação de falhas e na extração de *features*, abrangendo todas as condições de desalinhamento, bem como as amostras saudáveis. Além disso, foram criados dois subconjuntos específicos: o subconjunto de desalinhamento paralelo, composto por amostras de desalinhamento paralelo (vertical e bidirecional) e saudáveis, e o subconjunto de desalinhamento angular, contendo amostras de desalinhamento angular e saudáveis.

Essa estrutura permitiu analisar o impacto de cada tipo de desalinhamento na classificação. Como os desalinhamentos angular e paralelo apresentam comportamentos distintos (LEES, 2007), especialmente no domínio da frequência, a separação dos dados em subconjuntos teve como objetivo avaliar se a presença de diferentes tipos de desalinhamento afetaria o desempenho da classificação. Dessa forma, o fluxo de

trabalho completo foi executada em cada um dos três conjuntos, permitindo verificar esses efeitos e comparar o desempenho dos modelos em cada caso.




Figura 27 – Fluxo de trabalho utilizado no trabalho.

Fonte: Autor.

Os modelos de classificação implementados neste trabalho foram a regressão logística, *SVM*, utilizando o *kernel RBF*, floresta aleatória de classificação e *XGBoost*, utilizados para classificar as amostras entre duas classes: saudável (alinhada) e defeituosa (desalinhada). Os dados foram inicialmente divididos em conjuntos de treino e teste. Em seguida, aplicou-se uma metodologia de otimização de hiperparâmetros para aprimorar o desempenho dos modelos. Após o treinamento com os conjuntos definidos, os modelos foram testados, e seus resultados foram comparados entre os diferentes algoritmos. Por fim, avaliou-se o desempenho dos modelos e a influência das *features* em cada subconjunto de dados.

3.6.1 Divisão de treino e teste

A divisão dos dados entre treino e teste foi realizada de forma estratificada, alocando 75% das amostras para o conjunto de treino e 25% para o de teste. Essa separação foi feita de maneira aleatória, porém garantindo que todos os segmentos de dados, assim como todos os eixos provenientes de uma mesma amostra do mesmo sensor, estivessem presentes apenas em um dos conjuntos, prevenindo vazamento de informações. Além disso, esse método assegurou que a proporção de amostras rotuladas como saudáveis fosse preservada em ambos os conjuntos, mesmo diante do desbalanceamento das classes.

Ademais, [Bai, Ganeriwala e Sawalhi \(2019\)](#) demonstraram que informações provenientes de diferentes eixos são necessárias para a detecção eficaz do desalinhamento de eixos. Com base nisso, o treinamento e o teste dos modelos de aprendizado de máquina foram realizados em todas as configurações de subconjuntos definidos, considerando duas abordagens distintas. Na primeira abordagem, cada eixo do sensor foi tratado como uma amostra individual, garantindo que os dados de todos os eixos fossem alocados no mesmo conjunto de treino ou teste, evitando vazamento de informações. Já na segunda abordagem, os dados de todos os eixos foram combinados em uma única amostra. Para isso, todas as *features* foram renomeadas de acordo com o eixo em que foram calculadas (axial, horizontal ou vertical) e realocadas em uma mesma amostra, resultando na triplicação do número de *features* e na redução em um terço do número de amostras. Essa configuração foi implementada com o objetivo de avaliar o impacto do uso de informações de apenas um eixo em comparação ao uso de dados combinados de todos os eixos no desempenho da classificação.

3.6.2 Otimização dos hiperparâmetros e treinamento dos modelos

Neste trabalho, não foi reservado um conjunto exclusivo para validação, uma vez que a otimização de hiperparâmetros foi realizada utilizando o método de validação cruzada *Stratified Group K-Fold* com três *folds*. Esse método assegura a divisão estratificada dos dados, garantindo uma distribuição balanceada das classes em cada *fold* e evitando que segmentos de uma mesma amostra sejam divididos entre conjuntos de treino e validação.

Cada amostra foi definida como uma configuração experimental específica, por exemplo, uma condição de operação a 1000 rpm, com acoplamento rígido e desalinhamento paralelo vertical de intensidade B . Para preservar a integridade dos dados e evitar vazamento de informações, todos os segmentos derivados de uma mesma amostra (ou seja, as seis janelas de 5 segundos obtidas para todos os eixos dos acelerômetros) foram alocados no mesmo *fold*. Assim, ao aplicar o *Stratified Group K-Fold*, o modelo foi treinado em dois *folds* e validado no terceiro, garantindo que dados de uma mesma configuração experimental não estivessem presentes simultaneamente nos conjuntos de treino e validação.

Esse processo de validação cruzada foi repetido para todas as combinações de *folds*, resultando em uma média da métrica *AUC ROC*, utilizada para avaliar o desempenho do modelo em cada configuração de hiperparâmetros. O modelo com melhor desempenho foi selecionado e, posteriormente, ajustado utilizando todo o conjunto de treino. Em seguida, o modelo foi testado no conjunto de teste para validar sua capacidade de generalização.

A otimização dos hiperparâmetros foi realizada por meio do método *RandomizedSearchCV* da biblioteca *scikit-learn* (PEDREGOSA et al., 2011). Esse algoritmo executa uma busca aleatória dentro de um espaço pré-definido de valores. Neste trabalho, foram realizadas 100 iterações, buscando aumentar as chances de encontrar a configuração ótima dos hiperparâmetros. A quantidade de iterações foi definida como um compromisso prático, equilibrando a convergência do desempenho dos modelos e a redução da variabilidade que uma amostragem menor poderia introduzir.

O *RandomizedSearchCV* permitiu especificar distribuições para cada hiperparâmetro. Para este estudo, as distribuições foram configuradas conforme a natureza de cada modelo: *loguniform* para hiperparâmetros em escala logarítmica, como C e γ , e *uniform* para distribuições lineares. Adicionalmente, a função *randint* foi utilizada para selecionar inteiros aleatórios em intervalos específicos. O espaço de busca de hiperparâmetros foi baseado no trabalho de Sikora (2024), e está apresentado na Tabela 12.

Tabela 12 – Espaço de busca de hiperparâmetros utilizados para a otimização dos modelos.

Fonte: (SIKORA, 2024).

Modelo	Hiperparâmetro	Espaço de busca
Regressão logística	C	loguniform(10^{-6} , 10^5)
SVM	C	loguniform(10^{-6} , 10^5)
	gamma	loguniform(10^{-6} , 10^5)
Floresta aleatória de classificação	n_estimators	randint(50, 400)
	max_depth	randint(1, 64)
	max_features	[None, "sqrt", "log2"]
	min_samples_split	randint(2, 16)
	min_samples_leaf	randint(1, 10)
	ccp_alpha	uniform(10^{-6} , 1)
XGBoost	max_depth	randint(1, 64)
	learning_rate	uniform(0.01, 0.1)
	subsample	uniform(10^{-6} , 1)
	n_estimators	randint(50, 400)

3.6.3 Análise de desempenho e seleção de *features*

Os algoritmos de regressão logística, *SVM*, floresta aleatória de classificação e *XGBoost* foram avaliados utilizando as métricas *ROC AUC*, acurácia, acurácia balanceada e *FPR* para um *threshold* de 90% de *TPR*, denominado *Best FPR*. Todas as métricas foram calculadas no conjunto de teste. Inicialmente, os resultados foram comparados entre os modelos que utilizaram amostras com eixos separados e aqueles que combinaram todas as informações dos eixos em uma única amostra. Essa análise preliminar foi realizada no subconjunto geral de dados e teve como objetivo selecionar a abordagem de amostragem mais eficiente com base nas métricas de desempenho.

Em seguida, a pesquisa avançou com a seleção de *features* por meio da análise *SHAP*, realizada na configuração com a melhor performance. Foram selecionadas as 20 *features* mais influentes no processo, com base no algoritmo de aprendizado de máquina que apresentou o melhor desempenho entre os quatro analisados. O modelo de maior performance foi então retreinado e testado utilizando apenas essas *features* principais, com o objetivo de otimizar os resultados mantendo as informações mais relevantes.

Além disso, os modelos foram retreinados e testados separadamente com *features* estatísticas de tempo, de frequência e de órbita. Essa análise comparativa tem como objetivo avaliar a contribuição individual das *features* de cada domínio (tempo, frequência, órbita) e comparar os resultados obtidos com os de um modelo que utiliza todas as *features*. O desempenho de ambos os cenários foi analisado com base nas métricas de desempenho e na análise *SHAP*.

Por fim, com as 20 *features* mais influentes, o algoritmo identificado como o de melhor desempenho foi treinado e testado nos subconjuntos de desalinhamento paralelo e angular. Os resultados obtidos foram então comparados com os do subconjunto geral. Adicionalmente, matrizes de confusão foram geradas para todos os modelos treinados com as *features* mais influentes, com o objetivo de detalhar a performance e a capacidade de detecção de desalinhamento em cada categoria.

4 RESULTADOS E DISCUSSÃO

Este capítulo visa detalhar os resultados obtidos neste trabalho na análise exploratória dos sinais e *features*, além de comparar os resultados entre os algoritmos de aprendizado de máquina nas diferentes configurações de amostra, e realizar uma seleção de *features* para posterior utilização no retreinamento e no teste dos modelos nos diferentes subconjuntos definidos. Dessa maneira, a Figura 28 representa o fluxo de trabalho utilizado.



Figura 28 – Fluxo de análise de desempenho e seleção de *features*.

Fonte: Autor.

4.1 ANÁLISE EXPLORATÓRIA

Inicialmente, foram gerados gráficos de vibração no domínio do tempo, comparando sinais alinhados e desalinhados sob as mesmas condições de acoplamento, velocidade, eixo e posição do acelerômetro, descritas na Figura 29. Observou-se que não há características visíveis no domínio do tempo que distingam claramente o desalinhamento do alinhamento. Assim, para simplificar a visualização, esta seção apresenta apenas um exemplo de sinal de desalinhamento paralelo em comparação com um sinal saudável, ambos no eixo vertical.




Figura 29 – (a) Sinal saudável no domínio do tempo, com 3000 rpm, acoplamento flexível, e acelerômetro no mancal *LA*, em azul. (b) Sinal com desalinhamento paralelo de intensidade média, nas mesmas condições, em laranja.

Fonte: Autor.

Em seguida, foram gerados gráficos no domínio da frequência dos mesmos sinais, utilizando a mesma abordagem (Figura 30). Para essa velocidade de rotação, as frequências 1X, 2X e 3X são de 50 Hz, 100 Hz e 150 Hz, respectivamente. Ao comparar os sinais, foi observada uma redução na resposta em

$2X$ no sinal desalinhado paralelo, contrastando com as observações de (LEES, 2007). Além disso, houve um aumento na resposta em $1X$, característica geralmente associada ao desalinhamento angular. Não foi identificada uma padronização na resposta no domínio da frequência entre as amostras, reforçando a necessidade de um modelo de aprendizado de máquina para a classificação.




Figura 30 – Sinal saudável na frequência com 3000 rpm, acoplamento flexível e acelerômetro no mancal *LA features*, em azul (a). Sinal na frequência com desalinhamento paralelo de intensidade média, 3000 rpm, acoplamento flexível e acelerômetro no mancal *LA*, em laranja (b).

Fonte: Autor.

Gráficos de órbita tridimensionais também foram gerados para os mesmos sinais (Figura 31). Observou-se que o sinal desalinhado paralelo apresentou um formato de "oito" em um plano, enquanto o sinal alinhado mostrou uma elipse contorcida. Essa diferença indica que as *features* de órbita podem ser úteis para os algoritmos de classificação.





Figura 31 – Órbita saudável na frequência com 3000 rpm, acoplamento flexível e acelerômetro no mancal *LA features* (a). Órbita com desalinhamento paralelo de intensidade média, 3000 rpm, acoplamento flexível e acelerômetro no mancal *LA* (b).

Fonte: Autor.


Foi realizada uma análise exploratória das *features* de *RMS* e dos picos das frequências $1X$, $2X$ e $3X$ nos três eixos (Figura 32), com diferentes níveis de desalinhamento, em que 0 representa a condição

saudável, e 0,05 mm, 0,25 mm e 0,55 mm representam intensidades crescentes de desalinhamento vertical, incluindo a utilizada anteriormente na análise orbital. Similar ao observado nas análises no domínio do tempo e da frequência, as *features* não apresentaram um comportamento linear ou consistente com o aumento do desalinhamento, uma vez que seus valores ora aumentavam, ora diminuía, ou sofriam uma variação desprezível em relação ao sinal alinhado. Esse comportamento variável reforçou a ausência de um padrão claro nessas métricas e a necessidade por algoritmos de aprendizado de máquina para a classificação.


RMS Global para Intensidade de Desalinhamento



2X Global



1X Global



3X Global




Figura 32 – Análise exploratória do valor *RMS* e dos picos de frequência *1X*, *2X* e *3X*, nos eixos horizontais, verticais e axiais do acelerômetro posicionado no mancal *LA*, e a intensidade do desalinhamento variando entre saudável e alta.

Fonte: Autor.

Ademais, embora as *features* de órbita não tenham mostrado um comportamento consistente entre as diferentes intensidades de desalinhamento, como observado nas Figuras 33 e 34, as diferentes classes apresentam *features* significativamente diferentes, sugerindo uma sensibilidade potencial dessas *features* ao desalinhamento.




Figura 33 – Área da órbita para os eixos axiais (XZ) com a variação da intensidade de desalinhamento paralelo vertical.

Fonte: Autor.




Figura 34 – SDI para os eixos axiais (YZ) com a variação da intensidade de desalinhamento paralelo vertical.

Fonte: Autor.

4.2 ALGORITMOS DE APRENDIZADO DE MÁQUINA

Essa seção busca apresentar os resultados dos testes dos modelos de aprendizado de máquina implementados. Inicialmente, foram comparadas as configurações dos modelos com amostras de eixos individuais e os combinados. Dessa forma, com a configuração mais adequada e o algoritmo mais performático selecionados, as *features* foram analisadas e selecionadas através de análises *SHAP*. Por conseguinte, os algoritmos foram retreinados e testados com as 20 melhores *features* nos três subconjuntos pré-definidos.

4.2.1 Configurações de amostragem dos eixos

Os modelos de aprendizado de máquina foram treinados e testados com todas as *features* nas duas configurações de amostragem, de eixos separados e eixos combinados. Esse processo foi repetido quinze vezes, resultando em uma curva *ROC* e métricas avaliativas médias, em razão da aleatoriedade envolvida nos algoritmos, como a divisão de treino e teste e a otimização dos hiperparâmetros.

Na primeira configuração (Figura 35), em que os eixos foram considerados como amostras independentes, os resultados foram insatisfatórios para todos os algoritmos, apresentando valores de *AUC* próximos ao nível de chance (*chance level*), que se refere ao desempenho esperado de um modelo que faz classificações de maneira completamente aleatória, especialmente para o Random Forest ($AUC = 0,39$) e o XGBoost ($AUC = 0,41$).

Ademais, na configuração com eixos combinados (Figura 36), o desempenho dos modelos foi significativamente superior, com destaque para o XGBoost, que alcançou uma *AUC* de 0,80, sugerindo que a combinação dos eixos fornece informações adicionais cruciais para a detecção de desalinhamento de eixos. Dessa forma, a primeira configuração foi descartada e a segunda foi utilizada para o restante deste trabalho.




Figura 35 – Curva *ROC* para os algoritmos de aprendizado de máquina na configuração com eixos em amostras separadas.

Fonte: Autor.




Figura 36 – Curva *ROC* para os algoritmos de aprendizado de máquina na configuração com eixos combinados nas mesmas amostras.

Fonte: Autor.

4.2.2 Análise e seleção de *features*

Para a seleção e análise das *features*, foi utilizada a análise *SHAP* no algoritmo *XGBoost*, que apresentou desempenho superior aos demais modelos. Na Figura 37, observa-se que, embora a curva *ROC* indique uma performance de 0,80 de *AUC*, a acurácia balanceada do modelo foi de 0,52, com uma taxa de falsos positivos de 0,60 para um *threshold* de 90% de verdadeiros positivos. Esse resultado sugere que uma das classes foi detectada de forma inadequada, possivelmente devido à presença de *features* que não contribuem para a discriminação das classes e podem estar confundindo o modelo.

Para aprimorar a capacidade preditiva do modelo, foram selecionadas as 20 *features* mais influentes com base na análise *SHAP*, conforme ilustrado na Figura 38. As *features* mais relevantes, que são as melhores classificadas na análise *SHAP*, incluem o pico de frequência 4X no eixo vertical, a planicidade espectral nos eixos axial e horizontal, o pico de frequência 2X no eixo axial e o pico de frequência 1X no eixo horizontal.

Esses resultados indicam que os diferentes eixos contêm informações distintas e importantes para a classificação, o que explica o desempenho inferior dos modelos quando os eixos foram analisados separadamente. Além disso, as *features* relacionadas à análise orbital, como o ângulo de inclinação radial (XY) e a amplitude radial menor (XY), assim como *features* estatísticas no domínio do tempo, como a curtose no eixo vertical, o fator de forma no eixo vertical e o desvio padrão no eixo axial, também foram influentes na decisão do modelo. Esse conjunto de *features* sugere que as informações dos domínios da frequência, do tempo e da análise orbital podem ser complementares e podem contribuir significativamente para a detecção de desalinhamento de eixos usando aprendizado de máquina.




Figura 37 – Curva *ROC* para o algoritmo de *XGBoost* com eixos combinados na mesma amostra.

Fonte: Autor.




Figura 38 – Análise *SHAP* para o algoritmo de *XGBoost* com eixos combinados na mesma amostra.

Fonte: Autor.

Além disso, foram realizados treinos, testes e análises *SHAP* utilizando separadamente as *features* de frequência (Figura 39 e 40), estatísticas de tempo (Figura 41 e 42) e de órbita (Figura 43 e 44), em algoritmos de *XGBoost*. O objetivo dessa análise foi investigar a interatividade das *features* entre diferentes domínios, identificando se elas perdem relevância quando isoladas dos outros domínios.




Figura 39 – Curva *ROC* para *XGBoost* apenas com *features* de frequência em comparação com o modelo com todas as *features*.

Fonte: Autor.




Figura 40 – Análise *SHAP* do modelo de *XGBoost* com *features* de frequência.

Fonte: Autor.

Dessa forma, o algoritmo performou de maneira superior com apenas *features* de frequência, com uma *ROC AUC* de 0,89, acurácia balanceada de 0,60 e taxa de falsos positivos de 0,40 para o *threshold* de 90% de verdadeiros positivos, melhorando todas as métricas avaliativas em comparação com o modelo com todas as *features*. Foi possível observar, ademais, que as *features* de frequência performam adequadamente

sem a necessidade das *features* de tempo e de órbita.




Figura 41 – Curva *ROC* para *XGBoost* apenas com *features* de tempo em comparação com o modelo com todas as *features*.

Fonte: Autor.




Figura 42 – Análise *SHAP* do modelo de *XGBoost* com *features* de tempo.

Fonte: Autor.




Figura 43 – Curva *ROC* para *XGBoost* apenas com *features* de órbita em comparação com o modelo com todas as *features*.

Fonte: Autor.




Figura 44 – Análise *SHAP* do modelo de *XGBoost* com *features* de órbita.

Fonte: Autor.

Entretanto, o algoritmo apresentou desempenho inferior ao utilizar apenas as *features* de tempo e as *features* de órbita (Figuras 41 e 43). Observou-se uma diferença desprezível na acurácia balanceada e uma redução significativa no *ROC AUC* (0,66 para as *features* de tempo e 0,47 para as *features* de órbita). Além disso, a taxa de falsos positivos aumentou consideravelmente para o *threshold* de 90% de verdadeiros

positivos definido (0,80 para as *features* de tempo e 0,94 para as *features* de órbita).

Embora as *features* de órbita estejam entre as mais influentes (Figura 38), a análise *SHAP* isolada (Figuras 42 e 44) revelou uma sensibilidade desprezível dessas *features* na decisão dos modelos. Isso indica que as *features* de órbita provavelmente são úteis apenas quando há interatividade com as *features* de tempo e frequência.

4.2.3 Subconjuntos das amostras

Inicialmente, o modelo *XGBoost* foi retreinado e testado utilizando as 20 *features* mais influentes (Figura 38) no subconjunto geral. A Figura 45 apresenta a curva *ROC* desse modelo em comparação com o modelo com todas as *features*, enquanto a Figura 46 exibe a matriz de confusão deste modelo. Observou-se um desempenho superior ao modelo que utilizava apenas as *features* de frequência e o algoritmo com todas as *features*, com *ROC AUC* de 0,90 e acurácia balanceada de 0,69, além de uma redução da taxa de falsos positivos para o *threshold* definido, atingindo 0,37. Na matriz de confusão, 93,14% dos dados foram classificados corretamente, somando os verdadeiros positivos e negativos. Entretanto, 6,13% dos dados são falsos positivos, enquanto apenas 0,73% dos dados são falsos negativos. Isso indica que o modelo está classificando muitas amostras saudáveis como desalinhadas. No contexto da manutenção de máquinas, é preferível ter erro do tipo de falsos positivos do que falsos negativos, já que é mais seguro gerar um alarme falso do que falhar em alertar para um defeito real. Além disso, a baixa acurácia balanceada dos resultados pode ser uma consequência direta do desbalanceamento do conjunto de dados. Por isso, é importante em trabalhos futuros a criação de um banco de dados com mais dados saudáveis, gerando balanceamento das classes.




Figura 45 – Curva *ROC* para *XGBoost* apenas com as 20 melhores *features* no subconjunto geral.

Fonte: Autor.




Figura 46 – Matriz de confusão para o *XGBoost* com apenas as 20 melhores *features* no subconjunto geral.

Fonte: Autor.

O modelo foi então retreinado e testado nos subconjuntos de desalinhamento paralelo e angular, utilizando as 20 *features* mais influentes. As Figuras 47 e 49 apresentam as curvas *ROC* desses subconjuntos, comparadas à curva *ROC* do subconjunto geral. Ademais, as Figuras 48 e 50 apresentam as matrizes de confusão dos subconjuntos de desalinhamento paralelo e angular, respectivamente.

Observou-se que a taxa de falsos positivos para o *threshold* definido foi maior nos subconjuntos (0,47 para o paralelo e 0,40 para o angular), enquanto a *ROC AUC* foi inferior (0,87 em ambos) em relação ao subconjunto geral. A acurácia balanceada aumentou ligeiramente para o desalinhamento angular e diminuiu para o paralelo. Além disso, na matriz de confusão do subconjunto de desalinhamento angular foi possível observar uma maior quantidade de verdadeiros negativos em relação aos outros subconjuntos, indicando que esse modelo possui maior capacidade de classificação dos dados saudáveis.




Figura 47 – Curva *ROC* para *XGBoost* no subconjunto de desalinhamento paralelo com apenas as 20 melhores *features*.

Fonte: Autor.




Figura 48 – Matriz de confusão para o *XGBoost* com apenas as 20 melhores *features* no subconjunto de desalinhamento paralelo.

Fonte: Autor.




Figura 49 – Curva *ROC* para *XGBoost* no subconjunto de desalinhamento angular com apenas as 20 melhores *features*.

Fonte: Autor.




Figura 50 – Matriz de confusão para o *XGBoost* com apenas as 20 melhores *features* no subconjunto de desalinhamento angular.

Fonte: Autor.

Posteriormente, foram realizadas análises *SHAP* nos subconjuntos de desalinhamento paralelo e angular (Figuras 51 e 52, respectivamente) para identificar a similaridade entre as *features* utilizadas na classificação dos modelos. Observou-se que as *features* mais impactantes para ambos os subconjuntos foram as mesmas: planicidade espectral no eixo axial, pico harmônico em $4X$ no eixo vertical e ângulo de inclinação da órbita no plano XY .

Uma diferença notável foi o pico espectral em $2X$ no eixo axial, mais relevante para o desalinhamento paralelo, enquanto o pico espectral em $1X$ no eixo horizontal mostrou maior influência no desalinhamento angular, conforme esperado na literatura (LEES, 2007). Ambos os picos, no entanto, contribuíram para a classificação em ambos os modelos. A interpretação das *features* foi consistente entre os subconjuntos analisados, evidenciando que valores elevados do pico harmônico em $4X$ estavam associados a amostras saudáveis, enquanto valores baixos indicaram desalinhamento. Esse comportamento foi semelhante ao observado para as demais *features*. Contudo, a literatura frequentemente associa aumentos em picos harmônicos a desalinhamentos, sugerindo uma possível contradição com os resultados deste estudo. Além disso, altos valores de planicidade espectral, que indicam maior semelhança do sinal com ruídos, foram associados pelos modelos a medições desalinhadas. Esses resultados sugerem que o desalinhamento nos experimentos conduzidos neste trabalho gerou não linearidades na resposta vibracional, como evidenciado na etapa de análise exploratória.




Figura 51 – Análise *SHAP* do modelo de *XGBoost* com as melhores *features* no subconjunto de desalinhamento paralelo.

Fonte: Autor.




Figura 52 – Análise *SHAP* do modelo de *XGBoost* com as melhores *features* no subconjunto de desalinhamento angular.

Fonte: Autor.

5 CONCLUSÕES

Neste trabalho, realizado em parceria com a empresa *Dynamox*, desenvolveu-se uma metodologia para a detecção de desalinhamento em máquinas rotativas, utilizando sinais de vibração obtidos por acelerômetros em uma bancada de simulação de defeitos presente no Laboratório de Vibração e Acústica (LVA), e algoritmos de aprendizado de máquina de classificação binária, visando aprimorar técnicas de manutenção preditiva.

Foi criada uma base de dados abrangendo diversas condições de desalinhamento, e *features* de frequência, tempo e órbita foram extraídas dos dados dos eixos dos acelerômetros segmentados em janelas de 5 segundos. A partir da análise exploratória manual dos dados, foi possível observar uma dificuldade na classificação manual das amostras, advinda de uma baixa padronização na variação dos sinais nos domínios e das *features* com o aumento da intensidade de desalinhamento, reforçando a necessidade do uso de algoritmos de aprendizado de máquina para a classificação automatizada.

Em seguida, os modelos de *XGBoost*, *Random Forest*, regressão logística e *SVM* foram implementados em duas configurações de amostras, separando os eixos dos acelerômetros em diferentes amostras em uma e os combinando na mesma amostra em outra. A concatenação dos eixos se mostrou benéfica, visto que os modelos apresentaram desempenho superior ao considerar as interações entre os eixos, indo ao encontro da literatura que indica a necessidade dessas informações combinadas. Além disso, o *XGBoost* performou de forma significativamente superior aos outros algoritmos para a detecção de desalinhamento de eixos.

A análise das *features* mostrou que, enquanto as *features* de domínios isolados, como tempo e orbital, apresentaram desempenho limitado, as *features* de frequência mantiveram alta relevância. Adicionalmente, a seleção das 20 *features* mais influentes contribuiu significativamente para a eficácia dos modelos. A interação entre as melhores *features* de diferentes domínios possibilitou uma maior discriminação entre classes, com maior acurácia balanceada, maior *ROC AUC* e menor taxa de falsos positivos. As *features* mais relevantes para o subconjunto geral incluem o pico de frequência $4X$ no eixo vertical, a planicidade espectral nos eixos axial e horizontal, o pico de frequência $2X$ no eixo axial e o pico de frequência $1X$ no eixo horizontal.

Finalmente, foram comparados os resultados entre os modelos de aprendizado de máquina nos subconjuntos gerais e nos subconjuntos específicos de desalinhamento. Observou-se que a exclusão de um tipo específico de desalinhamento reduziu levemente o desempenho dos modelos, indicando que os algoritmos treinados com todos os dados têm maior capacidade de generalização para detectar o desalinhamento, apesar da pequena melhoria em acurácia balanceada no subconjunto de desalinhamento angular. Além disso, foi observado que a interpretação e a influência das *features* para a classificação dos modelos nos dois subconjuntos é semelhante entre si e com o subconjunto geral. Ademais, o pico espectral em $1X$ foi influente para a detecção de desalinhamento angular, assim como o pico espectral em $2X$ foi impactante para a detecção de desalinhamento paralelo, o que vai ao encontro da literatura.

Portanto, este estudo atendeu satisfatoriamente aos objetivos específicos propostos com uma metodologia de detecção de desalinhamento de eixos em máquinas rotativas e aprendizado de máquina para a manutenção preditiva. Dessa forma, visando dar continuidade ao projeto e otimizar os resultados,

o próximo capítulo destaca etapas futuras para pesquisas no assunto.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

Este capítulo apresenta direções recomendadas para pesquisas futuras, com o objetivo de expandir e aprimorar as metodologias de detecção de desalinhamento em máquinas rotativas, utilizando aprendizado de máquina e análise de vibração.

A criação de um banco de dados balanceado, com a inclusão de mais medições saudáveis pode permitir uma melhor acurácia balanceada. Ademais, a implementação de um modelo multirrótulo que permita classificar simultaneamente múltiplos tipos de falhas, como desalinhamento paralelo, angular e defeitos combinados pode melhorar os resultados obtidos, além de elevar a generalização dos modelos. Além disso, a inclusão de *features* de tempo-frequência e características de correlação entre eixos pode ser igualmente útil para o mesmo objetivo. Ao utilizar técnicas como a transformada discreta de *wavelet* (*DWT*), essas características podem ajudar a captar variações temporais e espectrais dos sinais, permitindo identificar padrões sutis associados ao desalinhamento que não são facilmente visíveis no domínio da frequência tradicional. Essas informações adicionais podem aumentar a precisão dos algoritmos na detecção de desalinhamento. Além disso, seria interessante a implementação de modelos de aprendizado profundo para a quantificação do nível de desalinhamento dos eixos, o que pode auxiliar no prognóstico de alinhamento.

Ademais investigação do desalinhamento combinado, que considera desalinhamentos paralelos e angulares ocorrendo simultaneamente pode ser útil para a maior generalização dos algoritmos. Além disso, novos tipos de acoplamentos, mais velocidades de rotação e níveis de desalinhamento, além de uma realização de mais experimentos com repetibilidade podem contribuir para o mesmo objetivo.

Por fim, seria interessante realizar uma investigação do detecção de desalinhamento combinado com outros defeitos, como desbalanceamento, falhas em engrenagens e rolamentos, para elevar a generalização do modelo à situações práticas em que múltiplos defeitos ocorrem dinamicamente. Dessa forma, essas propostas visam ampliar as capacidades dos modelos de detecção de desalinhamento, contribuindo para o avanço das práticas de manutenção preditiva e aumentando a confiabilidade dos sistemas de detecção em aplicações industriais.

5.2 CRONOGRAMA DE ATIVIDADES

De forma similar às atividades descritas neste trabalho, os próximos passos do projeto serão desenvolvidos no LVA em parceria com a empresa *Dynamox* e estão listados a seguir:

1. Utilização de novas configurações da bancada, como novos acoplamentos, eixos de diâmetros diferentes e mais velocidades de rotação, com desalinhamento combinado e repetibilidade, além de mais dados saudáveis para um conjunto balanceado;
2. Implementação de features de tempo-frequência e correlação;
3. Implementação de modelos de aprendizado profundo para a quantificação do nível de desalinhamento;

4. Implementação de um modelo multirrótulo;
5. Diagnóstico de desalinhamento com defeitos combinados, como desbalanceamento, defeitos em engrenagens e rolamentos.

O projeto está previsto para ser executado ao longo de 2027, pois o primeiro ano do mestrado seria utilizado para a conclusão das disciplinas necessárias. A Tabela 13 apresenta o cronograma contendo o período e a ordem de execução de cada etapa.

Tabela 13 – Cronograma de atividades do projeto.

Fonte: Autor.

Atividades	2027											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1.	×	×	×									
2.		×	×	×	×							
3.				×	×	×						
4.					×	×	×	×				
5.							×	×	×			
6.								×	×	×		
7.									×	×	×	×

5.3 PREVISÃO FINANCEIRA E INFRAESTRUTURA

Inicialmente, será utilizada a mesma bancada de simulação de falhas deste trabalho para a extração das novas amostras de sinais de vibração. Dessa forma, os custos associados ao mestrado estão relacionados à compra de novos acoplamentos de eixos, sendo um de borracha e um do tipo *Lovejoy*. Essas peças podem ser compradas por preços que variam entre 50 e 100 dólares cada.

BIBLIOGRAFIA

- ALSALAET, J. **Dynamic Balancing and Shaft Alignment**. Springer, ago. 2015.
- B&K. **Product Data – Triaxial DeltaTron Accelerometers with TEDS – Types 4525-B and 4525-B-001**. 2024. Último acesso em 28/10/2024.
- BACHSCHMID, N.; PENNACCHI, P.; VANIA, A. Diagnostic Significance of Orbit Shape Analysis and its Application to Improve Machine Fault Detection. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Politecnico di Milano, Department of Mechanics, Via La Masa 34, I-20158, Milano, Italy, v. 26, n. 2, p. 208–220, abr. 2004.
- BAI, C.; GANERIWALA, S.; SAWALHI, N. A Rational Basis for Determining Vibration Signature of Shaft/Coupling Misalignment in Rotating Machinery. In: Springer Cham, jan. 2019. P. 207–217.
- BEHERA, D. P.; BEHERA, R.; NAIKAN, V. N. A. Virtual Fault Simulation for Diagnosis of Shaft Misalignment of Rotating Machine. In: PROCEEDINGS of International Conference on Advances in Computing, Communications and Informatics. New Delhi, India, 2014. P. 2476–2480.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006. cap. 4.3.4.
- CARBONELL, J. G.; MICHALSKI, R. S.; MITCHELL, T. M. An Overview of Machine Learning. **Machine Learning**, Springer, v. 1, n. 1, p. 1–29, 1983.
- CARVALHO, D.; PEREIRA, E.; CARDOSO, J. Machine Learning Interpretability: A Survey on Methods and Metrics. **Electronics**, v. 8, p. 832, 2019.
- CHEN, T.; GUESTRIN, C. XGBoost: A Scalable Tree Boosting System. In: KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, ago. 2016. P. 785–794.
- DEVELOPERS, S.-I. **Ensemble Methods**. 2024. Accessed: 2024-10-27.
- DUBNOV, S. Generalization of spectral flatness measure for non-Gaussian linear processes. **IEEE Signal Processing Letters**, v. 11, n. 8, p. 698–701, ago. 2004.
- DYNAMOX. **Como o desalinhamento de eixos ocorre e quais os perigos para o seu equipamento**. 2022. Acessado: 26 de outubro de 2024.
- DYNAMOX. **Guia completo da manutenção preditiva**. Acesso em: 21 nov. 2024. 2024. Disponível em: <<https://dynamox.net/blog/guia-completo-da-manutencao-preditiva>>.
- GANERIWALA, S. A Demystifying Shaft/Coupling Misalignment Signature Using Vibration Analysis. In: SOCIETY FOR MACHINERY FAILURE PREVENTION TECHNOLOGY. MFPT 2023 - Diagnostics, Prognostics, and Failure Prevention: Where Theory Meets Practice. Niagara Falls, NY, jul. 2023. Apresentação.
- GANERIWALA, S. N.; LI, Z.; RICHARDSON, M. H. Using Operating Deflection Shapes to Detect Misalignment in Rotating Equipment. In: IMAC. PROCEEDINGS of IMAC XXVI. Orlando, FL: Spectra Quest, Inc Vibrant Technology, Inc, 2008. february 4–7.

- GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow**. O'Reilly Media, 2019.
- GUPTA, M. K.; GUPTA, K.; PERFETTO, A. D. Vibration Analysis and Condition Monitoring of Rotating Machines. **Journal of Vibration Engineering & Technologies**, v. 7, n. 1, p. 65–76, 2019.
- HART, S. Shapley Value. In: EATWELL, J.; MILGATE, M.; NEWMAN, P. (Ed.). **The New Palgrave: Game Theory**. Norton, 1989. P. 210–216.
- IBM. **Decision Trees**. 2024. Accessed: 2024-10-27.
- JALAN, A. K.; PATIL, S.; MITTAL, G. A Review on Fault Diagnosis of Misaligned Rotor Systems. **International Journal of Production Engineering**, Birla Institute of Technology e Science, Pilani, Rajasthan, India, v. 16, n. 4, p. 499–509, abr. 2020. * Corresponding author.
- JAMES, G. et al. **An Introduction to Statistical Learning**. Springer, 2013.
- JANG, J.-G. et al. Vibration data feature extraction and deep learning-based preprocessing method for highly accurate motor fault diagnosis. **Journal of Computational Design and Engineering**, Oxford University Press, v. 10, n. 1, p. 204–220, fev. 2023. Published: 06 December 2022, Corrected and typeset: 03 February 2023.
- JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, v. 20, n. 7, p. 1483–1510, out. 2006.
- JESSE, S. et al. Motor Shaft Misalignment Bearing Load Analysis. In: PROCEEDINGS of the Maintenance and Reliability Conference (MARCON 99). Gatlinburg, TN, 1999.
- JORDAN, M. A. What are Orbit Plots, Anyways? In: 1993. P. 8–15.
- KIM, S.-i. et al. Fault classification model based on time domain feature extraction of vibration data. **Journal of the Computational Structural Engineering Institute of Korea**, v. 34, n. 1, p. 25–33, 2021.
- KORBICZ, J. et al. **Fault Diagnosis: Models, Artificial Intelligence, Applications**. Berlin: Springer, 2004.
- KRAJŇÁK, J. et al. The failures of flexible couplings due to self-heating by torsional vibrations – validation on the heat generation in pneumatic flexible tuner of torsional vibrations. **Engineering Failure Analysis**, v. 119, p. 104977, 2021.
- KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. Springer, 2013.
- KUNDU, P.; DARPE, A. K.; KULKARNI, M. S. A review on diagnostic and prognostic approaches for gears. **Structural Health Monitoring**, SAGE Publications Ltd, 2020. Cited By 17.
- KWIATKOWSKI, R. Gradient Descent Algorithm — a deep dive. **Towards Data Science**, mai. 2021. 8 min read.
- LEES, A. W. Misalignment in Rigidly Coupled Rotors. **Journal of Sound and Vibration**, v. 305, n. 1-2, p. 261–271, 2007.

- LUNDBERG, S. M.; LEE, S.-I. **An introduction to explainable AI with Shapley values**. 2021. Accessed: 2024-10-27.
- MANCUSO, J. R. The Manufacturers World of Coupling Potential Unbalance. In: PROCEEDINGS of the Thirteenth Turbomachinery Symposium. 1985. P. 97–103.
- MIAN, T.; CHOUDHARY, A.; FATIMA, S. Multi-Sensor Fault Diagnosis for Misalignment and Unbalance Detection Using Machine Learning. **IEEE Transactions on Industry Applications**, v. 59, n. 5, p. 5749–5759, 2023.
- MONTE, M.; VERBELEN, F.; VERVISCH, B. The Use of Orbitals and Full Spectra to Identify Misalignment. In: STRUCTURAL Health Monitoring. New York: Springer, 2014. v. 5.
- MURA, A.; CURÀ, F.; MOLFETTA, A. D. Investigation of bearings overloads due to misaligned splined shafts. In: AIAS 2018 International Conference on Stress Analysis. Torino, Italy: Elsevier B.V., 2018. P. 52–57. Available online at www.sciencedirect.com.
- NATIONAL INSTRUMENTS. **cDAQ-9174 Specifications**. 2023. Accessed: 2024-10-28.
- NATIONAL INSTRUMENTS. **NI 9234 Specifications**. 2023. Accessed: 2024-10-28.
- PEDREGOSA, F. et al. **scikit-learn: Machine Learning in Python**. 2011. P. 2825–2830. https://scikit-learn.org/1.5/modules/generated/sklearn.model_selection.RandomizedSearchCV.html.
- PEDREGOSA, F. et al. **StratifiedGroupKFold**. 2024. Acesso em: 30 out. 2024.
- PIOTROWSKI, J. **Shaft Alignment Handbook**. Boca Raton, FL, USA: CRC Press, 2007.
- PRATES, W. R. **Curva ROC e AUC em Machine Learning**. Nov. 2020.
- PRUFTECHNIK LTD. **A Practical Guide to Shaft Alignment**. U.S.: Pruftechnik Ltd., 2002.
- RAJ, P. Why Is Logistic Regression Called “Logistic Regression” And not a Logistic Classification? **Medium**, ago. 2023.
- RANDALL, R. B. **Vibration-based Condition Monitoring**. Wiley, jan. 2011.
- REZAZADEH, N.; LUCA, A. D.; PERFETTO, D. Unbalanced, cracked, and misaligned rotating machines: a comparison between classification procedures throughout the steady-state operation. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 44, p. 450, 2022. Received: 25 April 2022 / Accepted: 17 August 2022 / Published online: 8 September 2022.
- RUBACK, L.; AVILA, S.; CANTERO, L. Vieses no Aprendizado de Máquina e suas Implicações Sociais: Um Estudo de Caso no Reconhecimento Facial. In: ANAIS do Workshop de Inteligência Computacional e Sistemas. Jul. 2021. P. 90–101.
- SARKER, I. Machine Learning: Algorithms, Real-World Applications and Research Directions. **SN Computer Science**, v. 2, mar. 2021.
- SAWALHI, N.; GANERIWALA, S.; TÓTH, M. Parallel misalignment modeling and coupling bending stiffness measurement of a rotor-bearing system. **Applied Acoustics**, Elsevier, v. 144, p. 124–141, 2019.

- SCHÖLKOPF, B. et al. New Support Vector Algorithms. **Neural Computation**, MIT Press, GMD FIRST, Berlin, Germany; Department of Engineering, Australian National University, Canberra, Australia, v. 12, n. 5, p. 1207–1245, 2000. Communicated by John Platt.
- SCIKIT-LEARN. **RandomForestClassifier**. 2024. Accessed: 2024-10-27.
- SCIKIT-LEARN. **Tree-based Models — scikit-learn 1.5 documentation**. 2024.
<https://scikit-learn.org/1.5/modules/tree.html>.
- SCIKIT-LEARN. **Cross-validation: evaluating estimator performance**. 2024.
- SCIKIT-LEARN. **Supervised Learning**. 2024. Accessed: 2024-10-27.
- SCIKIT-LEARN DEVELOPERS. **Support Vector Machines — scikit-learn 1.5 documentation**. 2024. Accessed: 2024-10-27.
- SETHIYA, S. K. Condition Based Maintenance (CBM), n.d. Secretary to CME, West Central Railway, Jabalpur, India.
- SHIN, K.; HAMMOND, J. **Fundamentals of Signal Processing for Sound and Vibration Engineers**. 1st: Wiley, 2008.
- SIKORA, M. V. **Comparison of Machine Learning Binary Classifiers for Detection of Gear Defects**. 2024. Diss. (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis.
- SMOLA, A. J.; SCHÖLKOPF, B. A Tutorial on Support Vector Regression. **Statistics and Computing**, Springer, v. 14, n. 3, p. 199–222, 2004.
- SPECTRA QUEST, INC. **User Operating Manual for Machinery Fault Simulator**. Richmond, VA, dez. 2010. Version 2.2.
- SPECTRAQUEST. **Machinery Fault Simulator (MFS)**. Accessed: 2024-10-28.
- TAMASCELLI, N.; PALTRINIERI, N.; COZZANI, V. Predicting chattering alarms: A machine learning approach. **Computers & Chemical Engineering**, v. 143, p. 107122, dez. 2020.
- THOMA, M. **ROC-Kurve - die Abszisse ist die Falsch-Positiv-Rate und die Ordinate die Richtig-**. Jun. 2018.
- WALD, A. **Statistical Decision Functions**. [S.l.]: Wiley, 1950.
- WU, T. Y.; CHUNG, Y. L. Misalignment Diagnosis of Rotating Machinery Through Vibration Analysis via the Hybrid EEMD and EMD Approach. **Smart Materials and Structures**, v. 18, n. 9, 2009.
- YANG, H.; MATHEW, J.; MA, L. Vibration feature extraction techniques for fault diagnosis of rotating machinery: a literature survey. In: **PROCEEDINGS of the Asia-Pacific Vibration Conference**. Australia, 2003. P. 1–6.
- ZONTA, T. et al. Predictive maintenance in the Industry 4.0: A systematic literature review. **Computers & Industrial Engineering**, Elsevier, v. 150, p. 106889, 2020.