

UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
NÍVEL MESTRADO PROFISSIONAL

GUILHERME ANGELO PIAIA

DESENVOLVIMENTO, IMPLEMENTAÇÃO E ESTUDO DE
CASO DE UM SOFTWARE PARA DETECÇÃO
AUTOMÁTICA DE FALHAS EM MOTORES ELÉTRICOS
DE INDUÇÃO E SISTEMAS MANCALIZADOS VIA
ANÁLISE DE VIBRAÇÃO E TEMPERATURA

São Leopoldo, RS

2022

GUILHERME ANGELO PIAIA

**DESENVOLVIMENTO, IMPLEMENTAÇÃO E ESTUDO DE
CASO DE UM SOFTWARE PARA DETECÇÃO
AUTOMÁTICA DE FALHAS EM MOTORES ELÉTRICOS
DE INDUÇÃO E SISTEMAS MANCALIZADOS VIA
ANÁLISE DE VIBRAÇÃO E TEMPERATURA**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica, pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade do Vale do Rio dos Sinos - UNISINOS.

Orientador:

Prof. Dr. Rodrigo Marques de
Figueiredo

São Leopoldo, RS

2022

P581d

Piaia, Guilherme Angelo.

Desenvolvimento, implementação e estudo de caso de um software para detecção automática de falhas em motores elétricos de indução e sistemas mancalizados via análise de vibração e temperatura / por Guilherme Angelo Piaia. – 2022.

47 f. : il. ; 30 cm.

Dissertação (mestrado) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Engenharia Elétrica, São Leopoldo, RS, 2022.

“Orientador: Dr. Rodrigo Marques de Figueiredo”.

1. Análise de vibração e temperatura. 2. Detecção de falhas. 3. Monitoramento em tempo real. 4. Motores elétricos de indução. 5. Aprendizado de máquina. 6. Software - Desenvolvimento. I. Título.

CDU: 621.313.33:004.4

GUILHERME ANGELO PIAIA

**DESENVOLVIMENTO, IMPLEMENTAÇÃO E ESTUDO DE
CASO DE UM SOFTWARE PARA DETECÇÃO
AUTOMÁTICA DE FALHAS EM MOTORES ELÉTRICOS
DE INDUÇÃO E SISTEMAS MANCALIZADOS VIA
ANÁLISE DE VIBRAÇÃO E TEMPERATURA**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica, pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade do Vale do Rio dos Sinos - UNISINOS.

Aprovado em 15 de outubro de 2021.

BANCA EXAMINADORA:

Prof. Dr. Lúcio Rene Prade – UNISINOS
Avaliador

Prof. Dr. Maurício de Campos – UNIJUÍ
Avaliador Externo

Prof. Dr. Sandro Jose Rigo – UNISINOS
Avaliador

Prof. Dr. Rodrigo Marques de
Figueiredo
(Orientador)

Visto e permitida a impressão
São Leopoldo, RS

Prof. Dr. Paulo Ricardo Pereira
Coordenador do Mestrado Profissional em En-
genharia Elétrica

AGRADECIMENTOS

Este trabalho é o resultado de muito esforço e dedicação, durante dois anos, não só meu, mas de todos que contribuíram de alguma forma para a realização do mesmo.

Aos meus pais, Celso e Luiza, agradeço pelo apoio e incentivo incondicional, nunca medindo esforços para me ajudarem.

Agradeço à minha namorada Patrícia, pelo incentivo, dicas e ajuda durante esse período.

Ao meu orientador, Prof. Dr. Rodrigo Marques de Figueiredo, agradeço pelos ensinamentos, amizade, rapidez e eficácia nos ensinamentos e orientações.

Agradeço aos meus sócios na Floki Sys, Lucas Weber, Giuliano e Patricia Hoffmann, pelo apoio e participação neste projeto.

Não poderia deixar de agradecer aos demais amigos, familiares, professores e funcionários da Unisinos, que de alguma forma ajudaram no decorrer do curso e no desenvolvimento deste trabalho.

*“Science, my boy, is made up of mistakes, but they are mistakes which it is useful to make,
because they lead little by little to the truth.”
(Jules Verne, Journey to the Center of the Earth)*

RESUMO

Falhas em equipamentos industriais acarretam parada de produção, prejuízos e por consequência, perda de competitividade com aquelas que mitigam estes problemas. O desenvolvimento e implementação de soluções que busquem detectar e identificar falhas nestes equipamentos são, em sua maioria, indispensáveis para se minimizar os prejuízos de produção e os potenciais riscos à saúde das pessoas que trabalham nestes ambientes. Presente nestas máquinas, estão os motores elétricos de indução, que acoplados em um sistema mancalizado, criam o movimento necessário para a realização da atividade objetivo da máquina. Estas partes que se movimentam, com o uso ou com alguma adversidade, em algum momento entrarão em colapso, evidenciando a falha, sendo então necessário o monitoramento dos mesmos em tempo real para se prever e evitá-las. O atual estado da arte apresenta alguns trabalhos que consideram a energia da vibração no espectro, mas a construção de um sistema que monitore em tempo real e pode ser usado em diversos dispositivos, não foram encontrados trabalhos neste sentido. O presente trabalho propõe uma solução que integra *software* e *hardware* para resolver o problema antes citado, inclusive em tempo real e que aprende o comportamento do equipamento, sugerindo regiões de alerta e perigo, servindo de ferramenta para tomada de decisões. Para o desenvolvimento, as grandezas físicas de vibração foram utilizadas, com técnicas de processamento de sinais e *machine learning* (aprendizado de máquina). Após o desenvolvimento e implementação, a solução foi empregada em um estudo de caso em empresas de diferentes ramos da indústria, que obtiveram resultados positivos. A solução conseguiu armazenar, processar e disponibilizar os dados de vibração e temperatura em tempo real, onde o sistema detectou com antecedência em um dos casos, e no outro, mesmo com o estado avançado de desgaste do equipamento, segundo a norma ISO 10816-1, demonstrar que o equipamento se encontrava em estado severo.

Palavras-chaves: Análise de Vibração e temperatura. Detecção de Falhas. Monitoramento em tempo real. Motores elétricos de indução. Aprendizado de Máquina.

ABSTRACT

Faults in industrial equipment lead to production interruptions, losses and, consequently, loss of competitiveness with those that mitigate these problems. The development and implementation of solutions that seek to detect and identify faults in this equipment are, mostly indispensable to minimize production losses and potential risks to the health of people working in these environments. Present in these machines, the engines induction motors, which coupled in a bearing system, create the necessary movement to carry out the objective activity of the machine. These moving parts, with the use or with any adversity, at some point they will collapse, showing the fault, so it is necessary to monitor them in real time to predict and avoid them. The current state-of-the-art presents some works that consider the vibration energy in the spectrum, but the construction of a system that monitors in real time and can be used in several devices, no works were found in this sense. This work presents a solution that integrates software and hardware for solve the aforementioned problem, including in real time and that learns the behaviour equipment, suggesting regions of alert and danger, serving as a tool for taking decisions. For the development, the physical quantities of vibration were used, together with signal processing techniques and machine learning. After development and implementation, the solution was used in a case study in companies from different branches of industry, which obtained very positive results. The solution was able to store, process and make available the vibration and temperature data in real time, where the system detected in advance in one case, and not the other, despite the advanced state of wear of the equipment, according to an ISO 10816-1 standard, demonstrate that the equipment was in severe condition.

Keywords: Vibration. Fault Analysis. Vibration and Temperature Analysis. Fault Detection. Real Time Monitoring. Machine Learning. Induction Motor.

LISTA DE FIGURAS

Figura 1 – Motor elétrico de indução tipo gaiola de esquilo.	15
Figura 2 – Circuito equivalente monofásico de um motor de indução polifásico.	16
Figura 3 – Visão geral de sistema com um motor elétrico.	17
Figura 4 – Árvore dos principais tipos de falhas em motores elétricos.	18
Figura 5 – Ilustração com os tipos de desalinhamento.	18
Figura 6 – Imagens de rolamentos no topo, e falhas na parte de baixo.	19
Figura 7 – Ilustração da variação da carga para distinção da causa do efeito observado.	20
Figura 8 – Indicação espectral de desalinhamento na velocidade.	22
Figura 9 – Indicação espectral de desbalanceamento na velocidade.	22
Figura 10 – Árvore de métodos de monitoramento de falhas em motores elétricos.	23
Figura 11 – Metodologia do Projeto	28
Figura 12 – Estrutura do simulador MFS [®]	29
Figura 13 – Desenho simplificado da Planta.	30
Figura 14 – Tarefas de Aquisição e ML	31
Figura 15 – Tarefa de monitoramento	33
Figura 16 – Fluxo de acesso do <i>software</i>	34
Figura 17 – Diagrama de integração entre sensores e <i>software</i>	36
Figura 18 – Fotografia externa de um exaustor industrial.	37
Figura 19 – Fotografia externa do sensor instalado em um exaustor industrial.	38
Figura 20 – Captura de tela do sistema instalado no exaustor.	40
Figura 21 – Velocidade RMS [$\frac{mm}{s}$] coletados do eixo x (A) e z (B).	41
Figura 22 – Temperatura em °C amostrada no exaustor.	42
Figura 23 – Linhas de base e sinais coletados em um dos 5 sensores na seleira universal.	43
Figura 24 – Linhas de base e dados de velocidade [$\frac{mm}{s}$] no momento da instalação (A) x próximo da falha (B).	44
Figura 25 – Temperatura [°C] amostrada na seleira universal.	45

LISTA DE TABELAS

Tabela 1 – Tabela de valores eficaz máximos de velocidade para cada porte de máquina indicados pela norma ISO 10816-1.	21
Tabela 2 – Tabela de trabalhos correlatos.	27
Tabela 3 – Testes realizados.	30
Tabela 4 – Especificações do Sensor QM30VT2	35
Tabela 5 – Características da prova de conceito no exaustor	38
Tabela 6 – Características da prova de conceito na seleira universal	39

LISTA DE ABREVIATURAS E SIGLAS

ISO	<i>International Organization for Standardization</i> (Organização Internacional de Normalização)
FFT	<i>Fast Fourier Transform</i> (Transformada rápida de Fourier)
CNN	<i>Convolutional Neural network</i> (Rede neural convolucional)
RNA	Rede Neural Artificial
ICA	<i>Independent Component Analysis</i> (Análise de componentes independentes)
RMS	<i>Root Mean Square</i> (Raiz do valor quadrático médio)
ML	<i>Machine Learning</i> (Aprendizado de máquina)
DFT	<i>Discrete Fourier Transform</i> (Transformada discreta de Fourier)
MFS	<i>Machinery Fault Simulator</i> (Simulador de falhas em máquinas)
RTU	<i>Remote Terminal Unit</i> (Unidade de terminal remoto)
TCP	<i>Transmission Control Protocol</i> (Protocolo de Controle de Transmissão)
MTBF	<i>Mean Time Between Failures</i> (Tempo médio entre falhas)
DA	Desalinhamento
DB	Desbalanceamento

LISTA DE SÍMBOLOS

\hat{V}_1	Tensão no estator
\hat{E}_2	Força eletromotriz contrária gerada pelo fluxo no entreferro
\hat{I}_1	Corrente do estator
\hat{R}_1	Resistência efetiva do estator
\hat{X}_1	Reatância de vazamento do estator
R_c	Resistência às perdas no núcleo
X_m	Reatância magnetizante
\hat{I}_2	Componente de corrente gerada pela carga
\hat{X}_2	Reatância de vazamento do rotor no estator na frequência de escorregamento
R_2	Resistência do rotor
\hat{I}_φ	Componente de corrente excitada no estator
X_{RMS}	Valor RMS da função $x(t)$
T	Período
E	Energia
P	Potência
N	Número de amostras de um sinal
\bar{x}	Média aritmética do sinal $x(t)$
σ	Desvio padrão
var	Variância
n	Enésimo elemento
A	Nível de alerta de vibração
Pe	Nível de perigo de vibração
α	Coefficiente de alerta
β	Coefficiente de perigo

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO BIBLIOGRÁFICA	15
2.1	Motores Elétricos de Indução	15
2.2	Falhas em Motores Elétricos de Indução	17
2.3	Sistemas de Detecção e Diagnóstico de Falhas	20
2.3.1	Análise de Vibração	20
2.4	Técnicas de Processamento de Sinais	23
2.5	Estado da Arte	25
3	METODOLOGIA	28
3.1	Configurações das Simulações	29
3.2	Desenvolvimento do <i>software</i>	31
3.3	Integração entre <i>Software</i> e <i>Hardware</i>	35
3.4	Estudo de Caso	36
4	ANÁLISE DE RESULTADOS	40
5	CONCLUSÃO	46
	REFERÊNCIAS BIBLIOGRÁFICAS	47

1 INTRODUÇÃO

Os motores elétricos de indução são amplamente empregados na indústria pela sua confiabilidade e construção, tornando uma opção econômica e confiável (UMANS, 2014). Com o tempo, esses equipamentos apresentam falhas decorrentes dos regimes de trabalho, esforços não projetados, ou somente pelo desgaste natural dos componentes. Nesses casos, a aplicação de uma estratégia de manutenção apropriada, que monitore em tempo real e indique a manutenção em um tempo ótimo, pode diminuir em até 65% os custos de manutenção (RANDALL, 2011).

Essa técnica preditiva, que possibilita essa intervenção ótima, pode ser desenvolvida com diversas ferramentas, desde o monitoramento de limites de vibração até a utilização de técnicas modernas de inteligência artificial e aprendizado de máquina. Indicar que a falha é iminente ou está se desenvolvendo é imprescindível para um processo ser mais produtivo, pois a manutenção pode ser programada para um horário onde a máquina já estaria parada para outros fins, maximizando a produção, além do processo de manutenção ser mais rápido, já que os elementos não se danificaram por completo.

Este trabalho tem como principal objetivo a implementação de uma técnica de manutenção preditiva, onde possibilite a detecção de falhas via análise da vibração em motores elétricos de indução e sistemas mancalizados. Essa solução une técnicas de processamento de sinais e aprendizado de máquinas, visando identificar limites de vibração para detecção de falhas de forma menos invasiva e mais acessível economicamente possível, possibilitando o aumento da produtividade da indústria local. As principais contribuições deste trabalho são:

- Técnica automática para prever falhas em equipamentos industriais;
- Monitoramento em tempo real de diversos equipamentos;
- Interface gráfica completa e de simples operação;
- Escalabilidade da solução;
- Trabalhos futuros que poderão ser baseados neste.

A metodologia proposta pelo presente trabalho inicia com a utilização de um simulador de falhas em máquinas, onde foi possível modelar a proposta de solução de *software*. Passa pelo desenvolvimento do *software*, que emprega ferramentas como Python, InfluxDB e Node-Red para a prototipação. Na integração entre *software* e *hardware*, que une a solução de software ao *hardware* industrial, por um protocolo industrial. Ao final da execução, temos o estudo de caso, o qual aplica a solução desenvolvida em duas empresas de diferentes setores, visando prova de conceito e validação do produto, gerando possível aquisição do sistema por parte da empresa.

O trabalho está organizado em capítulos, onde o presente é o primeiro. O segundo é o referencial teórico, que aborda conceitos básicos sobre o trabalho, acrescentando o estado da arte ao final, onde é possível ver o estágio atual das tecnologias que propõem resolver o mesmo problema. Seguindo, o terceiro capítulo é a metodologia, onde as simulações, desenvolvimento do *software* e os estudos de casos são apresentados. Já no quarto capítulo, os resultados são apresentados e com a análise dos mesmos. Por último, a conclusão, onde estão descritos os principais desfechos, limitações e problemas encontrados, além dos próximos passos, que podem ser tomados a partir deste trabalho.


2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta de forma evolutiva todos os conceitos utilizados neste trabalho, iniciando pelo estudo de motores elétricos com suas particularidades, passando pelas técnicas de processamento de sinais, até o estado da arte em detecção e diagnóstico de falhas em motores elétricos de indução.

2.1 Motores Elétricos de Indução

Motores elétricos de indução são um dos tipos de máquinas elétricas, as quais convertem energia elétrica em mecânica. Nos motores elétricos de indução, uma corrente elétrica é induzida no rotor através da corrente de armadura que circula no estator. Contudo, um rotor do tipo gaiola de esquilo, pode ser visto na Figura 1, é um curto-circuito formado por barras e lâminas de alumínio. Por essa constituição simples, motores elétricos de indução com rotor do tipo gaiola resultam em motores relativamente baratos e confiáveis, contribuindo para sua popularidade (UMANS, 2014).

Figura 1 – Motor elétrico de indução tipo gaiola de esquilo.




Fonte: Adaptado de Petruzella (2016).

Uma das formas de se modelar um motor elétrico de indução, é através de uma representação em forma de um circuito elétrico, onde todas as variáveis podem ser representadas por componentes elétricos simples, facilitando a compreensão, modelagem e detectar possíveis variações nos elementos mecânicos e elétricos. O circuito representado na Figura 2, é um circuito equivalente monofásico de um motor elétrico indutivo polifásico, o que simplifica toda a análise

em um único circuito, onde é trivial isolar a tensão em um terminal e a sua corrente. Para se saber as demais correntes e tensões, basta deslocar as fases em $\pm 120^\circ$ (UMANS, 2014).

Figura 2 – Circuito equivalente monofásico de um motor de indução polifásico.



Fonte: Umans (2014).

onde

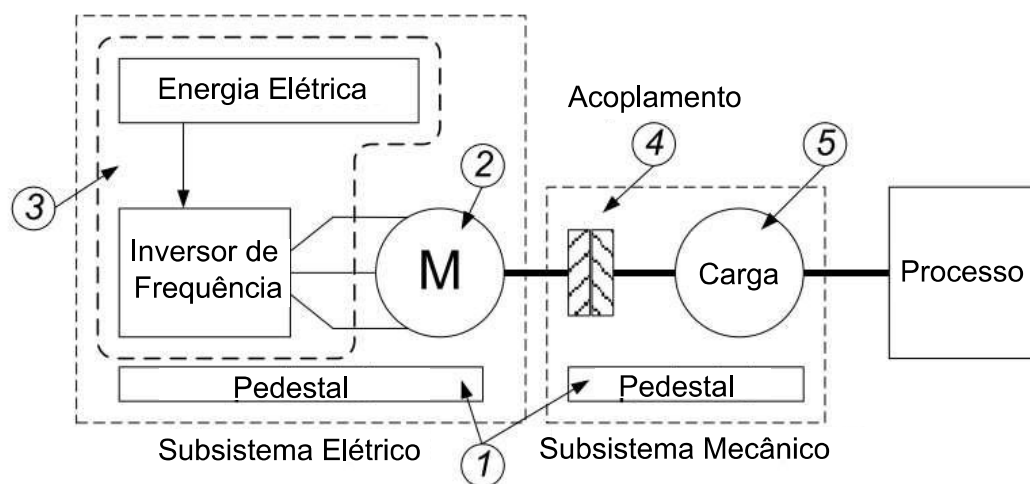
- \hat{V}_1 = tensão no estator [V]
- \hat{E}_2 = Força eletromotriz contrária gerada pelo fluxo no entreferro [V]
- \hat{I}_1 = corrente do estator [A]
- \hat{R}_1 = resistência efetiva do estator [Ω]
- \hat{X}_1 = reatância de vazamento do estator [Ω]
- R_c = resistência às perdas no núcleo [Ω]
- X_m = reatância magnetizante [Ω]
- \hat{I}_2 = componente de corrente gerada pela carga [A]
- \hat{X}_2 = reatância de vazamento do rotor no estator na frequência de escorregamento [Ω]
- R_2 = resistência do rotor [Ω]
- \hat{I}_φ = componente de corrente excitada no estator [A]

Com a apresentação de conceitos básicos sobre motores elétricos de indução e sua modelagem, é possível abordar as principais falhas que acometem as partes mecânicas e elétricas de um motor elétrico.

2.2 Falhas em Motores Elétricos de Indução

Como dito anteriormente, um motor elétrico é utilizado para transformar energia elétrica em mecânica, sendo empregado em máquinas que podem realizar diversas atividades. A Figura 3 representa uma generalização de um sistema em que um motor elétrico é empregado. Nesta Figura, podemos ver os elementos que constituem a parte elétrica: a fonte de energia, o inversor de frequência e o próprio motor. Também é possível ver a parte mecânica: a estrutura do motor, o acoplamento mecânico, a carga e as bases. Todos esses elementos podem induzir falhas no motor, começando pelo acionamento, onde pode ocorrer uma falha e fazer o motor perder uma fase, ou ainda, oscilações na tensão e sobrecarga. Todas essas falhas inevitavelmente alteram o espectro da fonte de energia Gorbounov e Dzhikov (2018). Na parte mecânica, o desalinhamento entre a carga e o motor pode acarretar falhas no acoplamento que transfere a energia mecânica do motor para o processo, e isso é normalmente provocado por uma instalação inapropriada.

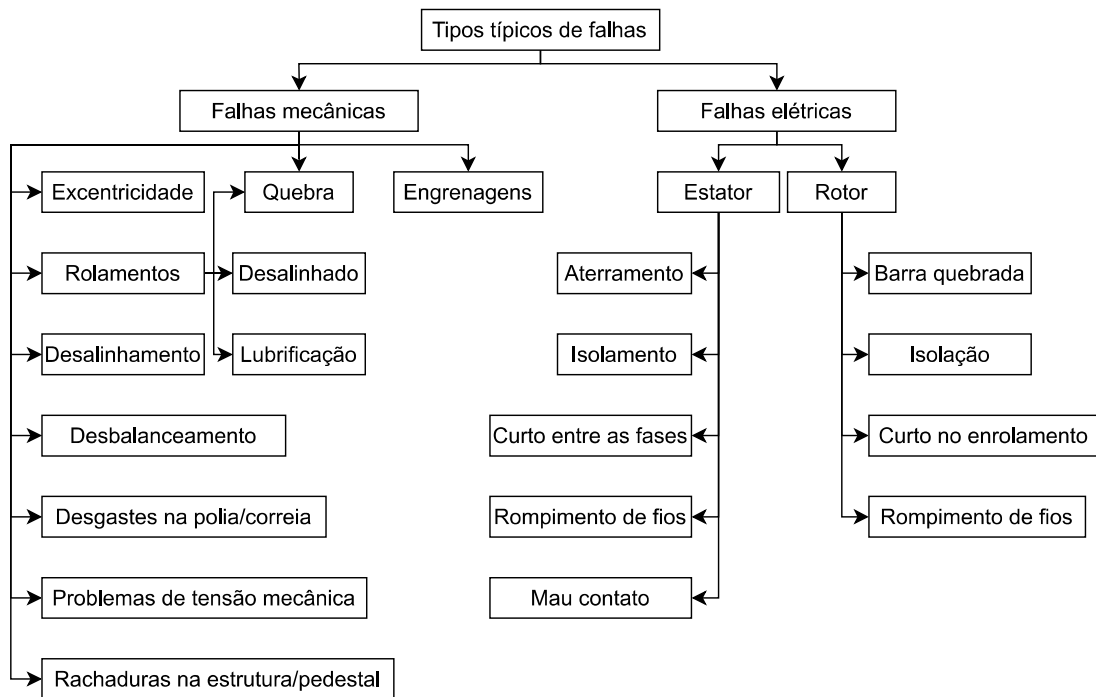
Figura 3 – Visão geral de sistema com um motor elétrico.



Fonte: Adaptado de Gorbounov e Dzhikov (2018).

A Figura 4 apresenta uma árvore das principais falhas que acometem os motores elétricos, sendo também divididas em mecânicas e elétricas.


Figura 4 – Árvore dos principais tipos de falhas em motores elétricos.



Fonte: Adaptado de Gorbounov e Dzhikov (2018).

Dentre todas essas falhas, o trabalho aborda com maior foco as falhas mecânicas, mais especificamente desalinhamento, rolamentos e desbalanceamento que causam um aumento na vibração do sistema. O desalinhamento ocorre quando o motor e o sistema não estão perfeitamente alinhados, podendo ter dois tipos: paralelo e angular, os quais podem ser vistos na Figura 5, respectivamente na parte (a) e (b) (SOPCIK; SULLIVAN, 2019).

Figura 5 – Ilustração com os tipos de desalinhamento.



Fonte: Sopcik e Sullivan (2019).

Já a falha de desbalanceamento, pode ocorrer em qualquer parte rotativa do sistema, que vai desde o motor até a carga, compreendida por algum problema na disposição das massas. Por último, os rolamentos, que são utilizados em diversas partes de um sistema e que podem apresentar pequenas rachaduras na falta de lubrificação, que podem ser vistas na Figura 6, aumentando a vibração (SOPCIK; SULLIVAN, 2019).

Figura 6 – Imagens de rolamentos no topo, e falhas na parte de baixo.



Fonte: Adaptado de Sopcik e Sullivan (2019).

Mais de 66% destas falhas são detectadas durante a operação e 28% são encontradas apenas durante a manutenção preventiva (GORBOUNOV; DZHIKOV, 2018), destacando a importância de uma boa estratégia de manutenção. Existem três tipos de estratégias para manutenção (RANDALL, 2011):

1. **Manutenção Corretiva:** é uma das técnicas mais tradicionais, onde o equipamento funciona até apresentar a falha. Só após isso a manutenção é realizada. Possui diversas desvantagens, principalmente pelo fato que a falha pode se manifestar durante a produção e deixar a máquina parada por horas, causando grande prejuízo;
2. **Manutenção Preventiva:** é baseada em manutenções em intervalos regulares antes da falha se manifestar. Quando a frequência das falhas é conhecida, pode ser uma boa estratégia, mas possibilita a troca de componentes que ainda teriam uma sobrevida, ou ainda, a falha ocorrer antes do previsto, devido às alterações não esperadas no processo;

3. Manutenção Preditiva: quando é detectado que uma falha está próxima, antes de acontecer e com tempo ótimo para se fazer a manutenção sem afetar a produtividade e danificar mais o equipamento. Essa estratégia é baseada em um monitoramento do equipamento, permitindo acompanhar o estado de saúde da máquina. Se bem implementada esta estratégia, pode reduzir em até 65% os custos de manutenção (RANDALL, 2011);

Após apresentados os conceitos básicos sobre motores elétricos e suas falhas, e como essas falhas aumentam o nível de vibração, o próximo capítulo tem por objetivo apresentar conceitos de detecção e diagnóstico destas falhas.

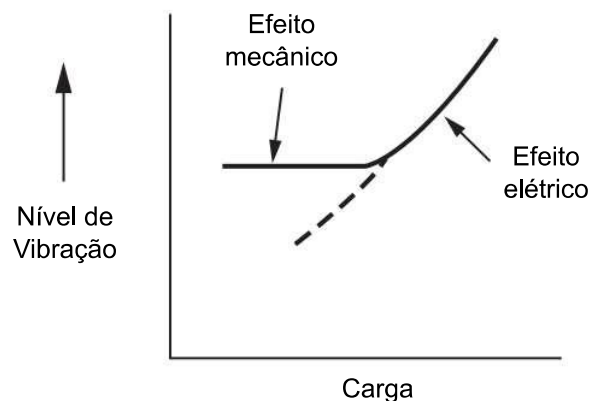
2.3 Sistemas de Detecção e Diagnóstico de Falhas

Como apresentado anteriormente, falhas em componentes de um motor elétrico, ou no sistema em que ele está inserido, podem ocasionar um aumento da vibração e alteração no espectro da corrente do motor, que serão estudados na sequência.

2.3.1 Análise de Vibração

O aumento da vibração pode ocasionar perturbações até mesmo na parte elétrica de um motor, como ilustra o gráfico que está na Figura 7. Com o aumento da carga e da vibração em conjunto, o efeito mecânico e elétrico pode ser severo Randall (2011).

Figura 7 – Ilustração da variação da carga para distinção da causa do efeito observado.



Fonte: Adaptado de Randall (2011).

Essa vibração possui uma característica específica, que depende de qual falha ela é oriunda, cria uma assinatura ao se analisar a vibração, sendo possível diagnosticar se o motor e o sistema em que ele está inserido está com boa saúde (RANDALL, 2011). Uma das primeiras técnicas para classificar o estado de saúde de uma máquina, é a norma ISO 10816-1, que

recomenda níveis de vibração em valores eficaz de acordo com o porte da máquina, que pode ser visto na Tabela 1.

Tabela 1 – Tabela de valores eficaz máximos de velocidade para cada porte de máquina indicados pela norma ISO 10816-1.

Velocidade de vibração RMS [$\frac{\text{mm}}{\text{s}}$]	Classe I	Classe II	Classe III	Classe IV
0,25	A	A	A	A
0,45	A	A	A	A
0,71	A	A	A	A
1,12	B	A	A	A
1,8	B	B	A	A
2,8	C	B	B	A
4,5	C	C	B	B
7,1	D	C	C	B
11,2	D	D	C	C
18	D	D	D	C
28	D	D	D	D
45	D	D	D	D

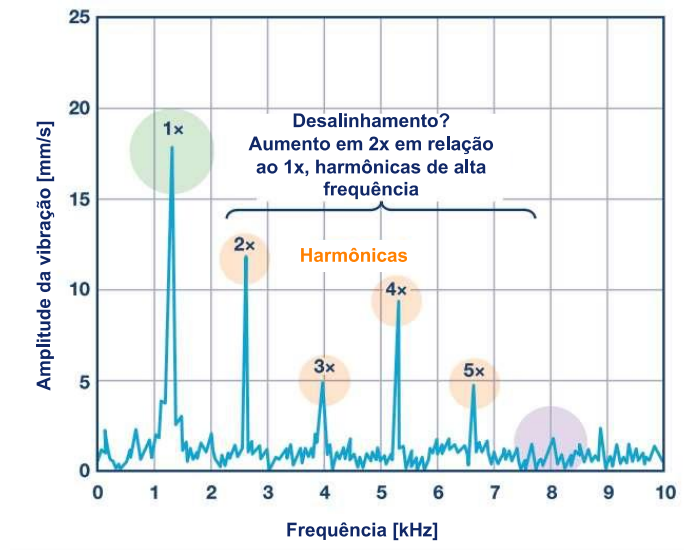
Fonte: Adaptado de Randall (2011).

onde

- A = bom estado
- B = aceitável
- C = apenas tolerável
- D = não permitido
- Classe I = pequenas máquinas (potência menor que 15kW)
- Classe II = máquinas médias sem uma fundação especial (potência entre 15kW e 75kW)
- Classe III = máquinas grandes sobre uma fundação rígida e pesada
- Classe IV = máquinas grandes sobre uma fundação flexível (turbomáquinas)

Relembrando o que foi escrito anteriormente, é possível ver as assinaturas das falhas no espectro da vibração captada por um transdutor que está acoplado no sistema. Quando uma falha de desalinhamento está presente, há um aumento de até duas vezes nas harmônicas de alta frequência, como pode ser visto na Figura 8 (SOPCIK; SULLIVAN, 2019).


Figura 8 – Indicação espectral de desalinhamento na velocidade.



Fonte: Adaptado de Sopcik e Sullivan (2019).

Já quando uma falha de desbalanceamento está presente, há um aumento na harmônica principal da velocidade, em relação ao valor de base. A Figura 9 exemplifica.

Figura 9 – Indicação espectral de desbalanceamento na velocidade.



Fonte: Adaptado de Sopcik e Sullivan (2019).

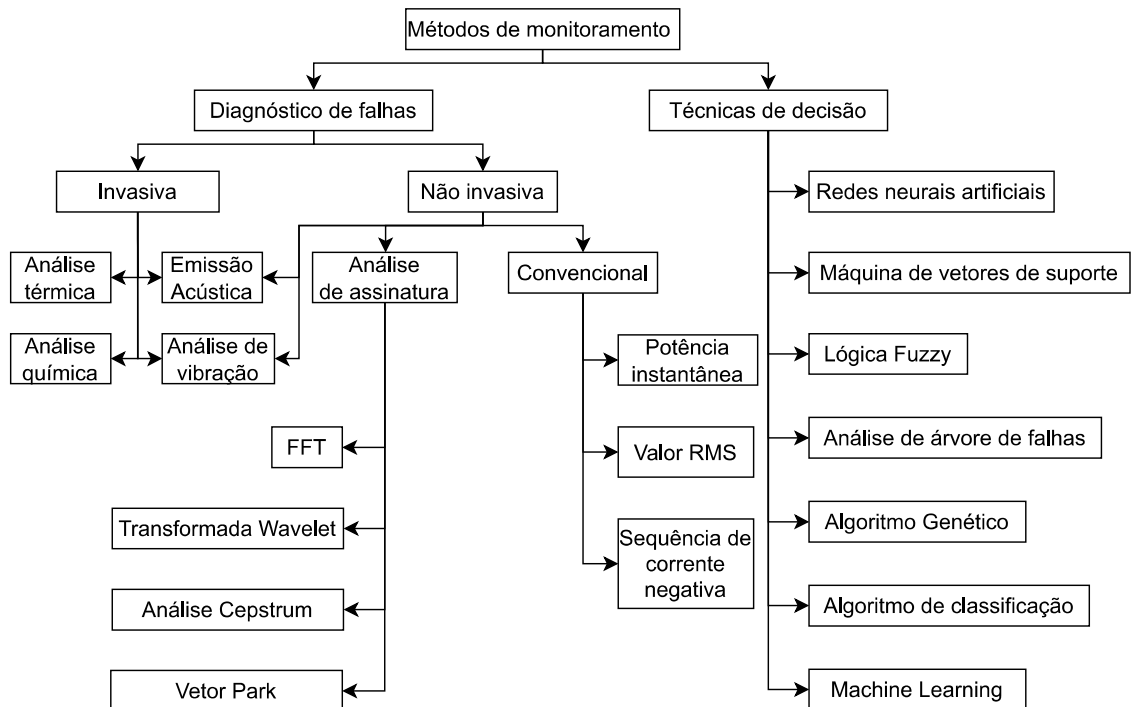
No mesmo conceito, é possível identificar a assinatura de uma falha de rolamentos conforme a categoria de rolamento, velocidade de rotação do motor, entre outras características.

Após a análise das falhas utilizando a vibração do sistema, é necessário abordar as principais técnicas de processamento de sinais.

2.4 Técnicas de Processamento de Sinais

Com o objetivo de se detectar falhas e se obter um diagnóstico das mesmas, muitas técnicas já foram implementadas. Essas técnicas podem ser não invasivas ou invasivas (GORBOUNOV; DZHIKOV, 2018). A Figura 10 apresenta algumas técnicas que são utilizadas para detecção e diagnóstico de falhas.

Figura 10 – Árvore de métodos de monitoramento de falhas em motores elétricos.



Fonte: Adaptado de Gorbounov e Dzhikov (2018).

Dentre estas, a FFT (*Fast Fourier Transform - transformada rápida de Fourier*), Valor RMS (*Root Mean Square - valor quadrático médio*) e ML (*Machine Learning - aprendizado de máquina*) serão utilizadas de forma direta ou indireta neste trabalho. FFT é um algoritmo muito eficiente que calcula a DFT (*Discrete Fourier Transform - Transformada discreta de Fourier*). Esta ferramenta é utilizada para se representar no domínio da frequência, sinais discretos que estão no domínio do tempo. Isto possibilita extrair informações do espectro desses sinais, conforme descrito na seção anterior.

Já o Valor RMS, que é a representação mais comum de se descrever a energia que um

signal $x(t)$ carrega em qualquer período (CRYER; BENDAT; PIERSOL, 2010), que pode ser representado da seguinte forma:

$$X_{RMS} = \sqrt{\frac{1}{T} \int_0^T x(t)^2 dt} \quad (1)$$

A ideia de se caracterizar a energia de um sinal através do Valor RMS (CRYER; BENDAT; PIERSOL, 2010), vem da seguinte expressão

$$E = \int_0^T [x(t)]^2 dt \quad [\text{J}] \quad (2)$$

onde E é a energia carregada pelo sinal $x(t)$ (OPPENHEIM; VERGHESE, 2016). Expandindo, se calcularmos a potência dissipada em um resistor de 1Ω num intervalo de tempo T , temos a seguinte expressão

$$P = \frac{1}{T} \int_0^T [x(t)]^2 dt \quad [\text{W}] \quad (3)$$

Se compararmos as equações 1 e 3, vemos que o valor RMS está relacionado com a raiz quadrada da potência do sinal. Ao se utilizar sinais discretos, o valor RMS pode ser representado da seguinte forma

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x^2(i)} \quad (4)$$

A última das técnicas utilizadas no presente trabalho, ML, que nasceu dentro da ciência da computação, e que veio ao encontro do reconhecimento de padrões, já este, oriundo das engenharias, para formar uma ferramenta importantíssima para as ciências, com as mais diversas aplicações. No campo do reconhecimento de padrões, a palavra-chave é a incerteza. Teoria da probabilidade é uma ferramenta matemática sólida para quantificar e manipular incertezas, formando a fundamentação para o recondicionamento de padrões. O estudo da distribuição de probabilidades em variáveis contínuas é essencial para entender a dinâmica destes dados. A distribuição de probabilidades mais conhecida é a Gaussiana, que também é chamada de distribuição normal (BISHOP, 2006). Três dos principais parâmetros para se analisar em uma distribuição normal são: média, variância e desvio padrão, onde a média de um sinal $x(t)$ num período T , pode ser calculado da seguinte forma (DINARDO *et al.*, 2018)

$$\bar{x} = \lim_{T \rightarrow \infty} \frac{1}{T^*} \int_0^T x(t) dt \quad (5)$$

Já a variância

$$\sigma^2 = \lim_{T^* \rightarrow \infty} \frac{1}{T^*} \int_0^{T^*} [x(t) - \bar{x}]^2 dt \quad (6)$$

onde σ é o desvio padrão, que representa a dispersão, em outras palavras, o quão distante os dados amostrados estão da média. Um dado amostrado que se encontra disperso, ou seja, com elevado desvio padrão, pode significar que houve um ganho ou perda de energia, se esse dado for um valor RMS, caracterizando uma anomalia. Assim que os conceitos básicos foram apresentados, podemos relacionar os trabalhos correlatos, os quais serão descritos na próxima etapa.

2.5 Estado da Arte

O estado da arte em detecção e diagnóstico de falhas em motores elétricos está no emprego de diversas técnicas numa mesma solução. A busca por estes trabalhos se deu pelas palavras chaves que envolviam: vibração e temperatura de motores elétricos, detecção de falhas em motores elétricos de indução e sistemas de monitoramento em tempo real de vibrações; Alguns destes trabalhos encontrados, utilizam técnicas clássicas, outros empregam diversas técnicas modernas para se obter o resultado ótimo. A presente seção contém alguns exemplos que empregam novos arranjos de técnicas, as quais já foram discutidas anteriormente.

A busca pela compreensão dos padrões das falhas em máquinas rotativas e não rotativas, com o foco na análise dos níveis de vibração. O artigo de Jeong *et al.* (2016) busca encontrar e entender estes padrões em orbitais gerados pela vibração conjugada entre dois eixos, o axial e o radial. A vibração é tratada no plano complexo, e imagens são geradas a partir desta representação e classificadas por uma CNN (*Convolutional Neural network* - rede neural convolucional), que apresentou erro de 1,3 % na classificação das falhas. Este foi o primeiro trabalho estudado, influenciando diretamente os primeiros meses do desenvolvimento do presente trabalho, onde a busca se deu pela detecção e classificação das falhas.

Outra forma de detecção de falhas e diagnóstico utilizando rede neural convolucional, é através do processamento dos sinais de corrente. O artigo de Ince *et al.* (2016) trata deste tema ao utilizar uma CNN unidimensional para classificar as falhas. Como o método anterior, o treinamento ocorre de forma *offline*, além de tratar os sinais de corrente, que possuem limitações na amostragem e na construção dos sensores, que precisam ser não invasivos e não influenciáveis pelos inversores de frequência, encarecendo o *hardware*, ou até limitando o uso. Os resultados foram bem satisfatórios, com acurácia de mais de 97 %, com tempo de processamento inferior a 450 ms.

Outra técnica aplicada na detecção e diagnóstico de falhas, é a transformada Wavelet, conforme a Figura 10. O artigo de Hemmati, Orfali e Gadala (2016) trata deste assunto. No artigo, características de um sinal de vibração são levantadas e comparadas, onde uma delas é o

estudo do valor RMS, tratado anteriormente na etapa de conceitos básicos. Uma das principais conclusões do trabalho é que o valor RMS é o melhor parâmetro estatístico para detectar uma falha incipiente.

Contribuindo com a tendência ao processamento de imagens para a detecção e diagnóstico de falhas, o artigo de Hatami, Gavet e Debayle (2017) trata deste tema utilizando CNN, mas com a transformação das séries temporais em imagens em duas dimensões e após isso, aplicadas em uma CNN. Estas imagens são texturizadas de acordo com as características dos sinais. Este trabalho também apresentou resultado satisfatório.

Outro trabalho importante, o artigo de Caesarendra e Tjahjowidodo (2017), é o qual realizou uma pesquisa sistemática com as principais técnicas de detecção de falhas que são estatísticas. Neste trabalho foram analisadas ferramentas como Kurtosis, Variância e valor RMS. As técnicas foram aplicadas em dados gerados em laboratório, e resultados foram elencados. Levanta a questão que o valor RMS é relevante para detectar iminentes falhas, mas limitado para se diagnosticar falhas.

A técnica ICA (*Independent Component Analysis*- análise de componentes independentes) também está muito presente nos trabalhos atuais. O artigo de Garcia-Bracamonte *et al.* (2019) utiliza essa técnica combinada com uma rede neural artificial para fazer a detecção e diagnóstico, nesta ordem, utilizando sinais de corrente. O trabalho é muito rico de análise estatística, com resultados satisfatórios, tendo um protótipo e um estudo de caso do método desenvolvido.

O uso da ferramenta FFT pura também foi listado durante as pesquisas. O trabalho de Azeem *et al.* (2019) a utiliza para detectar desalinhamento, e o estudo experimental aconteceu com o uso do mesmo modelo de simulador de falhas que foi utilizado neste trabalho, que será explicado no próximo capítulo. Ao analisar o espectro e levantar as assinaturas, os resultados deste trabalho também se mostraram satisfatórios.

Outro exemplo de trabalho importante, mesmo que não se tratando da análise de vibração de motores, e sim de transformadores, é o artigo de Zhang *et al.* (2019). Ele apresenta um *software* para monitorar em tempo real a vibração de transformadores, utilizando algumas ferramentas estatísticas e transformada Wavelet. Utilizou o *software* Labview® para a implementação da metodologia desenvolvida, obtendo os resultados esperados. A tabela 2 relaciona todos os trabalhos anteriormente discutidos.

Tabela 2 – Tabela de trabalhos correlatos.

Ano	Autores	Trabalho Realizado	Relação
2016	(JEONG <i>et al.</i> , 2016)	Detecção e classificação de falhas pela geração de orbitais	Motivação inicial e emprego de ML
2016	(INCE <i>et al.</i> , 2016)	Detecção de falhas através da análise da corrente elétrica via CNN	Estudo da viabilidade do uso da corrente elétrica
2016	(HEMMATI; ORFALI; GADALA, 2016)	Estração de assinaturas via transformada Wavelet	Estudo do valor RMS na detecção de falhas
2017	(HATAMI; GAVET; DEBAYLE, 2017)	Criação de imagens 2D texturizadas e classificadas via CNN	Alternativa para análise de falhas em sinais de vibração
2017	(CAESARENDRA; TJAHJOWIDODO, 2017)	Revisão sistemática de ferramentas estatísticas para detecção e diagnóstico de falhas	Valor RMS
2019	(GARCIA-BRACAMONTE <i>et al.</i> , 2019)	Emprego de ICA para detecção e diagnóstico através de sinais de corrente.	Estudo estatístico e criação de um protótipo
2019	(AZEEM <i>et al.</i> , 2019)	Emprego da FFT	FFT e simulador de falhas
2019	(ZHANG <i>et al.</i> , 2019)	Sistema para monitoramento em tempo real utilizando ferramentas estatísticas	Ferramentas estatísticas e <i>software</i> para monitoramento em tempo real

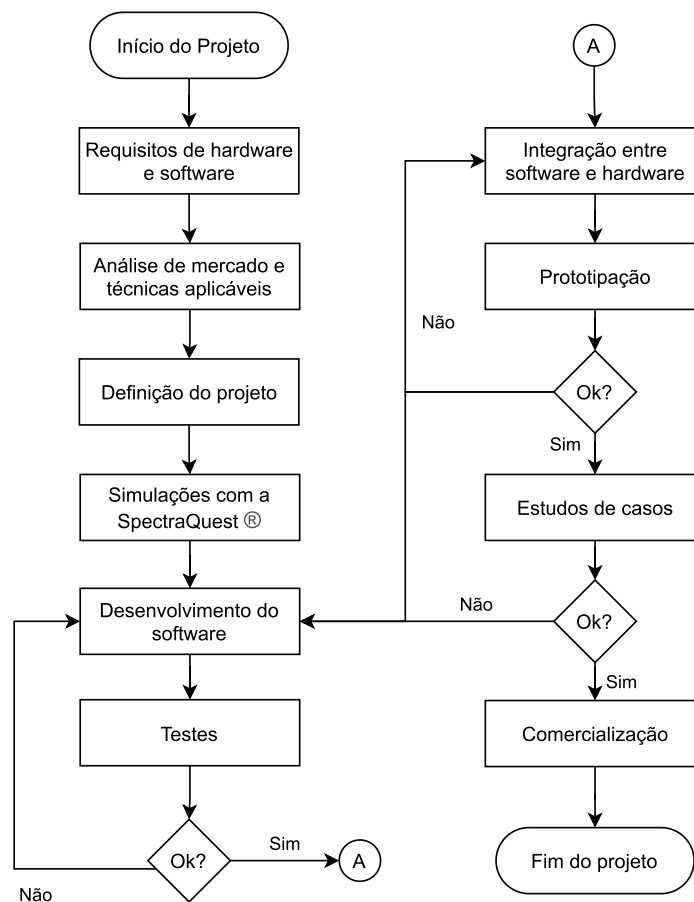
Fonte: Elaborado pelo autor.

Concluída a apresentação de trabalhos que contém alguma relação com o presente, onde características importantes e resultados foram apresentados. Visto os trabalhos correlatos, muitos empregam a mesma técnica de análise de energia dos sinais de vibração. Outros analisam o espectro, indo em busca de extrair mais informações e já realizar o diagnóstico da falha, mas apenas o último artigo que propôs uma análise em tempo real e implementou um protótipo, mas para a análise de vibração em transformadores, ao contrário do presente trabalho, que tem como foco em motores de indução e sistemas mancalizados. Com isto, prossegue-se para o próximo capítulo, etapa esta em que a proposta do atual trabalho é apresentada e implementada.

3 METODOLOGIA

O presente capítulo descreve todas as etapas do desenvolvimento do projeto, começando pela configuração do simulador de falhas MFS[®], da empresa SpectraQuest[®], até a implementação em campo. A metodologia do desenvolvimento se encontra na Figura 11, onde as etapas estão descritas em forma de fluxo de trabalho.

Figura 11 – Metodologia do Projeto




Fonte: Elaborado pelo autor.

Entre as etapas descritas na imagem anterior, a simulação, o desenvolvimento do *software*, a integração do *software* com o *hardware* e a implementação estão descritas com detalhes nos subcapítulos a seguir.

3.1 Configurações das Simulações

Como dito anteriormente no fluxo de desenvolvimento, fez-se o uso de simulações antes da implementação do sistema. Para isso, foi utilizado um simulador de falhas em motores elétricos de indução e sistemas mancalizados, denominado MFS[®] (*Machinery Fault Simulator* - simulador de falhas em máquinas), que pode ser visto na Figura 12. O simulador é composto por um motor elétrico de indução trifásico de 1 HP (*Horse Power* - Cavalos Vapor), o qual está conectado com um eixo via um acoplamento. Esse eixo possui dois discos dourados e furados, onde é possível se colocar cargas para criar um desbalanceamento no sistema.


Figura 12 – Estrutura do simulador MFS[®].



Fonte: SpectraQuest (2011).

Para a realização dos testes, diversas combinações de falhas, frequências do inversor e frequências de amostragem foram utilizadas, para se entender as dinâmicas das falhas em diferentes condições de testes. A planta possui diversos acelerômetros e um sensor de corrente, que está amostra uma das fases da alimentação. As falhas que foram inseridas nos testes foram: desalinhamento dos mancais e o desbalanceamento das cargas. Essas partes podem ser vistas na Figura 13.

Figura 13 – Desenho simplificado da Planta.



Fonte: Elaborado pelo Autor.

A Tabela 3 contém as combinações de testes que foram realizados. Onde DA é desalinhamento e DB é desbalanceamento. Cada um destes arquivos gerados possuem 9 colunas de dados, que correspondem aos 7 acelerômetros, 1 tacógrafo e um transformador de corrente.

Tabela 3 – Testes realizados.

Nome	Falha	Freq. do motor [Hz]	Amostragem [kHz]
Bom	Sem	60	25
Misa15	DA de 15 mils	60	10
Misa35_10k_20Hz	DA de 35 mils	20	25
Misa35_10k_20Hz_unb	DA de 35 mils e DB	20	25
Misa35_10k_30Hz_unb	DA de 35 mils e DB	30	25
Misa35_10k_40Hz	DA de 35 mils	40	25
Misa35_10k_5Hz	DA de 35 mils	5	25
Misa35_10k_80Hz	DA de 35 mils	80	25
Misa35_8k	DA de 35 mils	20	20

Fonte: Elaborado pelo Autor.

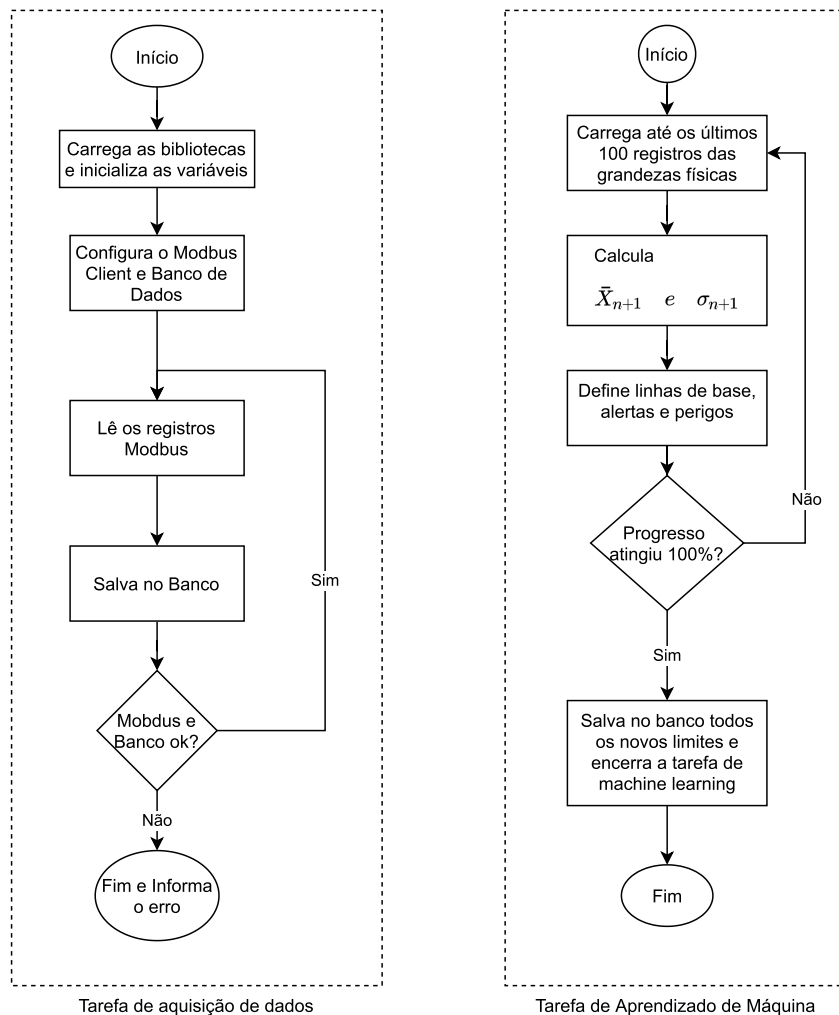
Após a apresentação de como foram realizados os testes no simulador, é possível aplicar as topologias propostas no presente trabalho nos dados gerados. Após a etapa de simulação

e análise dos dados, com os resultados obtidos, foi possível o início do desenvolvimento do *software*, que será descrito na próxima etapa.

3.2 Desenvolvimento do *software*

Com a escrita dos requisitos, simulações e análise dos dados das simulações, foi possível o início da etapa de desenvolvimento de *software*, que agrega várias ferramentas para entregar um sistema de tempo real para o monitoramento da saúde de motores elétricos de indução. A implementação foi dividida em três principais tarefas: aquisição dos dados, ML e o monitoramento. As duas primeiras estão descritas na imagem a seguir.

Figura 14 – Tarefas de Aquisição e ML



Fonte: Elaborado pelo autor.

Na tarefa de aquisição de dados, a qual foi desenvolvida utilizando a linguagem de

programação Python, o protocolo de comunicação utilizado foi o Modbus, muito comum na indústria e de fácil utilização, principalmente porque a leitura é feita de forma periódica e com um intervalo de até 5 min entre cada uma, que é um dos conceitos básicos do protocolo. O banco de dados utilizado é o InfluxDB, um banco de dados não relacional para armazenamento de séries temporais, que também é uma característica dos dados amostrados. Já na tarefa de aprendizado de máquina, ela manipula banco de dados e variáveis de ambiente da aplicação para encontrar as linhas de base e os limiares de alerta e perigo, basicamente encontrando a seguinte relação:

$$\bar{X}_{n+1} = \bar{X}_n + \frac{x - \bar{X}_n}{n} \quad (7)$$

onde \bar{X}_{n+1} é a média aritmética para os $n + 1$ elementos, \bar{X}_n é a média aritmética anterior, x é o novo dado adquirido. Já a relação da variância, pode ser calculada da seguinte forma:

$$var_{n+1} = var_n + (x - \bar{X}_{n+1})(x - \bar{X}_n) \quad (8)$$

E por fim, o desvio padrão σ_{n+1} para um novo elemento:

$$\sigma_{n+1} = \sqrt{\frac{var_{n+1}}{n}} \quad (9)$$

Assumimos que a região de alerta (A), a qual significa uma moderada tendência à falha, pode ser calculada da seguinte forma:

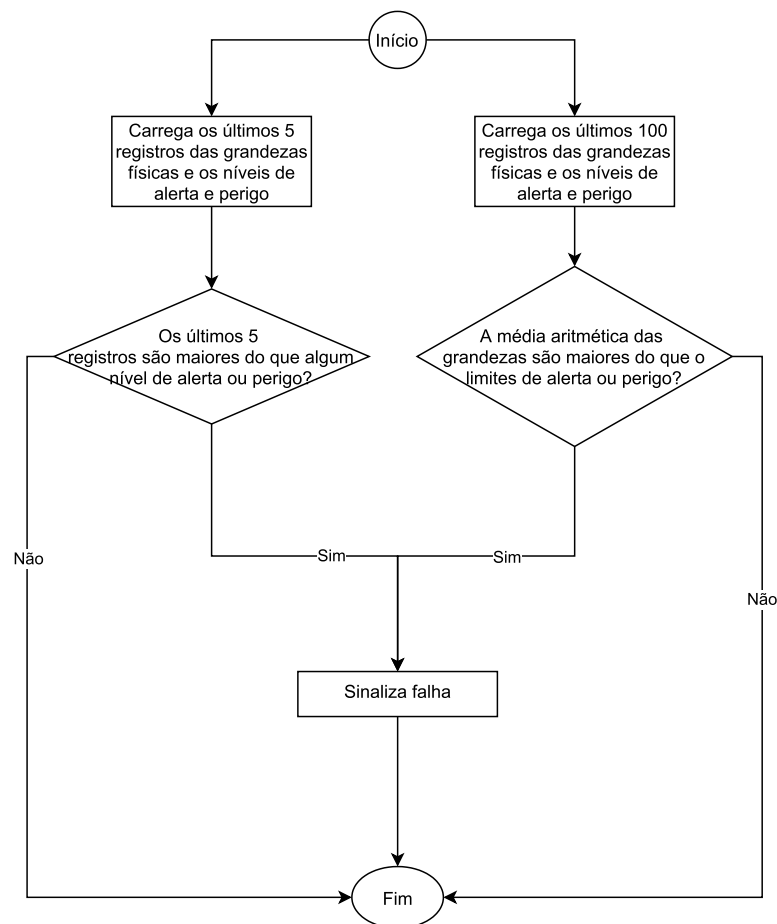
$$A = \bar{X}_{n+1} + \alpha \sigma_{n+1} \quad (10)$$

onde α é um coeficiente ajustável. Segundo a mesma regra, a região onde há uma falha iminente (Pe), um comportamento ambiental ou regime de funcionamento atípico, pode ser calculado da seguinte forma:

$$Pe = \bar{X}_{n+1} + \beta \sigma_{n+1} \quad (11)$$

onde β é outro coeficiente ajustável, que deve ser necessariamente maior do que α . Por resultados empíricos, o uso de 2 para α e 3 para β , se mostraram valores aceitáveis para motores e máquinas em perfeitas condições, necessitando de ajuste manual se já se encontravam em uso por um longo período. Após os valores das linhas de base, alerta e perigo, a aplicação pode ficar encarregada de monitorar os novos dados e aplicar um conjunto de regras para classificar se o motor elétrico de indução tem um comportamento normal. O fluxograma da sequência descreve tal tarefa.

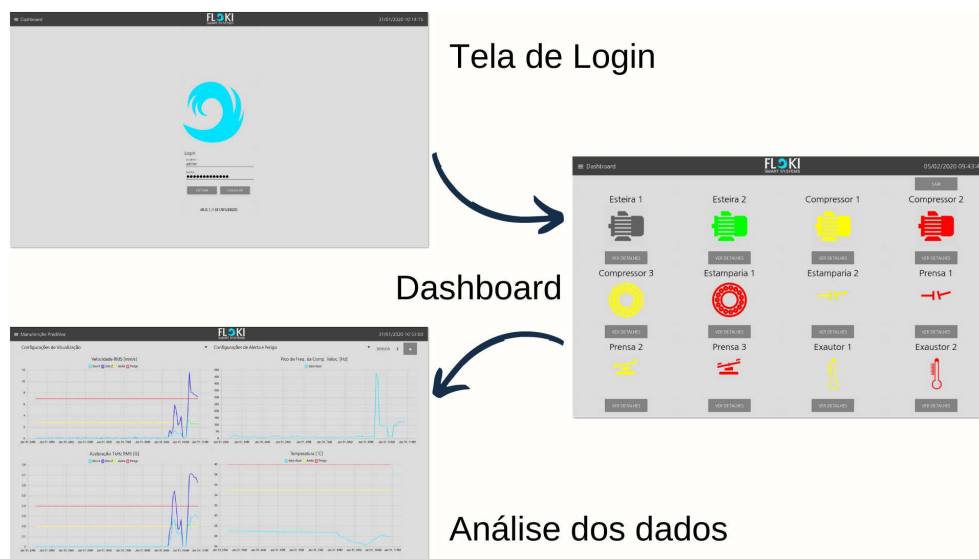
Figura 15 – Tarefa de monitoramento



Fonte: Elaborado pelo autor.

Os critérios elencados para se decidir sinalizar uma tendência de falhas, como podem ser vistos no fluxograma anterior, podem ser divididos em duas partes. A primeira regra empírica, para evitar que dados anômalos ou alguma vibração atípica interfira no sistema, somente se 5 amostras apresentarem valores maiores ou iguais aos limites um sinal de alerta, ou perigo, um sinal será gerado. No segundo caso, se a média dos últimos 100 elementos for maior, eliminando os casos em que o motor pode ter um regime não contínuo dentro das 5 amostras, tendo apenas 4 ou menos amostras com valores excedentes.

Para uma interface entre homem e máquina, fez-se o uso da ferramenta Node-Red[®] para prototipar a presente aplicação. A imagem da sequência mostra a estrutura básica das telas do *software*, que é uma ferramenta baseada em web que pode ser acessada por qualquer dispositivo com navegador web que esteja na rede.

Figura 16 – Fluxo de acesso do *software*.

Fonte: Elaborado pelo autor.

Como é possível perceber, a aplicação possui uma tela de *login* que protege o acesso ao *dashboard* principal, que contém imagens que facilitam a identificação visual de algum problema com o motor ou com o sistema de aquisição de dados. Ao se selecionar um dos motores, a aplicação é redirecionada para uma tela que contém um grupo de gráfico e configurações. A aplicação também permite a configuração manual dos limites de alerta e perigo. As principais informações que podem ser vistas nesta tela são:

- Configurações de visualização: campos para selecionar se o gráfico será em tempo real, ou os dados serão exibidos dentro de um intervalo, além de permitir selecionar qual eixo se deseja visualizar;
- Configurações de Alerta e Perigo: possui o botão para ativação e desativação do ML, além dos campos para se editar os valores de alerta e perigo, conforme desejo do usuário;
- Gráfico de Velocidade RMS em $\frac{mm}{s}$, que contém: reta da linha de base em azul-escuro, dados de velocidade amostrados em azul-claro, linha da alerta em amarelo, e por fim, linha de perigo em vermelho;
- Gráfico de Pico de frequência da velocidade em Hz, que contém: dados do pico de frequência da velocidade amostrados em azul-claro;
- Gráfico de Velocidade RMS em $\frac{mm}{s}$, que contém: reta da linha de base em azul-escuro, dados de velocidade amostrados em azul-claro, linha da alerta em amarelo, e por fim, linha de perigo em vermelho;

- Gráfico de Temperatura em °C, que contém: reta da linha de base em azul-escuro, dados de temperatura amostrados em azul-claro, linha da alerta em amarelo, e por fim, linha de perigo em vermelho;

Após a conclusão e aprovação do *software*, foi possível executar a integração entre *hardware* e *software*, para finalizar o desenvolvimento. Esta etapa está descrita na sequência.

3.3 Integração entre *Software* e *Hardware*

Para a aquisição das grandezas físicas, as quais alimentam a aplicação de *software*, foi selecionado o sensor de vibração e temperatura QM30VT2, da Banner Engineering, que possui as seguintes características:

Tabela 4 – Especificações do Sensor QM30VT2

Especificação	Valores
Intervalo de medição	0 a 46 $\frac{\text{mm}}{\text{s}}$
Largura de banda	10 a 4 kHz
Acurácia	$\pm 10\%$ a 25 °C
Amostragem	20 kHz
Tempo de Amostragem	0,4 s
Grau de Certificação	IP67

Fonte: Elaborado pelo Autor.

Como é possível ver, ele possui uma largura de banda de até 4 kHz, adequado até para detecção de falhas em rolamentos, como descrito no referencial teórico. Os dados são adquiridos via Modbus RTU (*Remote Terminal Unit* - Unidade de terminal remoto) diretamente do sensor, ou ainda, via Modbus TCP (*Transmission Control Protocol* - Protocolo de Controle de Transmissão) a partir de um *gateway wireless* e um nó, facilitando a implantação por não utilizar cabos entre os sensores e a unidade de processamento. O diagrama da Figura a seguir representa o fluxo básico dos sinais, indo do sensor até o sistema embarcado, o qual processa, armazena e disponibiliza a visualização em tempo real dos dados.

Figura 17 – Diagrama de integração entre sensores e *software*.

Fonte: Adaptado pelo autor.

O sistema embarcado, o qual é a unidade de processamento da aplicação, é composto por uma Raspberry Pi 3 Modelo B+, que é um dispositivo muito utilizado e confiável, executando uma distribuição Linux baseada em Debian. Após o desenvolvimento de *software*, da integração com o *hardware*, prototipação, o projeto foi executado em campo, em forma de estudo de caso, em uma empresa da região metropolitana de Porto Alegre - RS, seguindo o fluxograma da Figura 11, que será descrito na próxima etapa.

3.4 Estudo de Caso

Como descrito no fluxograma do projeto, a etapa final do desenvolvimento é a de testes em campo, em forma de estudo de caso, com o objetivo de analisar a robustez do produto, da comunicação entre o sensor e a unidade de processamento e da confiabilidade da aplicação de *software*. Para aplicar a solução, foram escolhidos equipamentos reais e funcionais, que operam 24 horas, 7 dias por semana em empresas parceiras, com o objetivo de prova de conceito e posterior aquisição pelas mesmas. Para isto, um exaustor industrial foi escolhido em uma delas, que é uma montadora da região metropolitana de Porto Alegre - RS. A Figura 18 representa um exaustor industrial, um dispositivo que com o decorrer do uso, apresenta severas falhas com o acúmulo de partículas que estão suspensas no ar. Uma falha num dispositivo como este, acarreta uma parada de produção, impactando diretamente no financeiro da empresa, justificando facilmente o investimento da tecnologia desenvolvida neste trabalho.

Figura 18 – Fotografia externa de um exaustor industrial.



Fonte: Fornecida pela empresa.

Em um destes dispositivos, foi instalado um sensor industrial de vibração e temperatura, com o objetivo de coletar, processar e armazenar os dados, criando um *dashboard* com o estado de saúde do motor elétrico de indução. A Figura 19 apresenta o sensor instalado. O motor já se encontrava em uso há algum tempo antes dos testes em campo, significando que já existe uma base de vibração maior do que se fosse um motor há pouco reconicionado, exigindo um ajuste manual na ferramenta de ML, reduzindo os limites criados pelo *software*, que consideram que o motor está em perfeito estado de saúde para começar a criação dos limites. Já estava previsto na etapa de análise de mercado, a possibilidade de se ajustar os resultados do ML, devido a grande frequência de instalações em motores que possuem médio ou elevado MTBF (*Mean Time Between Failures* - tempo médio entre falhas), mas que ainda oferecem prejuízos se a falha ocorrer de forma imprevista.

Figura 19 – Fotografia externa do sensor instalado em um exaustor industrial.



Fonte: Fornecida pela empresa.

Como pode ser visto na figura anterior, o sensor está fixo de forma magnética na carcaça do motor, facilitando a instalação do mesmo. Já as características dos testes, que podem ser vistas na Tabela 5,

Tabela 5 – Características da prova de conceito no exaustor

Característica	Valores
Tempo entre cada amostragem	5 min
Número de sensores	1
Potência do motor	22,065 kW
Classe do motor segundo a ISO 10816-1	II

Fonte: Elaborado pelo Autor.

Já na outra empresa, que é uma produtora de tabaco e seus derivados, também no estado do Rio grande do sul, o sistema foi instalado em uma seleira universal, não especificamente em um motor elétrico de indução, mas em 5 pontos estratégicos, distribuindo os 5 sensores nos principais pontos de falhas: acoplamentos, moto-redutores e nas proximidades de polias. Esta seleira universal tem um papel muito importante na produção, sendo um dos gargalos da produção. Qualquer falha imprevista, também impacta na produção diária, distorcendo toda a produção. A Tabela 6 apresenta as características da prova de conceito na seleira universal.

Tabela 6 – Características da prova de conceito na seleira universal

Característica	Valores
Tempo entre cada amostragem	30s
Número de sensores	5
Potência do motor	1,1185 kW
Classe do motor segundo a ISO 10816-1	I

Fonte: Elaborado pelo Autor.

É perceptível que a amostragem e o número de sensores são as principais diferenças. A amostragem com 10 vezes mais elementos, foi uma exigência da empresa, além do mais, o equipamento tem variações de ciclos, não sendo um processo contínuo, inviabilizando amostras com intervalo de 5 min. Imagens da instalação dos sensores, e nem da máquina, foram liberadas pela empresa, mas os resultados foram disponibilizados na íntegra.

Após a descrição de toda a metodologia do presente trabalho, iniciando pela estrutura básica da metodologia, das simulações, do desenvolvimento do *software*, da integração de *software* e *hardware*, e por fim, a instalação do protótipo nas empresas parceiras, para a prova de conceito, podemos apresentar os resultados, que se encontram no próximo capítulo.

4 ANÁLISE DE RESULTADOS

Neste capítulo são apresentados os resultados do projeto, os quais são os produtos do estudo de caso desenvolvido nas empresas parceiras. Como se trata de um estudo de caso, e para as empresas, uma prova de conceito, os resultados também foram divididos por equipamento avaliado: exaustor e seleira universal. Os resultados, inicialmente são apresentados e forma de capturas de telas do *software* na parte de análise dos sinais coletados, para fim de dar uma visão global do estado de saúde do equipamento no dado momento. Na sequência, gráficos específicos, levantando características e comparações em diferentes condições, mostrando a relação de causa e efeito. Por fim, apontamentos e discussões sobre os resultados de cada um dos elementos, e também comparações entre os mesmos.

Figura 20 – Captura de tela do sistema instalado no exaustor.

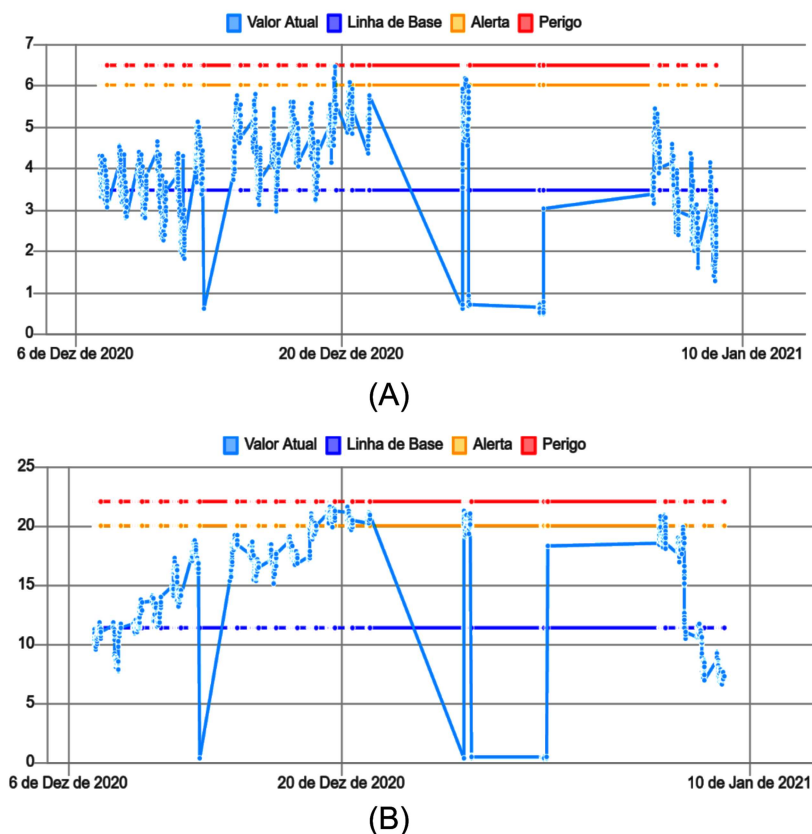


Fonte: Elaborado pelo Autor.

Para a apresentação dos resultados do exaustor, foram feitas capturas de tela do *software* do sistema que estava instalado no motor, de forma remota e supervisionada pelos responsáveis dos serviços de manutenção dos mesmos. A Figura 20 é a captura de tela do sistema no dia em que um relatório sobre a saúde dos exaustores foi gerado, com os dados daquele momento, e com os limites gerados pelo ML no momento da instalação (06/12/2020).

A captura de tela está com os dados de velocidade e aceleração do eixo Z, como pode ser observado. Fica claro que as grandezas físicas ultrapassam os limites estabelecidos pelo ML, somente no estado de alerta, mas isso não significa que o motor esteja em bom estado. Se consultarmos a tabela 1, veremos que os valores para um motor de Classe II, segundo norma ISO 10816-1, está entre apenas tolerável e não permitido, dependendo do regime de funcionamento. Se olharmos o eixo z, que se encontra na Figura 21, os valores não permitidos, deixando claro o risco de falha iminente do motor.

Figura 21 – Velocidade RMS [$\frac{\text{mm}}{\text{s}}$] coletados do eixo x (A) e z (B).

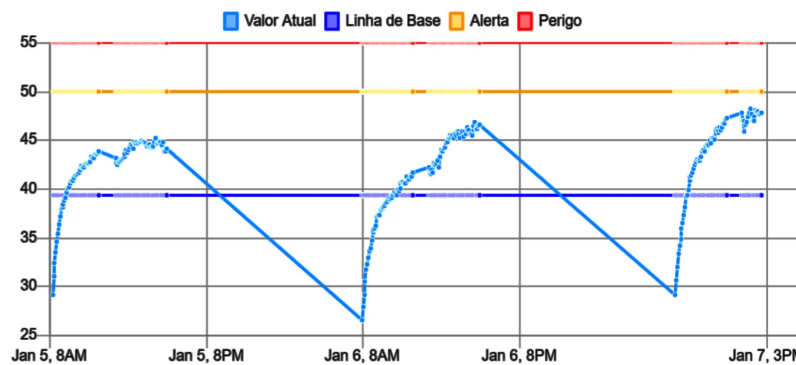


Fonte: Elaborado pelo Autor.

O eixo z se encontra em estado severo de vibração, não entrando em alarme devido ao ML tardio executado pelo operador, sendo agora uma tarefa de gerenciamento do sistema, de se executar da maneira mais adequada, que é logo após o recondicionamento ou ajustar

manualmente os limites de acordo com a norma ISO 10816-1. Outra característica importante é a temperatura, que pode ser vista na Figura 22, que teve uma dinâmica com característica de um sistema linear de primeira ordem.

Figura 22 – Temperatura em °C amostrada no exaustor.



Fonte: Elaborado pelo Autor.

Fica nítido também o processo de aquecimento do dispositivo, seguindo os ciclos de funcionamento, que são bem regulares. O estudo de caso do exaustor se mostrou um ótimo caso para se analisar o comportamento do sistema em um dispositivo que já estava em funcionamento por um bom tempo após o recondicionamento, onde a técnica de ML, como esperado, não contribuiu com o objetivo de se detectar falhas, pois as condições iniciais não eram as ideais e os limites ficaram além dos permitidos pela norma ISO 10816-1. Mas o funcionamento geral da ferramenta foi satisfatório, sem nenhum problema grave reportado, funcionando nas especificações e dentro do esperado pela empresa parceira. Um relatório foi gerado e entregue para a empresa, contendo todos os dados e explicações, sendo aceito e o desejo de instalar em mais equipamentos, foi sinalizado.

A segunda prova de conceito foi realizada em uma seleira universal, como descrito anteriormente, onde 5 sensores foram distribuídos pela máquina, com o objetivo de monitorar os pontos críticos. Como no caso do exaustor, foram realizadas capturas de telas do sistema, onde a Figura 23 representa a captura dos dados do sensor 5, 4 dias antes de uma falha (08/12/2020).


Figura 23 – Linhas de base e sinais coletados em um dos 5 sensores na seleira universal.



Fonte: Elaborado pelo Autor.

Esta máquina não apresenta um processo contínuo como o exaustor, exigindo uma amostragem maior para se captar todas as características do funcionamento. Estes sensores foram instalados no dia 13/11/2020, mas os dados começaram a ser coletados apenas no dia 16/11/2020, onde a ferramenta de ML foi usada e os limites foram criados. A ferramenta foi aplicada em todos os 5 sensores, instalados em acoplamentos próximo de polias e moto-redutores. Cada um destes monitorou um comportamento diferente, mas o sensor mais importante se mostrou ser o 5, onde os resultados foram mais nítidos. Os outros sensores, pelo menos mais 3 apresentaram comportamento anômalo, mas nenhum como este. A Figura 24 apresenta uma comparação dos dados de velocidade logo após a instalação, com os dados na iminência de uma falha.

Figura 24 – Linhas de base e dados de velocidade [$\frac{mm}{s}$] no momento da instalação (A) x próximo da falha (B).




Fonte: Elaborado pelo Autor.

Como pode ser observado, os dados coletados na iminência da falha ultrapassam os limites de alerta e perigo, mesmo que não continuamente, mas como a regra estabelecida na metodologia, da existência de 5 picos ou média acima dos limites, caracterizando uma alerta. Como são muitos dados, um a cada 30s, a visualização das retas de limites ficou comprometida, e só é possível ver pela parte da tela onde se edita os valores, ou pelos pontos azuis-escuros, amarelos e vermelhos no lado direito do gráfico. Além disso, é possível notar que no início do processo, o sistema já se encontrava em uma situação pouco tolerável, segundo a norma ISO 10816-1, justificável por estarem instalados em partes que normalmente vibram mais, justamente por possuírem muitos elementos mecânicos e partes móveis. Por fim, a seleira universal apresentou o rompimento de uma correia alguns dias após estes dados serem coletados e visualmente alertar uma condição severa de falha, consolidando o uso da ferramenta em mais um equipamento, independente de ser um motor ou outro sistema mecânico. A aplicação funcionou perfeitamente, similar ao estudo de caso do exaustor, apresentando apenas uma falha de salvar repetidas vezes os limites, que foi resolvida remotamente e incorporada ao *software* do projeto. Uma peculiaridade de um sistema mancalizado, que difere de uma instalação em um

motor elétrico de indução, é o comportamento da temperatura, que pode ser visto na Figura 25. Ela tem um perfil mais discreto, e não seguindo um sistema de primeira ordem, por não estar próximo de uma significativa fonte de calor, por isso os limites gerados para algo com pouca variância, são limites muito próximos dos dados amostrados, ocorrendo falsos positivos apenas com a variação da temperatura ambiente. A solução para isso, já prevista no início do projeto, é a possibilidade do operador alterar os limites, de acordo com a dinâmica que o sistema está inserido, não cabendo utilizar ML onde há pouca variância ou o equipamento já se encontra em severo desgaste.

Figura 25 – Temperatura [°C] amostrada na seleira universal.



Fonte: Elaborado pelo Autor.

Após a escrita de todo o trabalho, indo desde o conhecimento mínimo para o entendimento das propostas, passando pela descrição dos métodos empregados, até a análise dos resultados, foi possível ver o funcionamento satisfatório do projeto. O próximo capítulo apresenta as conclusões gerais do projeto, além de sugestões para trabalhos futuros.

5 CONCLUSÃO

A aplicação do protótipo em campo, no estudo de caso, mostrou como é diversificada a indústria em que estamos inseridos. A necessidade de diferentes amostragens, configuração manual dos limites de alerta e perigo, e diferentes regimes de funcionamento dos equipamentos, também evidencia quão flexível a ferramenta desenvolvida necessita ser para atender estes cenários. O emprego de ferramentas de rápida prototipação, como o uso de Node-Red, Raspberry Pi e um sistema de coleta de dados robusto e consolidado no mercado, possibilitou essa flexibilidade ao presente projeto, que saiu de uma ideia até um produto que já está sendo comercializado.

Na análise dos resultados, que foi realizada no capítulo 4, percebe-se a aplicabilidade via a análise dos estudos de casos. O sistema foi capaz de monitorar, armazenar e de alarmar um estado crítico, na iminência de uma falha em um dos estudos. Já no outro, que se trata do exaustor, o sistema foi instalado tardiamente, cabendo apenas avaliar segundo a norma ISO 10816-1. Outra característica importante, é a utilização da ferramenta de ML, que se mostrou muito eficaz em criar linhas de alarme e perigo, quando o sistema é instalado em um dispositivo que há pouco passou por manutenção, e no uso para grandezas com variância considerável. Já nos cenários em que ela não obteve bons resultados: máquinas que já estão há tempo funcionando sem manutenção e grandezas com pouca variância, ficando a cargo do usuário avaliar se o uso do ML se aplica ou não. Pelo caráter inovador desta solução, o trabalho também gerou um registro de software que no momento da publicação deste documento, se encontra em andamento.

Trabalhos futuros a partir desse devem ser desenvolvidos, principalmente na adição de parâmetros de entrada, que utilizem a norma ISO 10816-1 por padrão. Tornar o *software* escalável e executável remotamente, para garantir que os dados não serão comprometidos. Analisar estudos de casos de mais máquinas e motores, melhorando o modelo da aplicação. Por fim, trabalhar no desenvolvimento de técnicas de diagnóstico de falhas, agregando valor ao sistema.

REFERÊNCIAS BIBLIOGRÁFICAS

- AZEEM, N. *et al.* Experimental condition monitoring for the detection of misaligned and cracked shafts by order analysis. *Advances in Mechanical Engineering*, v. 11, n. 5, p. 1–11, 2019. ISSN 16878140. Citado 2 vezes nas páginas 26 e 27.
- BISHOP, C. M. *Information Science and Statistics*. [S.l.: s.n.], 2006. 3–9 p. ISBN 9780387310732. Citado na página 24.
- CAESARENDRA, W.; TJAHJOWIDODO, T. A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, v. 5, n. 4, 2017. ISSN 20751702. Citado 2 vezes nas páginas 26 e 27.
- CRYER, J. D.; BENDAT, J. S.; PIERSOL, A. G. *Random Data*. [S.l.: s.n.], 2010. v. 82. 1197 p. ISSN 01621459. ISBN 9780470248775. Citado na página 24.
- DINARDO, G. *et al.* Vibrational signal processing for characterization of fluid flows in pipes. *Measurement*, Elsevier Ltd, v. 113, 2018. Citado na página 24.
- GARCIA-BRACAMONTE, J. E. *et al.* An Approach on MCSA-Based Fault Detection Using Independent Component Analysis and Neural Networks. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 68, n. 5, p. 1353–1361, 2019. Citado 2 vezes nas páginas 26 e 27.
- GORBOUNOV, Y.; DZHIKOV, T. Low Cost Data Acquisition System for Condition Assessment of Electric Motors. *Iarjset*, v. 5, n. 10, p. 76–82, 2018. Citado 4 vezes nas páginas 17, 18, 19 e 23.
- HATAMI, N.; GAVET, Y.; DEBAYLE, J. Classification of Time-Series Images Using Deep Convolutional Neural Networks. 2017. Disponível em: <<https://hal.archives-ouvertes.fr/hal-01743695>>. Citado 2 vezes nas páginas 26 e 27.
- HEMMATI, F.; ORFALI, W.; GADALA, M. S. Roller bearing acoustic signature extraction by wavelet packet transform, applications in fault detection and size estimation. *Applied Acoustics*, Elsevier Ltd, v. 104, p. 101–118, mar 2016. ISSN 1872910X. Citado 2 vezes nas páginas 25 e 27.
- INCE, T. *et al.* Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks. *IEEE Transactions on Industrial Electronics*, Institute of Electrical and Electronics Engineers Inc., v. 63, n. 11, p. 7067–7075, nov 2016. Citado 2 vezes nas páginas 25 e 27.
- JEONG, H. *et al.* Deep learning based diagnostics of orbit patterns in rotating machinery. *Proceedings of the Annual Conference of the Prognostics and Health Management Society, PHM*, v. 2016-Octob, p. 390–396, 2016. Citado 2 vezes nas páginas 25 e 27.
- OPPENHEIM, A. V.; VERGHESE, G. C. *Signals, Systems & Inference*. [S.l.: s.n.], 2016. 604 p. ISBN 9780133943283. Citado na página 24.
- PETRUZELLA, F. D. *Electric Motors and control systems*. [S.l.: s.n.], 2016. v. 33. 820–821 p. Citado na página 15.

RANDALL, R. B. *Vibration-based Condition Monitoring*. [S.l.: s.n.], 2011. v. 11. 431–477 p. Citado 4 vezes nas páginas 13, 19, 20 e 21.

SOPCIK, B. P.; SULLIVAN, D. O. How Sensor Performance Enables Condition-Based Monitoring Solutions. n. June, p. 1–5, 2019. Citado 4 vezes nas páginas 18, 19, 21 e 22.

SPECTRAQUEST, I. Machinery Fault Simulator. Package, p. 4–8, 2011. Citado na página 29.

UMANS, S. *Fitzgerald and Kingsley's Electric machinery*. [S.l.: s.n.], 2014. v. 319. 457 p. Citado 3 vezes nas páginas 13, 15 e 16.

ZHANG, Z. *et al.* Online monitoring research of transformer vibration based on labview. In: *Journal of Physics: Conference Series*. [S.l.: s.n.], 2019. v. 1168, n. 2. ISSN 17426596. Citado 2 vezes nas páginas 26 e 27.