

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA – CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE ELETRÔNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELETRÔNICA**

LAURA MARTIN DA SILVA WERNECK

**ANÁLISE COMPARATIVA DE MÉTODOS PARA DEFINIÇÃO DE
LIMIAR NA DETECÇÃO DE MÁQUINAS PARADAS**

FLORIANÓPOLIS, 2025.

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA – CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE ELETRÔNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELETRÔNICA**

LAURA MARTIN DA SILVA WERNECK

**ANÁLISE COMPARATIVA DE MÉTODOS PARA DEFINIÇÃO DE
LIMIAR NA DETECÇÃO DE MÁQUINAS PARADAS**

Trabalho de Conclusão de Curso
submetido ao Instituto Federal de
Educação, Ciência e Tecnologia de Santa
Catarina como parte dos requisitos para
obtenção do título de Engenheira em
Eletrônica.

Orientador:
Prof. Robinson Pizzio, Dr.

Coorientador:
Lucas Sousa Feitosa, Esp.

FLORIANÓPOLIS, 2025.

Ficha de identificação da obra elaborada pelo autor.

Werneck, Laura Martin da Silva

Análise comparativa de métodos para definição de limiar na detecção de máquinas paradas / Laura Martin da Silva Werneck; orientação de Robinson Pizzio; coorientação de Lucas Sousa Feitosa. - Florianópolis, SC, 2025.

55 p.

Trabalho de Conclusão de Curso (TCC) - Instituto Federal de Santa Catarina, Câmpus Florianópolis. Bacharelado em Engenharia Eletrônica. Departamento Acadêmico de Eletrônica.

Inclui Referências.

1. Monitoramento de vibração. 2. Análise de sinais. 3. Algoritmo de Otsu. 4. Monitoramento preditivo. I. Pizzio, Robinson. II. Feitosa, Lucas Sousa. III. Instituto Federal de Santa Catarina. IV. Análise comparativa de métodos para definição de limiar na detecção de máquinas paradas.

ANÁLISE COMPARATIVA DE MÉTODOS PARA DEFINIÇÃO DE LIMAR NA DETECÇÃO DE MÁQUINAS PARADAS

LAURA MARTIN DA SILVA WERNECK

Este trabalho foi julgado adequado para obtenção do título de Engenheira em Eletrônica em Março de 2025 e aprovado na sua forma final pela banca examinadora do Curso de Engenharia Eletrônica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Florianópolis, 26 de Março, 2025.

Banca Examinadora:

Documento assinado digitalmente
 **ROBINSON PIZZIO**
Data: 31/03/2025 23:50:18-0300
Verifique em <https://validar.iti.gov.br>

Robinson Pizzio, Dr.

Documento assinado digitalmente
 **LUCAS SOUSA FEITOSA**
Data: 03/04/2025 09:34:57-0300
Verifique em <https://validar.iti.gov.br>

Lucas Sousa Feitosa, Esp.
Dynamox S.A.

Documento assinado digitalmente
 **CARLOS GONTARSKI SPERANZA**
Data: 02/04/2025 08:31:11-0300
Verifique em <https://validar.iti.gov.br>

Carlos Gontarski Speranza, Dr.
Instituto Federal de Ciência e Tecnologia de Santa Catarina

Documento assinado digitalmente
 **RENAN AUGUSTO STARKE**
Data: 01/04/2025 13:39:27-0300
Verifique em <https://validar.iti.gov.br>

Renan Augusto Starke, Dr.
Instituto Federal de Ciência e Tecnologia de Santa Catarina

Dedico este trabalho aos meus pais, Débora e Marcelo.

AGRADECIMENTOS

Aos meus pais e minhas irmãs, minha eterna gratidão pelo apoio incondicional e pela confiança depositada em mim ao longo de toda a graduação. Seu suporte e incentivo foram essenciais para que eu seguisse em frente, independentemente dos desafios encontrados no caminho.

À minha mãe, meu maior exemplo de força e perseverança, que, com sua determinação, me inspirou a enfrentar os momentos difíceis longe da família. Ao meu pai, agradeço imensamente pelo incentivo na escolha da engenharia e por sua disposição em me ajudar sempre que enfrentei dificuldades acadêmicas. Sem vocês, essa jornada não teria sido possível.

Agradeço ao meu orientador, professor Robinson, por sua orientação, atenção e paciência ao longo do desenvolvimento deste projeto. Sua dedicação e acolhimento foram fundamentais não apenas nesta etapa, mas em grande parte da minha trajetória acadêmica. Sou imensamente grata por sua mentoria e pelos valiosos conselhos que sempre me ajudaram a tomar as melhores decisões.

Agradeço ao meu coorientador, engenheiro Lucas, por apresentar este trabalho e me auxiliar na formalização da proposta. Sua orientação e incentivo foram fundamentais ao longo do desenvolvimento deste projeto, contribuindo significativamente para sua realização.

Agradeço ao Instituto Federal de Santa Catarina (IFSC) e a todos os professores que fizeram parte da minha jornada acadêmica, pelo compromisso com o ensino e por proporcionarem uma educação pública de qualidade. Sou grata também pelas oportunidades de voluntariado, bolsas, projetos de pesquisa e intercâmbio que pude vivenciar, experiências que enriqueceram minha formação tanto pessoal quanto profissional.

Por fim, sou imensamente grata aos meus amigos e a todos que, de alguma maneira, contribuíram para essa trajetória.

“Descuidados, zombeteiros, violentos - assim
nos quer a sabedoria: ela é uma mulher,
ela ama somente um guerreiro.”
- Friedrich Nietzsche

RESUMO

Este trabalho busca entender e comparar duas formas de identificar quando uma máquina industrial está ligada ou desligada, um fator essencial para tornar o monitoramento da Dynamox mais eficiente e reduzir análises desnecessárias. Foram testados dois métodos: um que define um limiar global por um método empírico, baseado nas acelerações médias máximas e outro que utiliza o algoritmo de Otsu para segmentar os dados automaticamente. Para isso, foram coletados e analisados sinais de aceleração das máquinas, aplicando os dois métodos e avaliando qual conseguia distinguir melhor os momentos de operação e inatividade. Os resultados mostraram que o limiar global funciona muito bem para máquinas com aceleração moderada a alta, enquanto o algoritmo de Otsu é mais preciso para máquinas com aceleração muito baixa, embora exija mais tempo de processamento. No fim, o estudo demonstrou que é possível definir limiares eficazes para identificar quando a máquina está ligada, garantindo que apenas dados relevantes sejam analisados. Isso beneficia tanto os clientes, que recebem informações mais precisas, quanto a Dynamox, que reduz custos com armazenamento e processamento de dados desnecessários.

Palavras-chave: Monitoramento de vibração. Análise de sinais. Algoritmo de Otsu. Monitoramento preditivo.

ABSTRACT

This study aims to understand and compare two methods for identifying when an industrial machine is operating or idle, an essential factor for making Dynamox's monitoring more efficient and reducing unnecessary analysis. Two methods were tested: one that defines a global threshold using an empirical method based on maximum average accelerations, and another that uses the Otsu algorithm to automatically segment the data. To achieve this, acceleration signals from the machines were collected and analyzed, applying both methods and evaluating which one better distinguished moments of operation and inactivity. The results showed that the global threshold works very well for machines with moderate to high accelerations, while the Otsu algorithm is more accurate for machines with very low acceleration, though it requires more processing time. In the end, the study demonstrated that effective thresholds can be defined to identify when a machine is on, ensuring that only relevant data is analyzed. This benefits both clients, who receive more accurate information, and Dynamox, which reduces costs associated with storing and processing unnecessary data.

Keywords: Vibration monitoring. Signal analysis. Otsu algorithm. Predictive monitoring.

LISTA DE FIGURAS

Figura 1 – Exemplo de segmentação de imagem pelo método de Otsu.....	21
Figura 2 – Interface do DynaDetect.....	24
Figura 3 – Recursos avançados de análise.....	25
Figura 4 – DynaLoggers.....	28
Figura 5 – DynaLoggers instalados.....	28
Figura 6 – Gráfico de velocidade (mm/s) - DynaPredict.....	29
Figura 7 – Gráfico de temperatura (°C) - DynaPredict.....	29
Figura 8 – Gráfico de aceleração (g) - DynaPredict.....	29
Figura 9 – Gráfico dos sinais de aceleração nos eixos X, Y e Z.....	31
Figura 10 – Gráfico do sinal de aceleração resultante da soma dos eixos X, Y e Z..	32
Figura 11 – Gráfico dos sinais de aceleração nos eixos X, Y e Z e sua resultante (soma).....	32
Figura 12 – Gráfico de uma sinal com <i>outlier</i>	33
Figura 13 – Gráfico de um sinal após remoção de <i>outlier</i>	34
Figura 14 – Gráfico gerado após a análise do primeiro <i>script</i>	38
Figura 15 – Exemplo máquina ligada por muito tempo.....	39
Figura 16 – Validação algoritmo de Otsu.....	40
Figura 17 – Aceleração ao longo do tempo com limiares global e de Otsu.....	41
Figura 18 – Sinal com acelerações indefinidas.....	42
Figura 19 – Sinal com limiar global reduzido em 30%.....	42
Figura 20 – Sinal em que o desempenho de Otsu superou os limiares globais – exemplo 1.....	45
Figura 21 – Sinal em que o desempenho de Otsu superou os limiares globais – exemplo 2.....	45
Figura 22 – Sinal em que o desempenho de Otsu superou os limiares globais – exemplo 3.....	46
Figura 23 – Sinal com limiar de Otsu acima do esperado.....	46
Figura 24 – Sinal com limiar de Otsu próximo à aceleração mínima.....	47
Figura 25 – Primeiro exemplo de gráfico com resultados satisfatórios da análise....	47
Figura 26 – Segundo exemplo de gráfico com resultados satisfatórios da análise...	48

LISTA DE TABELAS

Tabela 1 – Análise das médias das acelerações.....	38
Tabela 2 – Resultados da análise sem <i>outliers</i> : número total de pontos e quantidade de erros por método.....	43
Tabela 3 – Resultados da análise considerando os <i>outliers</i> : número total de pontos e quantidade de erros por método.....	43
Tabela 4 – Erro percentual de cada amostra na análise sem <i>outliers</i> para os diferentes limiares.....	44
Tabela 5 – Erro percentual de cada amostra na análise considerando os <i>outliers</i> para os diferentes limiares.....	44
Tabela 6 – Comparação da taxa de erro total para cada método nos cenários com e sem <i>outliers</i>	48

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Justificativa.....	13
1.2	Definição do Problema.....	14
1.3	Objetivo Geral.....	15
1.4	Objetivos Específicos.....	15
1.5	Estrutura do Trabalho.....	15
2	FUNDAMENTAÇÃO TEÓRICA.....	17
2.1	Monitoramento de Vibrações em Máquinas Industriais.....	17
2.2	Algoritmo de Otsu para Segmentação de Dados.....	19
2.3	Tratamento de <i>Outliers</i> na Análise de Sinais.....	22
2.3.1	Método do Desvio Padrão.....	23
2.4	DynaPredict.....	23
2.5	Relação dos Tópicos Abordados com o Trabalho.....	25
3	METODOLOGIA.....	27
3.1	Métodos Aplicados.....	27
4	APRESENTAÇÃO DOS RESULTADOS.....	37
4.1	Definição do Limiar Global.....	37
4.2	Análise Final.....	40
5	CONSIDERAÇÕES FINAIS.....	50
5.1	Sugestões para Trabalhos Futuros.....	51
	REFERÊNCIAS.....	53

1 INTRODUÇÃO

Nos últimos anos, a mecanização e a automação dos processos produtivos têm desempenhado um papel fundamental na modernização da indústria. Com isso, a confiabilidade e a disponibilidade dos equipamentos tornaram-se fatores essenciais para a eficiência operacional. Com o avanço desse cenário, as estratégias e técnicas de manutenção de ativos empresariais passaram por significativas transformações na gestão da produção nas últimas três décadas (PIRES et al., 2018). Nesse contexto, ganha destaque o conceito de manutenção preditiva, que busca otimizar o desempenho dos equipamentos e reduzir custos com falhas inesperadas.

Segundo a NBR-5462, a manutenção preditiva é a:

Manutenção que permite garantir uma qualidade de serviço desejada, com base na aplicação sistemática de técnicas de análise, utilizando-se de meios de supervisão centralizados ou de amostragem, para reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva. (ABNT, 1994, p. 7).

Herpich e Fogliatto (2013) afirmam que a manutenção preditiva possibilita assegurar a qualidade do serviço por meio da aplicação sistemática de técnicas de análise. Utilizando supervisão centralizada ou por amostragem, essa abordagem busca prever falhas ao medir parâmetros que indicam sua evolução, permitindo correções antes que se tornem críticas. Dessa forma, busca-se realizar intervenções no momento adequado, reduzindo custos e aumentando a eficiência operacional.

Com base nisso, a empresa de tecnologia Dynamox, sediada em Florianópolis, se destaca como especialista em manutenção preditiva na indústria. Ela desenvolve e comercializa uma variedade de sensores sem fio e coletores de dados para monitoramento contínuo de vibração e temperatura de máquinas e equipamentos. Além disso, a empresa também desenvolveu uma plataforma *online* que, com o suporte de inteligência artificial, monitora continuamente os ativos, analisando seu comportamento e gerando alertas para a previsão de falhas nos equipamentos.

Para monitorar o funcionamento das máquinas utilizando a tecnologia da Dynamox, sensores coletam continuamente dados como velocidade, temperatura e

aceleração, transmitindo essas informações para análise na plataforma. Além da telemetria contínua, também é possível realizar a análise espectral, que se destaca por fornecer um detalhamento das frequências de operação, permitindo identificar padrões e anomalias. No entanto, essa análise é mais relevante quando a máquina está em funcionamento, pois é nesse momento que as vibrações refletem o real estado dos componentes.

Os dados coletados quando a máquina está desligada não contribuem de forma relevante para a análise do estado do ativo, pois não refletem seu comportamento real em operação. Além disso, armazenar essas informações representa um custo desnecessário, uma vez que possuem pouca utilidade para o diagnóstico das condições da máquina. Como a manutenção preditiva se baseia no histórico de funcionamento do equipamento, a inclusão de dados obtidos em condições diferentes das normais de operação pode comprometer a precisão das análises de tendências, distorcendo padrões esperados e reduzindo a confiabilidade das previsões. Dessa forma, a coleta de dados em momentos inadequados não apenas impacta a qualidade da análise, mas também gera custos adicionais sem benefícios práticos.

Diante desse cenário, este estudo tem como objetivo analisar e comparar dois métodos para definir um limiar que determine quando uma máquina está em operação. Isso permitirá a implementação dessa abordagem nas análises da Dynamox, garantindo que a coleta de dados espectrais ocorra apenas quando a máquina estiver ligada, otimizando o uso de recursos e aprimorando a precisão das análises.

1.1 Justificativa

A análise da condição operacional das máquinas têm um impacto direto na eficiência dos processos industriais, pois possibilita a redução de custos e a melhoria da confiabilidade dos equipamentos. Para isso, é essencial coletar apenas dados relevantes, evitando informações geradas com a máquina desligada, que podem comprometer a precisão das análises e gerar custos desnecessários. Essa

abordagem otimiza os recursos computacionais da Dynamox e agrega maior valor para os clientes.

Neste contexto, o objetivo deste trabalho é comparar dois métodos distintos para a definição de um limiar confiável: um baseado na análise empírica das acelerações médias máximas e outro utilizando o algoritmo de Otsu para segmentação automática dos dados. A comparação entre essas abordagens permitirá identificar qual delas oferece maior precisão na determinação do estado de funcionamento das máquinas.

O impacto desta pesquisa é considerável, pois possibilitará uma gestão mais eficiente dos recursos computacionais dos dispositivos da Dynamox, garantindo que análises espectrais sejam realizadas apenas quando realmente necessárias. Além disso, a definição mais precisa do estado operacional das máquinas contribuirá para um monitoramento mais preciso, elevando a confiabilidade das informações fornecidas aos clientes e otimizando a tomada de decisões no ambiente industrial.

1.2 Definição do Problema

A identificação precisa do estado operacional das máquinas é um problema recorrente em sistemas de monitoramento industrial. O desafio está na definição de um limiar que consiga separar de forma confiável os momentos em que a máquina está ligada dos momentos em que está desligada. A falta de um critério bem definido pode levar à execução de análises desnecessárias ou, por outro lado, à perda de dados relevantes sobre falhas mecânicas.

Assim, este estudo investiga qual método é mais eficaz na definição de um limiar que identifique com precisão os estados de operação das máquinas monitoradas pela Dynamox. Qual dos métodos analisados - a abordagem empírica das acelerações médias máximas ou o algoritmo de Otsu - apresenta maior precisão na determinação do estado operacional das máquinas?

1.3 Objetivo Geral

Analisar e comparar a eficiência de dois métodos para definição de um limiar na identificação do estado operacional de máquinas industriais, contribuindo para a otimização do monitoramento preditivo e a redução de custos computacionais.

1.4 Objetivos Específicos

Com base no objetivo geral, apresentam-se os seguintes objetivos específicos:

- a) revisar a literatura sobre monitoramento de vibração, o algoritmo de Otsu, estudo de identificação e filtragem de *outliers* e, por fim, a apresentação da plataforma DynaPredict;
- b) aplicar o método empírico de acelerações médias máximas para definição do limiar global;
- c) implementar o algoritmo de Otsu para segmentação automática dos dados;
- d) comparar os resultados obtidos pelos dois métodos em diferentes cenários de operação;
- e) avaliar o impacto da aplicação dos métodos na eficiência do sistema de monitoramento da Dynamox.

1.5 Estrutura do Trabalho

Este trabalho é composto por cinco capítulos. O primeiro capítulo tem como finalidade apresentar o tema, expondo a justificativa, a definição do problema e os objetivos do estudo.

O segundo capítulo apresenta a revisão da literatura essencial para a pesquisa, abordando o monitoramento de vibração, o algoritmo de Otsu como método de segmentação de dados e a identificação e filtragem de *outliers*. Esse embasamento teórico é fundamental para a definição da metodologia e das práticas realizadas no estudo. Além disso, é apresentada a plataforma DynaPredict, criada pela Dynamox para auxiliar na gestão e monitoramento de ativos industriais.

O terceiro capítulo descreve a metodologia utilizada no trabalho. Nele, são apresentados os métodos empregados para a definição do limiar global, detalhando os procedimentos para a análise empírica das acelerações médias máximas e a implementação do algoritmo de Otsu.

O quarto capítulo apresenta os resultados obtidos, seguidos de uma análise detalhada dos dados coletados. A comparação entre os métodos será discutida, avaliando a precisão e eficiência de cada abordagem na identificação do estado operacional das máquinas.

O quinto capítulo apresenta as conclusões e considerações finais do trabalho, resumindo as principais descobertas, destacando a eficácia dos métodos analisados e sugerindo possíveis direções para pesquisas futuras e aprimoramentos no monitoramento de máquinas industriais.

2 FUNDAMENTAÇÃO TEÓRICA

Para uma melhor compreensão deste trabalho e de seus aspectos fundamentais, este capítulo aborda a importância do monitoramento de vibração em máquinas industriais e os motivos que tornam essa análise essencial. Além disso, explica o funcionamento do algoritmo de Otsu, define o conceito de *outliers*, informação importante na análise de sinais de aceleração, e apresenta um método para sua remoção.

2.1 Monitoramento de Vibrações em Máquinas Industriais

O monitoramento de vibrações em máquinas industriais é um dos principais métodos empregados na manutenção preditiva. No entanto, segundo Mobley (2002, p. 114), a análise de vibração possui diversas aplicações além da manutenção preditiva, como:

- a) testes de aceitação: verifica se novos equipamentos atendem aos parâmetros de projeto, garantindo eficiência e minimizando custos com falhas prematuras;
- b) controle de qualidade: detecta variações na produção, prevenindo oscilações anormais em máquinas industriais que possam comprometer a qualidade do produto;
- c) detecção de peças soltas ou elementos estranhos: diagnostica a presença de objetos soltos em linhas de processo e vasos industriais, prevenindo falhas e danos;
- d) controle de ruído: identifica fontes de ruído em equipamentos industriais, permitindo ações corretivas para atender a normas regulatórias;
- e) detecção de vazamentos: monitora vibrações em válvulas e tubulações para identificar padrões anômalos causados por vazamentos;

- f) analisadores de motores aeronáuticos: utiliza sensores para monitorar vibrações em motores de aeronaves, auxiliando na detecção precoce de falhas;
- g) projeto e engenharia de máquinas: utiliza dados de vibração para aprimorar o desenvolvimento de novos equipamentos, garantindo maior confiabilidade e eficiência.

Além dessas aplicações, a análise de vibração, conforme destacado pela Dynamox (2023), desempenha um papel fundamental na manutenção preditiva, pois permite identificar falhas em estágios iniciais e viabiliza a adoção de medidas corretivas antes que evoluam para uma falha funcional. Dessa forma, as intervenções tornam-se mais ágeis e menos disruptivas para a operação industrial, reduzindo falhas graves, otimizando os intervalos de manutenção e contribuindo diretamente para a redução de custos. Além disso, o aumento da confiabilidade dos ativos e a extensão de sua vida útil impactam positivamente o desempenho financeiro das empresas e a segurança dos colaboradores.

A análise da vibração de um equipamento em operação permite obter informações sobre sua condição, uma vez que ele apresenta um padrão característico de vibração quando está em funcionamento normal. À medida que ocorrem falhas, esse padrão se altera devido ao aumento dos níveis de vibração. Comparando esses níveis com a assinatura de vibração original, é possível identificar condições de falha no equipamento. Além disso, a análise espectral da vibração auxilia na caracterização dos diferentes mecanismos de falha, permitindo um monitoramento eficaz do ativo sem a necessidade de interromper sua operação, possibilitando um planejamento antecipado das manutenções (SIEMANN, 2021).

Dessa forma, o monitoramento de vibrações em máquinas industriais se consolida como uma estratégia essencial para otimizar processos produtivos, reduzir custos e garantir a confiabilidade operacional, tornando-se um pilar fundamental na gestão de ativos industriais.

2.2 Algoritmo de Otsu para Segmentação de Dados

Um dos métodos mais conhecidos e amplamente utilizados para segmentação de sinais é o algoritmo de Otsu. Embora seja tradicionalmente aplicado à binarização de imagens para determinação automática de um limiar, neste trabalho, ele será empregado na segmentação de sinais de aceleração, com o objetivo de definir um limiar eficiente para a detecção de máquinas paradas.

O método de Otsu é amplamente reconhecido por sua capacidade de maximizar a variância entre classes, um critério essencial na análise estatística discriminante. Ele se baseia na premissa de que classes bem definidas devem apresentar diferenças significativas nos valores de intensidade de pixels, permitindo uma separação mais eficaz. Além disso, sua aplicação se destaca por utilizar exclusivamente cálculos baseados no histograma da imagem, o que facilita sua implementação (GONZALEZ; WOODS, 2010, p. 490).

Maia (2022) descreve que o método de Otsu baseia-se em um algoritmo que segmenta a imagem em duas classes, buscando maximizar a variância interna, a variância entre as classes e a variância total.

Segundo Otsu (1979), para realizar a segmentação da imagem, considera-se que os pixels estão distribuídos em L níveis de cinza, onde a quantidade de pixels em cada nível i é representada por n_i , e o total de pixels na imagem é dado por $N = n_1 + n_2 + \dots + n_L$. O histograma da imagem é normalizado para ser tratado como uma distribuição de probabilidade, conforme definido pela Equação 1.

$$p_i = \frac{n_i}{N}, \quad p_i \geq 0, \quad \sum_{i=1}^L p_i = 1 \quad (1)$$

Para realizar a segmentação, a imagem é dividida em duas classes, C_0 (fundo) e C_1 (objetos), utilizando um limiar k . Assim, os pixels são classificados como

$C_0 = [1, \dots, k]$ e $C_1 = [k + 1, \dots, L]$. Com base nisso, as probabilidades associadas às classes, w_0 e w_1 , são representadas pelas Equações 2 e 3.

$$w_0 = \sum_{i=1}^k p_i \quad (2)$$

$$w_1 = \sum_{i=k+1}^L p_i = 1 - w_0 \quad (3)$$

Já as médias das classes C_0 (fundo) e C_1 (objetos), representadas por μ_0 e μ_1 , são expressas conforme as Equações 4 e 5.

$$\mu_0 = \frac{\sum_{i=1}^k ip_i}{w_0} \quad (4)$$

$$\mu_1 = \frac{\sum_{i=k+1}^L ip_i}{w_1} \quad (5)$$

A separação ótima entre as classes é determinada pela maximização da variância entre classes, representada por σ_B^2 , definida como mostra a Equação 6.

$$\sigma_B^2 = w_0(\mu_0 - \mu_T)^2 + w_1(\mu_1 - \mu_T)^2 \quad (6)$$

Em que μ_T é a média total da imagem original, dada pela Equação 7.


$$\mu_T = \sum_{i=1}^L ip_i \quad (7)$$

Dessa forma, o limiar ideal k^* é aquele que maximiza $\sigma_B^2(k)$, garantindo a maior separabilidade entre o fundo e os objetos da imagem, conforme demonstrado pela Equação 8.

$$\sigma_B^2(k^*) = \max_{1 \leq k \leq L} \sigma_B^2(k) \quad (8)$$

Um exemplo da utilização desse algoritmo para segmentação de imagens é mostrado na Figura 1. A imagem à esquerda representa a versão original em tons de cinza. No centro, temos o histograma da imagem, onde a linha vermelha indica o limiar calculado automaticamente pelo método de Otsu. Já à direita, observa-se a imagem binarizada, onde os pixels foram separados em duas classes: fundo (branco) e objeto (preto), evidenciando a eficácia do algoritmo na segmentação.

Figura 1 – Exemplo de segmentação de imagem pelo método de Otsu



Fonte: Scikit-Image (2025).

Com base nesse exemplo, a utilização desse algoritmo neste trabalho tem como objetivo analisar sinais de aceleração e definir um limiar eficiente para diferenciar quando a máquina está parada ou em funcionamento. A escolha desse método se deve ao fato de que ele calcula automaticamente o limiar ideal sem necessidade de ajustes manuais, garantindo uma separação precisa entre os dois estados. Além disso, o Otsu é baseado na distribuição dos dados, o que permite

adaptar-se a diferentes máquinas e condições operacionais, tornando a detecção mais confiável.

2.3 Tratamento de *Outliers* na Análise de Sinais

Há várias formas de se definir o que é um *outlier*, algumas mais simples de se compreender e outras mais complexas e abstratas. Alguns exemplos de definições são:

- a) de acordo com Aggarwal (2017), um *outlier* é um ponto de dado que se diferencia de maneira significativa dos demais dados;
- b) Barnett e Lewis (1984) definem um *outlier* como uma observação, ou um conjunto de observações, que se mostra inconsistente com o restante dos dados em um determinado conjunto;
- c) Hawkins (1980) define um *outlier* de forma intuitiva como um dado que se desvia consideravelmente dos outros, gerando incertezas sobre os mecanismos responsáveis por sua geração.

Com base nessas definições, podemos entender que um *outlier* é um dado que, por alguma razão, não se comporta como os outros dados de um conjunto. Segundo Silva (2004), "*outliers* sempre ocorrem em pequenas proporções no conjunto ao qual pertencem, pois se vários elementos fossem *outliers*, seria impossível caracterizar um padrão". Isso indica que, apesar de sua presença ser rara, a identificação de *outliers* é fundamental para entender padrões e comportamentos anormais em um conjunto de dados.

Para a realização desta análise, é fundamental identificar e excluir os *outliers*, evitando a consideração de dados potencialmente incorretos que possam comprometer os resultados finais. Silva (2024) ressalta que a presença de *outliers* em conjuntos de dados pode influenciar de maneira significativa as análises, interferindo em sua interpretação e confiabilidade. Diante disso, torna-se essencial estabelecer um método adequado para a identificação desses valores discrepantes.

2.3.1 Método do Desvio Padrão

Um dos métodos mais simples e conhecidos para detectar *outliers* é o método do desvio padrão. Acuña e Rodriguez (2004) explicam que, em um conjunto de dados com n observações de uma variável x , um valor pode ser considerado um *outlier* se estiver fora do intervalo definido pela média $\bar{x}$ acrescida ou subtraída de um múltiplo k do desvio padrão s . O intervalo definido é mostrado na Equação 9.

$$(\bar{x} - ks, \bar{x} + ks) \quad (9)$$

Normalmente, k assume os valores 2 ou 3, pois, sob a suposição de distribuição normal, espera-se que cerca de 95% dos dados estejam dentro de dois desvios padrão da média e 99% dentro de três desvios padrão. Dessa forma, valores que ultrapassam esses limites podem ser identificados como discrepantes no conjunto de dados.

2.4 DynaPredict


Segundo a Dynamox (2025), o DynaPredict é uma plataforma *online* desenvolvida para facilitar a gestão e monitoramento de ativos industriais. Com ela, empresas podem acompanhar em tempo real o desempenho de suas máquinas, sensores e coletores por meio da árvore de ativos, garantindo uma visão detalhada de cada equipamento. Além disso, a plataforma permite o monitoramento individual dos *spots* (os pontos onde os sensores DynaLoggers estão instalados) e dos DynaGateways, que são responsáveis por coletar e transmitir os dados.

O diferencial do DynaPredict está no uso de inteligência artificial para interpretar os dados captados pelos sensores. Na prática, isso significa detectar falhas automaticamente e identificar possíveis problemas mecânicos, elétricos e fluidodinâmicos antes que eles se tornem algo sério. Assim, a equipe de manutenção pode agir antes que uma falha cause prejuízos ou paralise a operação.

O DynaPredict conta com diversas ferramentas para aprimorar a gestão de ativos e a tomada de decisões, como:

- a) DMA (*Decision Making Assistant*): painel que apresenta um resumo das condições de cada *spot* cadastrado, facilitando o monitoramento dos ativos;
- b) DynaDetect: funcionalidade que gera diagnósticos automatizados, destacando máquinas com possíveis falhas para ações corretivas e preventivas. Uma representação do DynaDetect é apresentada na Figura 2;
- c) *Dashboards* Interativos que permitem visualizar os dados coletados de forma estratégica, auxiliando na gestão dos ativos e na tomada de decisões.


Figura 2 – Interface do DynaDetect



Fonte: Dynamox (2025).

Além disso, a empresa informa que a plataforma oferece recursos como a gestão de coletas, que permite monitorar a transmissão dos dados dos sensores em tempo real, e a coleta de espectros sob demanda, possibilitando que analistas solicitem medições adicionais sempre que necessário. Alguns recursos de análise podem ser observados na Figura 3.

Figura 3 – Recursos avançados de análise



Fonte: Dynamox (2025).

Com essas funcionalidades o DynaPredict se torna uma ferramenta essencial para empresas que buscam otimizar a manutenção preditiva, reduzindo custos operacionais e aumentando a eficiência dos seus ativos.

2.5 Relação dos Tópicos Abordados com o Trabalho

A partir do que foi apresentado neste capítulo, foi possível entender o por que o monitoramento de vibrações em máquinas é tão importante. Ele é um dos principais métodos de análise na manutenção preditiva, garantindo que os equipamentos industriais sejam mais produtivos e seguros. Isso reforça a importância deste estudo para o avanço das técnicas de análise preditiva.

Além disso, foi explicado o funcionamento do algoritmo de Otsu, originalmente utilizado para binarização de imagens, mas que, neste estudo, será aplicado à segmentação de sinais de aceleração. Seu objetivo aqui é definir um limiar que permita identificar o estado operacional das máquinas de forma automática e eficiente.

Outro ponto muito importante discutido foi a identificação e remoção de *outliers*. No estudo dos sinais de aceleração, é essencial reconhecer corretamente esses pontos atípicos e eliminá-los para evitar distorções nos resultados. Para isso, será utilizado o método do desvio padrão.

Por fim, foi apresentada a plataforma DynaPredict, utilizada para obter os dados analisados neste estudo. Além disso, foram destacadas algumas de suas funcionalidades que auxiliam no monitoramento preditivo e na detecção de falhas.

Com base em todos esses conceitos, foi possível iniciar as análises deste trabalho com um embasamento teórico sólido, garantindo a base necessária para sua compreensão e desenvolvimento.

3 METODOLOGIA

Este trabalho tem como objetivo analisar e comparar a eficiência de dois métodos para determinar um limiar para identificar momentos em que máquinas estão paradas. Diante disso, foi realizada uma revisão bibliográfica sobre a importância da análise de vibração em máquinas industriais, um estudo sobre o funcionamento do algoritmo de Otsu, além de uma pesquisa sobre a definição de *outliers* e a definição de um método para filtrá-los.

A pesquisa adotou uma abordagem aplicada, pois este estudo busca descobrir métodos eficientes para identificar o estado operacional de máquinas industriais, melhorando a análise de vibração no monitoramento preditivo. De acordo com Gil (2022), a pesquisa aplicada se caracteriza pela obtenção de conhecimentos destinados à aplicação prática em contextos específicos.

Esse trabalho adota uma abordagem quantitativa e experimental, pois baseia-se na análise de dados numéricos extraídos de sensores e na validação empírica dos métodos propostos. Segundo Gil (2022), a pesquisa experimental busca testar hipóteses manipulando variáveis e observando seus efeitos, o que se aplica a este estudo ao avaliar diferentes limiares e suas respectivas taxas de erro na classificação dos estados da máquina.

Neste capítulo, serão apresentados os métodos utilizados para a obtenção dos dados para análise, o processo de definição dos limiares, assim como a metodologia empregada para validar e comparar os melhores métodos.

3.1 Métodos Aplicados

A primeira etapa deste trabalho consistiu em compreender como os dados são coletados e armazenados pela Dynamox. Foi identificado que essa coleta é realizada por sensores denominados DynaLoggers, conforme representados na Figura 4, que registram informações periodicamente. Um exemplo desse sensor instalado em um motor industrial é mostrado na Figura 5.

Figura 4 – DynaLoggers



Fonte: Dynamox (2025).


Figura 5 – DynaLoggers instalados



Fonte: Dynamox (2025).


Os dados coletados pelos sensores são obtidos por meio de coletores e transmitidos para a plataforma DynaPredict. Nesta plataforma, os dados são exibidos de acordo com seu tipo, podendo incluir velocidade (mm/s), conforme ilustrado na Figura 6, temperatura ($^{\circ}\text{C}$), conforme mostrado na Figura 7, e aceleração (g), conforme apresentado na Figura 8.

Figura 6 – Gráfico de velocidade (mm/s) - DynaPredict




Fonte: Dynamox (2024).

Figura 7 – Gráfico de temperatura (°C) - DynaPredict



Fonte: Dynamox (2024).

Figura 8 – Gráfico de aceleração (g) - DynaPredict



Fonte: Dynamox (2024).

Neste trabalho, o dado de maior interesse é a aceleração, obtida por meio de um acelerômetro integrado ao sensor. A medição é realizada em três eixos: X, Y e Z, também denominados horizontal, radial e vertical, conforme a configuração do cliente. A aceleração é expressa em múltiplos da aceleração da gravidade terrestre (g), onde 1g equivale a aproximadamente $9,81 \text{ m/s}^2$.

Uma informação importante é que os sensores da Dynamox não mostram exatamente 1g quando estão parados. Embora a aceleração da gravidade seja detectada, a análise é baseada apenas nos valores de aceleração variáveis, enquanto o componente constante da gravidade é descartado antes do processamento. Por isso, quando o sensor está em uma máquina parada, os valores de aceleração ficam próximos ao ruído de fundo do sensor. Essa é a razão pela qual os sinais apresentados para máquinas desligadas são próximos de 0g, e não de 1g.

Os dados para análise foram obtidos da plataforma DynaPredict por meio de um *script* em Python, responsável pela extração e filtragem, mantendo apenas os dados de aceleração. No total, foram coletados dados de 100 sensores distintos, selecionados aleatoriamente para garantir uma maior diversidade de amplitudes e formas de sinais.

Para a análise inicial e definição do limiar global, foi escolhido o valor de 100 sinais distintos como amostras, pois esse número proporciona uma boa representatividade da variação dos sinais de aceleração sem tornar o processamento excessivamente demorado. Como havia um grande volume de dados disponível, foi necessário encontrar um equilíbrio entre diversidade e viabilidade, garantindo que o limiar definido refletisse o comportamento geral das máquinas monitoradas, sem ser influenciado por casos muito específicos.


Além disso, o valor de 100 sinais de amostras foi escolhido com base nos conceitos de estatística e probabilidade relacionados à estimativa de proporção em uma amostra. Para determinar esse número, foi utilizada a Equação 10, proposta por Thompson (2012), na qual o cálculo do tamanho amostral (n) depende do nível de confiança desejado (Z), do erro máximo permitido (d) e da estimativa de sucesso esperada (p).

$$n = \frac{Z^2 \cdot p \cdot (1-p)}{d^2} \quad (10)$$

Com base nessa fórmula, chegou-se ao número de 100 amostras considerando um nível de confiança de 80%, uma porcentagem de sucesso esperada de 70% e uma margem de erro de 5%. Esses valores foram definidos empiricamente, com base na observação do funcionamento das máquinas e na expectativa de bons resultados.

A partir da coleta de dados de aceleração dos sensores, iniciou-se a criação de um *script*¹ para analisar os dados. A primeira etapa consistiu na definição do sinal a ser analisado. Inicialmente, foram observados os sinais de aceleração nos eixos X, Y e Z separadamente, conforme ilustrado na Figura 9.

Figura 9 – Gráfico dos sinais de aceleração nos eixos X, Y e Z




Fonte: Elaboração própria (2025).

Como esses sinais possuem a mesma grandeza, optou-se por trabalhar com o sinal resultante da soma das acelerações nos três eixos, apresentado na Figura 10. Essa escolha se deve ao fato de ser uma operação linear, permitindo uma análise mais simplificada e eficiente ao considerar um único sinal, em vez de avaliar

¹ Os *scripts* utilizados neste trabalho estão disponíveis em:
https://github.com/LauraMWerneck/Codigos_TCC


três separadamente. A Figura 11 compara as curvas individuais com o sinal resultante, evidenciando que a soma das acelerações destaca de forma mais significativa a diferença entre a máquina em funcionamento e parada. Esse fato nos traz maior viabilidade em determinar um limiar de detecção de máquina parada, objetivo deste trabalho.

Figura 10 – Gráfico do sinal de aceleração resultante da soma dos eixos X, Y e Z



Fonte: Elaboração própria (2025).

Figura 11 – Gráfico dos sinais de aceleração nos eixos X, Y e Z e sua resultante (soma)




Fonte: Elaboração própria (2025).

Com a definição do sinal a ser analisado, iniciou-se o estudo da melhor abordagem para estabelecer um limiar global que pudesse ser aplicado a diferentes tipos de sinais. O objetivo era determinar um limite único, evitando a necessidade de calcular um limiar específico para cada sinal individualmente, tornando o processo mais eficiente e ágil.

Pensando nisso, foi proposta a ideia de analisar a média das acelerações das amostras coletadas. A média a ser analisada seria a média das acelerações máximas e mínimas de cada sinal. Para realizar essa tarefa, foi criado um código o qual recebia o sinal de aceleração e calculava a mediana dele. Todos os valores acima da mediana eram usados para calcular a média da aceleração máxima do sinal, e os valores abaixo da mediana, usados para calcular a média das acelerações mínimas do sinal. A mediana foi escolhida para esse cálculo devido à uniformidade da maioria dos dados.

No entanto, antes de realizar os cálculos das médias das acelerações foi necessário realizar uma operação de remoção de *outliers*. Isso se deve ao fato de que alguns dos sinais coletados apresentarem picos que não eram periódicos e que se mostravam como pontos de dados errôneos sobre o sinal. Um exemplo dessa ocorrência, identificado em uma das amostras analisadas, é ilustrado na Figura 12.


Figura 12 – Gráfico de uma sinal com outlier



Fonte: Elaboração própria (2025).

Dessa forma, foi desenvolvida uma função que analisava o sinal de aceleração com base no seu desvio padrão (conforme método descrito na seção 2.3.1), e os valores que ultrapassaram os limites definidos por esse método eram descartados da análise, por serem considerados discrepantes em relação ao restante. O sinal mostrado na Figura 12, após a remoção dos *outliers*, é apresentado na Figura 13. Com os sinais filtrados, foram realizadas as análises das médias superiores e inferiores das acelerações.

Figura 13 – Gráfico de um sinal após remoção de *outlier*



Fonte: Elaboração própria (2025).

A partir da análise das médias das acelerações máximas e mínimas, foi possível estabelecer um limiar global para determinar se a máquina estava parada ou em funcionamento. A explicação detalhada de como esse resultado foi obtido é abordada no capítulo 4, que apresenta os resultados deste trabalho.

Além da definição do limiar global, ao analisar as amostras iniciais, também foi testado o uso do algoritmo de Otsu para a análise de um sinal contínuo no tempo, em vez de uma imagem. Para isso, foi utilizada a função de limiarização por Otsu, disponibilizada pela biblioteca *skimage* do Python.

Essa função recebe uma imagem em escala de cinza, representada por um array, e permite, de forma opcional, definir o número de intervalos (*bins*) e

fornecer um histograma para o cálculo. Ela determina um valor de limiar (*threshold*), onde os pixels com intensidade superior a esse valor são classificados como primeiro plano, enquanto os pixels com intensidade inferior ficam no fundo.

Para este estudo, foi fornecido para a função apenas o sinal da soma da aceleração como um array de dados. Assim, a função aplicou a lógica do algoritmo de Otsu e foi capaz de calcular o limiar de Otsu para o sinal de aceleração, em vez de uma imagem. A partir desse teste, foi possível concluir que o algoritmo pode ser utilizado também para a análise de sinais unidimensionais.

Com a definição do limiar global e a confirmação de que o algoritmo de Otsu poderia ser utilizado para a análise de um sinal de aceleração, iniciou-se a validação e comparação dos dois métodos para determinar os momentos em que uma máquina está ligada ou desligada.

Como foram extraídos 100 amostras para a definição do limiar global e para o teste da função de Otsu, determinou-se que seriam necessárias mais 50 amostras para a etapa de validação. Esse número foi escolhido por ser suficiente para testar a eficácia dos limiares determinados sem comprometer a análise com um volume excessivo de dados. Importante destacar que para o levantamento do limiar global estas 50 amostras nunca foram verificadas na metodologia de forma que serão utilizadas exclusivamente para testar a eficácia do limiar. Dessa forma, foram coletados outros 50 sinais de aceleração de diferentes sensores, com intensidades variadas, garantindo que a validação abrangesse uma diversidade de cenários e permitindo verificar se os limiares funcionavam corretamente em diferentes condições, sem tornar o processo excessivamente extenso ou complexo.

Após a extração dos dados e a soma das acelerações nos eixos X, Y e Z, esses dados foram analisados por outro *script*, responsável por remover *outliers* para o cálculo do limiar de Otsu e após isso gerar um gráfico. O gráfico exibe o sinal original (incluindo *outliers*, se houver), o valor do limiar de Otsu calculado e o limiar global obtido na primeira análise.

Esse novo gráfico foi elaborado com base nas amostras do sinal, onde cada ponto representa uma amostra em um determinado instante de tempo. Assim,

trata-se de um gráfico amostral, mas para facilitar a visualização do comportamento da máquina e identificar se estava ligada ou desligada, também foi gerado um gráfico contínuo sobreposto. Com essa abordagem, foi possível distinguir os momentos de operação da máquina, analisando os pontos amostrais que estavam acima ou abaixo dos limiares estabelecidos. A partir dessa análise, foi possível avaliar qual método de definição de limiar melhor atendia às expectativas.

4 APRESENTAÇÃO DOS RESULTADOS

Este capítulo apresenta os resultados obtidos a partir da análise dos sinais, utilizando os métodos descritos na metodologia. Inicialmente, foram analisadas as 100 amostras para determinar um limiar global e validar o funcionamento do algoritmo de Otsu na análise dos sinais.

Em seguida, foi realizada a segunda análise, com 50 amostras, focando na validação dos limiares. Nessa etapa, avaliou-se se os limiares atenderam à expectativa de identificar corretamente se a máquina estava ligada ou não, além de calcular o percentual de sucesso em cada caso.


Adicionalmente, este capítulo discute alguns pontos relevantes das análises, como situações em que a máquina permanece ligada por períodos prolongados e casos em que a aceleração da máquina apresenta valores muito baixos.

4.1 Definição do Limiar Global

A primeira análise realizada envolveu 100 amostras para a definição de um limiar global. Utilizando um *script* desenvolvido em Python para analisar as médias das acelerações, foi possível extrair dados como a média mínima e a média máxima das acelerações. Além disso, esse *script* também fornecia o valor do limiar calculado pelo algoritmo de Otsu.

Após esses cálculos, o *script* gerava um gráfico ilustrativo, como mostrado no exemplo da Figura 14. Nesse gráfico, o sinal já aparece filtrado para a remoção de *outliers*, e estão destacados em linhas pontilhadas a mediana calculada (na cor verde) para separação das médias, a média das acelerações máximas (na cor vermelha), a média das acelerações mínimas (na cor amarela) e o limiar determinado pelo algoritmo de Otsu (na cor roxa).

Figura 14 – Gráfico gerado após a análise do primeiro script



Fonte: Elaboração própria (2025).

Com essas informações, foi elaborada uma tabela que contém: o número da amostra, que varia de 1 a 100; o DynaLogger, que representa a identificação do sensor; a média da aceleração mínima; a média da aceleração máxima; e, por fim, o limiar de Otsu. Um modelo dessa tabela é apresentado na Tabela 1.

Tabela 1 – Análise das médias das acelerações


Nº da Amostra	DynaLogger	Média Aceleração Mínima	Média Aceleração Máxima	Limiar de Otsu
1	DyL3.02.C1925	0,0212761	3,3820587	0,0301597
2	DyL1.03.A1996	0,0763090	0,1801493	0,1190907
3	DyL1.03.A1541	1,4692427	2,1261190	0,1263005
4	DyL4.03.A5366	0,0222739	1,7210060	0,5813495
5	DyL0.02.A9678	0,0792777	1,9172637	0,9443829

Fonte: Elaboração própria (2025).

Com os dados coletados dos 100 sensores, localizados em máquinas diferentes, e após a análise das médias, observou-se que um possível valor de limiar global poderia ser a menor média de aceleração máxima encontrada.

Isso ocorreu porque, na maioria dos sinais, esse valor foi maior que os máximos valores da média de aceleração mínima. Nos poucos casos em que essa relação não se manteve, a causa foi o fato de a máquina permanecer ligada por longos períodos. Nesses casos, o cálculo da mediana não representou fielmente a separação entre valores máximos e mínimos, pois o sinal apresentava menos uniformidade em comparação aos demais, o mesmo ocorreria para situações em que a máquina fica desligada por muito tempo. Um exemplo dessa situação é mostrado na Figura 15.

Figura 15 – Exemplo máquina ligada por muito tempo




Fonte: Elaboração própria (2025).

Com base nessa análise, definiu-se que o limiar global seria o menor valor de aceleração média máxima encontrado entre os 100 sinais analisados, correspondente a 0,18015 g.

Além disso, esse estudo permitiu testar o algoritmo de Otsu em sinais de aceleração, em vez de imagens, validando seu funcionamento nesse contexto. Os resultados obtidos foram satisfatórios, como ilustrado no exemplo da Figura 16.

Figura 16 – Validação algoritmo de Otsu



Fonte: Elaboração própria (2025).


4.2 Análise Final

A partir da definição do limiar global e da validação do funcionamento do algoritmo de Otsu, foi necessário desenvolver um método para verificar a eficácia desses limiares e determinar a taxa de erro de cada um.

Os dados extraídos dos sinais de aceleração representam amostras de momentos específicos. Por isso, optou-se por analisar o gráfico das acelerações em conjunto com um gráfico discreto dos pontos amostrais. Essa abordagem permitiu identificar a forma de onda do sinal, diferenciando momentos em que a máquina estava ligada ou desligada. Além disso, foi possível quantificar os pontos em que a máquina estava ligada, mas foi erroneamente classificada como desligada pelos limiares, possibilitando o cálculo do percentual de erro de cada método.

Para essa análise, desenvolveu-se um novo *script* que processa o sinal de aceleração e contabiliza o número total de pontos amostrados. O *script* também gera um gráfico que exibe a aceleração ao longo do tempo, destacando tanto o limiar global definido anteriormente quanto o limiar calculado pelo algoritmo de Otsu para aquele sinal em específico. Um exemplo desse gráfico pode ser visto na Figura 17. A partir da visualização dos gráficos, duas situações importantes foram observadas.


Figura 17 – Aceleração ao longo do tempo com limiares global e de Otsu



Fonte: Elaboração própria (2025).

A primeira situação observada foi que alguns sinais apresentavam valores de aceleração intermediários, ou seja, nem tão altos para indicar que a máquina estava ligada, nem tão baixos para confirmar que estava desligada, como destacado na Figura 18. Como não era possível determinar com precisão se essas acelerações correspondiam a uma máquina parada ou em funcionamento, optou-se por realizar duas análises: uma desconsiderando esses valores como *outliers* e outra considerando-os como máquina ligada. Assim, foi possível avaliar o melhor e o pior cenário.


Figura 18 – Sinal com acelerações indefinidas



Fonte: Elaboração própria (2025).

Já a segunda observação foi que, em alguns sinais, as acelerações eram muito baixas, fazendo com que o limiar global parecesse elevado para certos casos. Para abranger mais situações, testou-se também um limiar reduzido em 30%, pois essa redução mostrou-se mais adequada em determinadas amostras, conforme ilustrado na Figura 19. Importante destacar que este valor de 30% foi obtido através de observações sobre as 100 amostras utilizadas, de forma que temos um patamar definido empiricamente.

Figura 19 – Sinal com limiar global reduzido em 30%



Fonte: Elaboração própria (2025).

A partir dos dados extraídos pelo *script* e dos gráficos de cada sinal, elaborou-se uma tabela comparativa para as duas análises (com e sem *outliers*). Essas tabelas incluem o número da amostra, o identificador do sensor, o número total de pontos do sinal e a quantidade de erros para cada método (limiar global reduzido, limiar global original e limiar de Otsu). Um trecho dessas tabelas pode ser observado na Tabela 2 (desconsiderando os *outliers*) e na Tabela 3 (considerando os *outliers*).

Tabela 2 – Resultados da análise sem *outliers*: número total de pontos e quantidade de erros por método

N° da Amostra	DynaLogger	N° Total de Pontos	N° de Pontos Errados Limiar Global Reduzido	N° de Pontos Errados Limiar Global	N° de Pontos Errados Limiar de Otsu
1	DyL0.02.A9093	183	0	1	2
2	DyL1.03.A1814	177	3	24	14
3	DyL4.03.A5360	186	8	133	1
4	DyL1.03.A3357	184	0	1	152
5	DyL3.01.A0131	344	0	0	0

Fonte: Elaboração própria (2025).

Tabela 3 – Resultados da análise considerando os *outliers*: número total de pontos e quantidade de erros por método

N° da Amostra	DynaLogger	N° Total de Pontos	N° de Pontos Errados Limiar Global Reduzido	N° de Pontos Errados Limiar Global	N° de Pontos Errados Limiar de Otsu
1	DyL0.02.A9093	183	0	2	5
2	DyL1.03.A1814	177	8	25	15
3	DyL4.03.A5360	186	9	134	1
4	DyL1.03.A3357	184	0	1	152
5	DyL3.01.A0131	344	77	77	77

Fonte: Elaboração própria (2025).

Além disso, a fim de quantificar o erro percentual de cada método, foi criada uma tabela adicional contendo a porcentagem de erro para cada amostra. Essa tabela apresenta o número da amostra, o identificador do sensor e a porcentagem de erro do limiar global reduzido, do limiar global e do limiar de Otsu, conforme ilustrado nas Tabelas 4 e 5.

Tabela 4 – Erro percentual de cada amostra na análise sem *outliers* para os diferentes limiares

Nº da Amostra	DynaLoggers	Porcentagem de Erro do Limiar Global Reduzido	Porcentagem de Erro do Limiar Global	Porcentagem de Erro do Limiar de Otsu
1	DyL0.02.A9093	0%	0,55%	1,09%
2	DyL1.03.A1814	3,95%	13,56%	7,91%
3	DyL4.03.A5360	4,30%	71,51%	0,54%
4	DyL1.03.A3357	0%	0,54%	82,61%
5	DyL3.01.A0131	0%	0%	0%

Fonte: Elaboração própria (2025).

Tabela 5 – Erro percentual de cada amostra na análise considerando os *outliers* para os diferentes limiares


Nº da Amostra	DynaLoggers	Porcentagem de Erro do Limiar Global Reduzido	Porcentagem de Erro do Limiar Global	Porcentagem de Erro do Limiar de Otsu
1	DyL0.02.A9093	0%	1,09%	2,73%
2	DyL1.03.A1814	4,52%	14,12%	8,47%
3	DyL4.03.A5360	4,84%	72,04%	0,54%
4	DyL1.03.A3357	0%	0,54%	82,61%
5	DyL3.01.A0131	22,38%	22,38%	22,38%

Fonte: Elaboração própria (2025).

Após a análise dos resultados, algumas observações importantes foram feitas. Em alguns casos, o algoritmo de Otsu obteve melhor desempenho do que os limiares globais, especialmente em sinais com acelerações médias máximas muito


baixas. Nesses casos, como o método de Otsu define um limiar exclusivo para cada máquina com base no sinal analisado, ele foi capaz de distinguir com maior precisão se a máquina estava ligada ou não. Esse comportamento pode ser observado nas Figuras 20, 21 e 21, onde os limiares globais ficaram acima do sinal de aceleração.

Figura 20 – Sinal em que o desempenho de Otsu superou os limiares globais – exemplo 1




Fonte: Elaboração própria (2025).

Figura 21 – Sinal em que o desempenho de Otsu superou os limiares globais – exemplo 2



Fonte: Elaboração própria (2025).


Figura 22 – Sinal em que o desempenho de Otsu superou os limiares globais – exemplo 3



Fonte: Elaboração própria (2025).


No entanto, em outros casos, o algoritmo de Otsu determinou limiares muito mais altos do que o necessário, como ilustrado na Figura 23. Já em algumas situações, ele calculou limiares excessivamente baixos, próximos da aceleração mínima da máquina, conforme demonstrado na Figura 24.

Figura 23 – Sinal com limiar de Otsu acima do esperado



Fonte: Elaboração própria (2025).


Figura 24 – Sinal com limiar de Otsu próximo à aceleração mínima



Fonte: Elaboração própria (2025).


De maneira geral, os resultados obtidos foram bastante satisfatórios. Como ilustrado nos gráficos das Figuras 25 e 26.

Figura 25 – Primeiro exemplo de gráfico com resultados satisfatórios da análise



Fonte: Elaboração própria (2025).

Figura 26 – Segundo exemplo de gráfico com resultados satisfatórios da análise



Fonte: Elaboração própria (2025).

Além disso, o limiar global reduzido apresentou um desempenho bastante consistente, com taxas de erro baixas na maioria dos casos. No total, sua taxa de erro foi de 4,94% na análise sem *outliers* e de 7,62% na análise considerando *outliers*. Para melhor visualização dos resultados, a Tabela 6 apresenta a porcentagem total de erro para cada método avaliado.

Tabela 6 – Comparação da taxa de erro total para cada método nos cenários com e sem *outliers*

	Análise Sem <i>Outlier</i>	Análise Com <i>Outlier</i>
Limiar Global Reduzido	4,94 %	7,62 %
Limiar Global	8,15 %	11,18 %
Limiar Otsu	5,45 %	8,46 %

Fonte: Elaboração própria (2025).

Como observado na Tabela 6, mesmo considerando os *outliers*, a taxa de erro obtida foi considerada satisfatória, especialmente devido à natureza da aplicação. Caso a máquina seja identificada erroneamente como desligada, apenas uma representação espectral será perdida, mas, como o erro de avaliação do limiar

global não é periódico, o sistema terá chances de realizar a análise corretamente em uma próxima coleta. Além disso, verificou-se que o algoritmo de Otsu apresentou boa eficiência, porém, além de não superar o desempenho do limiar global reduzido na maioria dos casos, também adiciona uma complexidade computacional maior ao processamento.

Com base nesses resultados, se fosse necessário escolher um único método, o limiar global reduzido seria a opção mais adequada, pois não exige tempo adicional para análise do sinal, tornando o processamento da informação mais rápido. No entanto, em situações onde as acelerações são muito baixas, recomenda-se utilizar a análise pelo algoritmo de Otsu para definir um limiar mais preciso na determinação da máquina parada.

5 CONSIDERAÇÕES FINAIS

A análise de vibrações é uma ferramenta essencial no monitoramento preditivo, permitindo a detecção precoce de falhas e o aumento da vida útil dos ativos industriais. No contexto da empresa Dynamox, especializada em manutenção preditiva por meio de sensores, coletores e uma plataforma de análise, essa abordagem é fundamental para evitar paradas inesperadas e otimizar a eficiência operacional.

Dentre as técnicas utilizadas pela Dynamox, destaca-se a análise espectral dos dados de vibração, que permite identificar padrões de operação e anomalias a partir das frequências presentes nos sinais. No entanto, essa análise só é relevante quando a máquina está ligada. A ausência de um mecanismo confiável para detectar se a máquina está parada pode levar à análise de dados irrelevantes, comprometendo a eficácia do monitoramento.

Diante desse problema, a definição de um limiar para identificar quando a máquina está parada torna-se essencial. Com essa informação, a plataforma pode processar apenas os dados coletados enquanto a máquina está em funcionamento, evitando análises desnecessárias e otimizando o uso dos recursos computacionais.

Neste trabalho, foram investigadas duas abordagens para determinar esse limiar: uma baseada em uma análise empírica de um conjunto de sinais e outra utilizando o algoritmo de Otsu. O primeiro método consistiu na definição de um limiar global, obtido a partir da análise da aceleração média máxima de diversos sinais. Identificou-se que um valor adequado para esse limiar seria a menor aceleração média máxima encontrada no conjunto analisado. No entanto, observou-se que reduzir esse valor em 30% proporciona uma melhor adaptação às variações dos sinais, aumentando a precisão da classificação dos estados da máquina.

A avaliação desse limiar global reduzido demonstrou que ele apresenta ótimos resultados tanto na análise considerando *outliers* quanto na análise sem *outliers*. Esse método garantiu que, na maioria dos casos, os dados fossem corretamente classificados como referentes à máquina ligada ou desligada,

tornando-se uma alternativa eficaz para a identificação do estado operacional do equipamento.

Além disso, foi testado o algoritmo de Otsu para a determinação do limiar. Inicialmente, validou-se sua aplicabilidade para sinais unidimensionais em vez de imagens e, com essa comprovação, os sinais de aceleração foram analisados. Os resultados indicaram que, embora o método de Otsu tenha apresentado um bom desempenho, ele frequentemente calculava limiares significativamente mais altos, o que levou a uma performance ligeiramente inferior à do limiar global reduzido. Além disso, o uso de Otsu introduz uma complexidade computacional adicional, enquanto o limiar fixo não exige qualquer processamento extra, tornando-se uma alternativa mais eficiente.

Entretanto, em sinais com aceleração muito baixa, o algoritmo de Otsu mostrou-se mais preciso. Dessa forma, conclui-se que o uso do limiar global reduzido é a melhor alternativa para máquinas com acelerações moderadas a altas, pois elimina a necessidade de processamento adicional e torna o sistema mais eficiente. Por outro lado, para máquinas com acelerações muito baixas, o algoritmo de Otsu pode ser uma opção mais confiável, ainda que implique em um maior tempo de processamento.

Com base nos resultados deste estudo, foi possível demonstrar que é viável determinar limiares eficazes para distinguir quando uma máquina está ligada ou desligada. Isso garante que apenas dados relevantes sejam coletados e analisados pela Dynamox, beneficiando tanto os clientes, que terão acesso a informações mais precisas, quanto a própria empresa, que reduzirá os custos de armazenamento e processamento de dados desnecessários.

5.1 Sugestões para Trabalhos Futuros

Sugere-se, para trabalhos futuros, ampliar a análise para incluir não apenas os dados de aceleração, mas também os dados de velocidade e temperatura, uma vez que esses parâmetros apresentam comportamentos distintos e podem contribuir significativamente para uma análise mais completa dos ativos.

Adicionalmente, recomenda-se o desenvolvimento de modelos de *Machine Learning* capazes de identificar automaticamente os padrões de funcionamento dos equipamentos, como os estados de máquina ligada e desligada, o que otimizará ainda mais as análises e proporcionará resultados mais precisos.

Outro ponto relevante para investigações futuras é a aplicação de diferentes algoritmos na determinação de limiares. Isso permitiria avaliar qual o método mais eficaz para cada situação, proporcionando uma análise mais robusta e com maior diversidade de exemplos.

REFERÊNCIAS

ACUÑA, Edgar; RODRIGUEZ, Caroline. **On detection of outliers and their effect in supervised classification**. Mayaguez: University of Puerto Rico at Mayaguez, 2004.

AGGARWAL, Charu C. **Outlier Analysis**. 2. ed. New York: Springer, 2017.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462: Confiabilidade e manutenibilidade**. Rio de Janeiro: Abnt–Associação Brasileira de Normas Técnicas, 1994. 37 p.

BARNETT, Vic; LEWIS, Toby. **Outliers in Statistical Data**. New York: Wiley, 1984.

DYNAMOX. **Página Inicial**. 2025. Disponível em: <https://dynamox.net/>. Acesso em: 20 mar. 2025.

_____. **Análise de vibração em máquinas industriais: principais ganhos**. 2023. Disponível em: <https://dynamox.net/blog/analise-de-vibracao-em-maquinas-industriais>. Acesso em: 23 fev. 2025.

_____. **DynaPredict**. Disponível em: <https://dyp.dynamox.solutions/signin>. Acesso em: 12 nov. 2024.

GIL, Antonio Carlos. **Como Elaborar Projetos de Pesquisa**. Rio de Janeiro: Atlas, 2022. Ebook. ISBN 9786559771653. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9786559771653>. Acesso em: 03 mar. 2025.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

HAWKINS, Douglas M. **Identification of outliers**. London: Chapman and Hall, 1980.

HERPICH, Cristiano; FOGLIATTO, Flávio Sanson. Aplicação de FMECA para Definição de Estratégias de Manutenção em um Sistema de Controle e Instrumentação de Turbogeneradores. **Iberoamerican Journal of Industrial Engineering**, Florianópolis, v. 5, n. 9, p. 70-88, out. 2013. Disponível em: <https://incubadora.periodicos.ufsc.br/index.php/IJIE/article/view/2594/pdf>. Acesso em: 22 fev. 2025.

MAIA, Marco Antônio Gonçalves. **Análise de Métodos para Detecção de Bordas em Dutos Submersos**. 2022. 39 f. TCC (Graduação) - Curso de Engenharia da Computação, Universidade Federal de Pernambuco, Recife, 2022. Disponível em: https://www.cin.ufpe.br/~tg/2022-1/tg_EC/TG_magm2.pdf. Acesso em: 16 fev. 2025.

MOBLEY, R. Keith. **An Introduction to Predictive Maintenance**. 2. ed. Elsevier Science, 2002. 459 p.

OTSU, Nobuyuki. A threshold selection method from gray-level histograms. **IEEE Transactions On Systems, Man, And Cybernetics**, v. 9, n. 1, p. 62-66, jan. 1979.

PIRES, Cinthia et al. **Importância da Criticidade de Equipamentos na Gestão da Manutenção**. 2018. 8 f. Centro Universitário de Belo Horizonte, Belo Horizonte, MG, 2018. Disponível em: <https://pmkb.com.br/wp-content/uploads/2018/07/Criticidade-de-Equipamentos-Gestao-da-Manutencao.pdf>. Acesso em: 22 fev. 2025.

SIEMANN, Gustavo Mello. **Análise de vibração: estudo da técnica e aplicação prática em uma indústria siderúrgica**. 2021. 64 f. TCC (Graduação) - Curso de Engenharia Mecânica, Unesp, Guaratinguetá, 2021.

SILVA, Alex Junio Souza da. **Uma Aplicação de Técnicas de Detecção de Outliers Multivariados para Identificação de Fraude Monetária**. 2024. TCC (Doutorado) - Curso de Estatística, Universidade Federal de Ouro Preto (Ufop), Ouro Preto, 2024.

SILVA, Flávio Roberto. **Uma Abordagem para Detecção de Outliers em Dados Categóricos**. 2004. 67 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Universidade Estadual de Campinas (Unicamp), Campinas, 2004.

SCIKIT-IMAGE. **Thresholding**. Disponível em: https://scikit-image.org/docs/0.25.x/auto_examples/segmentation/plot_thresholding.html#sphx-glr-auto-examples-segmentation-plot-thresholding-py. Acesso em: 30 fev. 2025.

THOMPSON, Steven K. **Sampling**. 3. ed. Hoboken: John Wiley & Sons, 2012.