

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

GUSTAVO VENDRAME BARBARA

**UM ESTUDO SOBRE MULTISSENSORIAMENTO NO DIAGNÓSTICO
DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS**

DISSERTAÇÃO

CORNÉLIO PROCÓPIO

2023

GUSTAVO VENDRAME BARBARA

**UM ESTUDO SOBRE MULTISSENSORIAMENTO NO
DIAGNÓSTICO DE FALHAS EM MOTORES DE INDUÇÃO
TRIFÁSICOS**

**A STUDY ON MULTISENSING IN THE FAULT DIAGNOSIS OF
THREE-PHASE INDUCTION MOTORS**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de Concentração: Sistemas Eletrônicos Industriais.

Orientador: Prof. Dr. Alessandro Goedel

Coorientador: Prof. Dr. Marcelo Favoretto Castoldi

CORNÉLIO PROCÓPIO

2023



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Esta licença permite *download* e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais.

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



GUSTAVO VENDRAME BARBARA

**UM ESTUDO SOBRE MULTISSENSORIAMENTO NO DIAGNÓSTICO DE FALHAS EM MOTORES DE
INDUÇÃO TRIFÁSICOS**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas Eletrônicos Industriais.

Data de aprovação: 26 de Maio de 2023

Dr. Alessandro Goedel, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Andre Sanches Fonseca Sobrinho, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Bruno Albuquerque De Castro, Doutorado - Universidade Estadual Paulista - Unesp

Dr. Paulo Rogerio Scalassara, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Wesley Angelino De Souza, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 26/05/2023.

Dedico este trabalho à minha esposa
Luana e a meus pais Antonio e Vilma.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus, sem ele nada seria possível, tenho certeza que em todos os momentos Ele estava e sempre estará ao meu lado.

Aos meus pais, Antonio de Rezende Barbara e Vilma Vendrame Barbara, por sempre estarem ao meu lado nos momentos que eu mais preciso, sempre me apoiarem nas minhas escolhas e por sempre me motivarem durante todo o tempo na realização deste trabalho.

À minha esposa, Luana Gabriela Faustino, por ser a primeira pessoa a ter me incentivado a me candidatar a uma vaga no programa de mestrado, por sempre estar ao meu lado me animando e me apoiando, e também por entender que em alguns momentos tive que estar um pouco ausente para que este trabalho de mestrado pudesse ser realizado.

Aos três professores que me auxiliaram na realização deste trabalho, profissionais que sempre terei como modelo em minha trajetória. Primeiramente, meu orientador Professor Dr. Alessandro Goedel, por todos os ensinamentos que me passou nessa jornada, por suas sugestões e conselhos que permitiram que esse trabalho se tornasse melhor. Meu coorientador Professor Dr. Marcelo Favoretto Castoldi por suas sugestões, ajuda e todo o suporte dado para que este trabalho pudesse ser realizado. E Professor Dr. Wesley Angelino de Souza, por todo auxílio na realização do trabalho, desde as etapas iniciais, até a etapa final, e também por sempre me incentivar em todos os momentos da realização deste trabalho.

Aos meus amigos que trabalharam comigo no Laboratório de Sistemas Inteligentes, em especial aos futuros doutores Avyner Lorrain de Oliveira Vitor e Yuri Piccolo Bornea pelo auxílio na realização dos ensaios para a construção do banco de dados realizado neste trabalho, e ao Mestre Ailton de Oliveira Louzada por também auxiliar na construção do banco de dados, bem como ter construído o sensor de fluxo de dispersão, e além disso compartilhar todo o seu conhecimento para que o banco de dados pudesse ser construído utilizando as técnicas corretas.

A todos os amigos e professores que me auxiliaram diretamente ou indiretamente na realização deste trabalho de mestrado.

A Universidade Tecnológica Federal do Paraná e ao Programa de Pós-

Graduação em Engenharia Elétrica pela disponibilização da estrutura necessária a realização deste trabalho.

Ao Instituto Federal do Paraná por permitir que parte de minha carga horária de trabalho pudesse ser utilizada para a realização desta pesquisa de mestrado.

"Prefiram a minha instrução à prata, e o conhecimento ao ouro puro, pois a sabedoria é mais preciosa do que rubis; nada do que vocês possam desejar compara-se a ela."(Provérbios 8:10-11)

RESUMO

BARBARA, Gustavo Vendrame. **UM ESTUDO SOBRE MULTISSENSORIAMENTO NO DIAGNÓSTICO DE FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS**. 2023. 170 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2023.

Os motores de indução trifásicos são as máquinas elétricas mais utilizadas no setor industrial por possuírem características tanto construtivas quanto econômicas que tornam sua utilização vantajosa. Observa-se que a manutenção preditiva tem papel de destaque nas rotinas de manutenção industrial. Assim, o diagnóstico de falhas em motores de indução trifásicos, bem como a classificação dessas falhas é uma área de estudo ampla e que envolve o estudo dos tipos de falhas, dos sensores, da aplicação de técnicas de processamento de sinais e classificação de padrões dos dados. Diante da grande relevância do tema relacionado às falhas de máquinas elétricas, esse trabalho cria de um banco de dados de falhas em motores de indução trifásico a partir de dados de sensores de corrente, vibração, áudio, tensão, fluxo de dispersão, torque e velocidade. Ainda, realiza-se um estudo que permite a validação dos dados coletados, verificando se os mesmos possuem as características para serem utilizados na identificação e classificação de falhas em motores elétricos. Observou-se que todos os sensores utilizados podem apresentar informações úteis para a identificação e classificação de falhas em motores elétricos, e que existem atributos selecionados em comum entre os dois motores utilizados neste trabalho. O banco de dados criado será uma importante ferramenta para o desenvolvimento de estudos relacionados à falhas em máquinas elétricas.

Palavras-chave: Motores elétricos de indução. multissensoriamento. banco de dados. seleção de atributos.

ABSTRACT

BARBARA, Gustavo Vendrame. **A STUDY ON MULTISENSING IN THE FAULT DIAGNOSIS OF THREE-PHASE INDUCTION MOTORS**. 2023. 170 p. Dissertation (Master's Degree in Electrical Engineering) – Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2023.

Three-phase induction motors are the most used electrical machines in the industrial sector because they have both constructive and economic characteristics that make their use advantageous. It is observed that predictive maintenance plays a prominent role in industrial maintenance routines. Thus, the diagnosis of faults in three-phase induction motors, as well as the classification of these faults, is a broad area of study that involves the study of the types of faults, the sensors, the application of signal processing techniques and classification of patterns of the data. Given the great relevance of the topic related to electrical machine failures, this work creates a database of failures in three-phase induction motors from data from current, vibration, audio, voltage, magnetic flux, torque and speed sensors. Still, a study is carried out that allows the validation of the collected data, verifying if they have the characteristics to be used in the identification and classification of faults in electric motors. It was observed that all sensors used can provide useful information for the identification and classification of failures in electric motors, and that there are selected attributes in common between the two motors used in this work. The database created will be an important tool for the development of studies related to failures in electrical machines.

Keywords: Electric induction motor. multisensing. database. feature selection.

LISTA DE ILUSTRAÇÕES

Figura 1 – Partes de uma máquina de indução trifásica assíncrona	23
Figura 2 – Partes de um rolamento	24
Figura 3 – Falha de pista externa	25
Figura 4 – Falha de Pista interna	26
Figura 5 – Representação das falhas de curto-circuito de estator.	28
Figura 6 – Representação de uma falha de rotor.	30
Figura 7 – Etapas realizadas na realização do trabalho	42
Figura 8 – Transdutor de áudio MEMS.	44
Figura 9 – Diagrama de um microfone MEMS com saída analógica.	45
Figura 10 – Diagrama de um microfone MEMS com saída PDM.	45
Figura 11 – Diagrama de um microfone MEMS com saída I ² S.	46
Figura 12 – Acomodação dos microfones.	47
Figura 13 – Posição dos microfones em relação ao motor.	48
Figura 14 – Sensor de Vibração PHD-SR510A.	49
Figura 15 – Construção básica de um acelerômetro MEMS.	50
Figura 16 – Diagrama de blocos do acelerômetro analógico que se pretende utilizar no trabalho.	51
Figura 17 – Acelerômetro FXLN8372Q, produzido pelo fabricante NXP Semiconductors.	52
Figura 18 – Posição dos sensores de vibração no motor.	53
Figura 19 – Transformador de corrente.	54
Figura 20 – Posicionamento dos TCs para a medição das correntes de linha.	55
Figura 21 – TPs utilizados para a medição da tensão de alimentação do motor.	56
Figura 22 – Sensor de fluxo de dispersão projetado por Louzada <i>et al.</i> (2022) posicionado no motor a ser ensaiado	58
Figura 23 – Esquema de funcionamento do torquímetro.	59
Figura 24 – Placa de condicionamento de sinais para os sensores de áudio.	60
Figura 25 – Sistema de condicionamento de sinais do sensor de vibração industrial	61
Figura 26 – Placa de condicionamento de sinais para o acelerômetro MEMS.	62
Figura 27 – Placa de condicionamento de sinais para os TCs.	64
Figura 28 – Placa de condicionamento de sinais para os TPs.	64
Figura 29 – Sistema de condicionamento de sinais para o torquímetro.	65
Figura 30 – Conexões nos terminais da placa NI USB-6210.	67
Figura 31 – Conexões nos terminais da placa NI USB-6221.	68
Figura 32 – Caixa de ligação do curto-circuito.	70
Figura 33 – Rotores com emulação de barras quebradas.	71
Figura 34 – Fluxograma utilizado para o desgaste dos rolamentos.	72
Figura 35 – Rolamento sem a capa de proteção.	74
Figura 36 – Rolamento sem lubrificação.	74
Figura 37 – Rolamento com pasta abrasiva.	75
Figura 38 – Painel de alimentação.	77
Figura 39 – Fluxograma do processo de aquisição de dados para curto-circuito de estator	79
Figura 40 – Rotores com emulação de barras quebradas.	80

Figura 41 – Fluxograma do processo de aquisição de dados para barra quebrada de rotor.	82
Figura 42 – Fluxograma do processo de aquisição de dados para desgaste de rolamento.	84
Figura 43 – Evolução do desgaste dos rolamentos no motor de 1CV.	102
Figura 44 – Evolução do desgaste dos rolamentos no motor de 2CV.	103
Figura 45 – Duas variáveis dentro do arquivo 'BEA_014_019'.	105
Figura 46 – Correlação entre os atributos selecionados utilizando informação mútua para falha de estator no motor de 1CV.	110
Figura 47 – Correlação entre os atributos selecionados utilizando informação mútua para falha de rotor no motor de 1CV.	112
Figura 48 – Correlação entre os atributos selecionados utilizando informação mútua para falha de desgaste de rolamento no motor de 1CV.	114
Figura 49 – Correlação entre os atributos selecionados utilizando VIF para falha de estator no motor de 1CV.	116
Figura 50 – Correlação entre os atributos selecionados utilizando VIF para falha de rotor no motor de 1CV.	119
Figura 51 – Correlação entre os atributos selecionados utilizando VIF para falha de desgaste de rolamento no motor de 1CV.	121
Figura 52 – Correlação entre os atributos selecionados utilizando <i>Random Forest</i> para falha de estator no motor de 1CV.	124
Figura 53 – Correlação entre os atributos selecionados utilizando <i>Random Forest</i> para falha de rotor no motor de 1CV.	126
Figura 54 – Correlação entre os atributos selecionados utilizando <i>Random Forest</i> para falha de desgaste de rolamento no motor de 1CV.	129
Figura 55 – Correlação entre os atributos selecionados utilizando informação mútua para falha de estator no motor de 2CV.	131
Figura 56 – Correlação entre os atributos selecionados utilizando informação mútua para falha de rotor no motor de 2CV.	133
Figura 57 – Correlação entre os atributos selecionados utilizando informação mútua para falha de desgaste de rolamento no motor de 2CV.	135
Figura 58 – Correlação entre os atributos selecionados utilizando VIF para falha de estator no motor de 2CV.	139
Figura 59 – Correlação entre os atributos selecionados utilizando VIF para falha de rotor no motor de 2CV.	140
Figura 60 – Correlação entre os atributos selecionados utilizando VIF para falha de desgaste de rolamento no motor de 2CV.	142
Figura 61 – Correlação entre os atributos selecionados utilizando <i>Random Forest</i> para falha de estator no motor de 2CV.	146
Figura 62 – Correlação entre os atributos selecionados utilizando <i>Random Forest</i> para falha de rotor no motor de 2CV.	148
Figura 63 – Correlação entre os atributos selecionados utilizando <i>Random Forest</i> para falha de desgaste de rolamento no motor de 2CV.	152
Figura 64 – Esquemático da placa de condicionamento dos sinais de áudio desenvolvida.	167
Figura 65 – Esquemático da placa de condicionamento dos sinais de vibração desenvolvida.	168

Figura 66 – Esquemático da placa de condicionamento dos sinais de corrente desenvolvida.	169
Figura 67 – Esquemático da placa de condicionamento dos sinais de tensão desenvolvida.	170

LISTA DE TABELAS

Tabela 1 – Sistemas comerciais para monitoramento de motores elétricos.	39
Tabela 2 – Características do acelerômetro industrial neste trabalho.	49
Tabela 3 – Resumo das taxas de aquisição para cada tipo de sensor utilizado.	68
Tabela 4 – Características dos motores utilizados neste trabalho.	69
Tabela 5 – Faixas de tensões de atendimento para sistemas 220V/127V.	75
Tabela 6 – Total de ensaios realizados.	104
Tabela 7 – Atributos selecionados a partir da informação mútua para falha de estator no motor de 1CV.	109
Tabela 8 – Atributos selecionados a partir da informação mútua para falha de rotor no motor de 1CV.	110
Tabela 9 – Atributos selecionados a partir da informação mútua para falha de desgaste de rolamento no motor de 1CV.	113
Tabela 10 – Atributos selecionados a partir do VIF para falha de estator no motor de 1CV.	115
Tabela 11 – Atributos selecionados a partir do VIF para falha de rotor no motor de 1CV.	117
Tabela 12 – Atributos selecionados a partir do VIF para falha de desgaste de rolamento no motor de 1CV.	119
Tabela 13 – Atributos selecionados a partir do <i>Random Forest</i> para falha de estator no motor de 1CV.	122
Tabela 14 – Atributos selecionados a partir do <i>Random Forest</i> para falha de rotor no motor de 1CV.	125
Tabela 15 – Atributos selecionados a partir do <i>Random Forest</i> para falha de desgaste de rolamento no motor de 1CV.	127
Tabela 16 – Atributos selecionados a partir da informação mútua para falha de estator no motor de 2CV.	130
Tabela 17 – Atributos selecionados a partir da informação mútua para falha de rotor no motor de 2CV.	132
Tabela 18 – Atributos selecionados a partir da informação mútua para falha de desgaste de rolamento no motor de 2CV.	134
Tabela 19 – Atributos selecionados a partir do VIF para falha de estator no motor de 2CV.	136
Tabela 20 – Atributos selecionados a partir do VIF para falha de rotor no motor de 2CV.	137
Tabela 21 – Atributos selecionados a partir do VIF para falha de desgaste de rolamento no motor de 2CV.	140
Tabela 22 – Atributos selecionados a partir do <i>Random Forest</i> para falha de estator no motor de 2CV.	143
Tabela 23 – Atributos selecionados a partir do <i>Random Forest</i> para falha de rotor no motor de 2CV.	147
Tabela 24 – Atributos selecionados a partir do <i>Random Forest</i> para falha de desgaste de rolamento no motor de 2CV.	149
Tabela 25 – Resumo da seleção dos atributos para o motor de 1CV.	153
Tabela 26 – Resumo da seleção dos atributos para o motor de 2CV.	153

Tabela 27 – Resumo dos atributos selecionados em comum entre os motores de 1CV e 2CV.	153
---	-----

SUMÁRIO

1	INTRODUÇÃO	17
1.1	JUSTIFICATIVA	18
1.2	OBJETIVOS	19
1.2.1	Objetivo Geral	19
1.2.2	Objetivos Específicos	19
1.3	ORGANIZAÇÃO DO TRABALHO	20
2	FALHAS EM MOTORES DE INDUÇÃO	21
2.1	ASPECTOS CONSTRUTIVOS DO MOTOR DE INDUÇÃO TRI-FÁSICO	22
2.2	FALHAS MECÂNICAS	23
2.2.1	Falha de Rolamento	24
2.3	FALHAS ELÉTRICAS	27
2.3.1	Falha de estator	28
2.3.2	Falha de rotor	29
2.4	CONCLUSÃO DO CAPÍTULO	31
3	SENSORIAMENTO APLICADO AOS MOTORES DE INDUÇÃO TRI-FÁSICOS	32
3.1	SENSORES DE CORRENTE	33
3.2	SENSORES DE ÁUDIO	35
3.3	SENSORES DE VIBRAÇÃO	36
3.4	MULTISSENSORIAMENTO	37
3.5	SISTEMAS COMERCIAIS DE MONITORAMENTO	38
3.6	CONCLUSÃO DO CAPÍTULO	40
4	METODOLOGIA DA PESQUISA	41
4.1	ANÁLISE, SELEÇÃO E ACONDICIONAMENTO DOS SENSORES UTILIZADOS	41
4.1.1	Sensores de áudio e de vibração	43
4.1.1.1	Sensores de áudio	43
4.1.1.2	Sensores de vibração	47
4.1.2	Sensores de corrente e de tensão	51
4.1.2.1	Sensor de Corrente	52
4.1.2.2	Sensor de Tensão	55
4.1.3	Sensor de Fluxo	57
4.1.4	Sensor de Torque e Velocidade	58
4.2	CONDICIONAMENTO DOS SINAIS	59
4.2.1	Condicionamento dos sinais de áudio	59
4.2.2	Condicionamento dos sinais de vibração	61
4.2.3	Condicionamento dos sinais de corrente e de tensão	63
4.2.4	Condicionamento dos sinais de torque e velocidade	65
4.3	AQUISIÇÃO DOS DADOS E CRIAÇÃO DA BASE DE DADOS	65
4.3.1	Características do Sistema de Aquisição	66
4.3.2	Características dos Motores Utilizados no Ensaio	68

4.3.3	Processo de inserção das falhas	69
4.3.3.1	Emulação da falha de curto-circuito de estator	69
4.3.3.2	Emulação da falha de barra quebrada de rotor	70
4.3.3.3	Emulação da falha de desgaste de rolamento	71
4.3.4	Ensaio Realizados	73
4.3.4.1	Curto-circuito de Estator	78
4.3.4.2	Barra Quebrada de Rotor	81
4.3.4.3	Desgaste de Rolamento	83
4.3.5	Definição das TAGs	85
4.4	PROCESSAMENTO DOS SINAIS	90
4.4.1	Medidas Estatísticas no Domínio do Tempo	90
4.4.2	Medidas Estatísticas no Domínio da Frequência	93
4.5	SELEÇÃO DOS ATRIBUTOS	96
4.5.1	Informação Mútua	97
4.5.2	<i>Variance Inflation Factor</i> (VIF)	97
4.5.3	<i>Random Forest</i>	99
4.6	CONCLUSÃO DO CAPÍTULO	100
5	RESULTADOS	101
5.1	EVOLUÇÃO DO DESGASTE DE ROLAMENTO	101
5.1.1	Desgaste do rolamento do motor de 1CV	101
5.1.2	Desgaste do rolamento do motor de 2CV	102
5.2	BANCO DE DADOS	104
5.2.1	Dados adicionais	107
5.3	SELEÇÃO DOS ATRIBUTOS E SENSORES	108
5.3.1	Seleção para o motor de 1CV	108
5.3.1.1	Seleção dos atributos utilizando informação mútua	108
5.3.1.1.1	<i>Informação mútua para falha de estator</i>	108
5.3.1.1.2	<i>Informação mútua para falha de rotor</i>	109
5.3.1.1.3	<i>Informação mútua para falha de desgaste de rolamento</i>	112
5.3.1.2	Seleção dos atributos utilizando VIF	114
5.3.1.2.1	<i>VIF para falha de estator</i>	115
5.3.1.2.2	<i>VIF para falha de rotor</i>	117
5.3.1.2.3	<i>VIF para falha de desgaste de rolamento</i>	118
5.3.1.3	Seleção dos atributos utilizando <i>Random Forest</i>	122
5.3.1.3.1	<i>Random Forest para falha de estator</i>	122
5.3.1.3.2	<i>Random Forest para falha de rotor</i>	125
5.3.1.3.3	<i>Random Forest para falha de desgaste de rolamento</i>	127
5.3.2	Seleção para o motor de 2CV	130
5.3.2.1	Seleção dos atributos utilizando informação mútua	130
5.3.2.1.1	<i>Informação mútua para falha de estator</i>	130
5.3.2.1.2	<i>Informação mútua para falha de rotor</i>	132
5.3.2.1.3	<i>Informação mútua para falha de desgaste de rolamento</i>	134
5.3.2.2	Seleção dos atributos utilizando VIF	136
5.3.2.2.1	<i>VIF para falha de estator</i>	136
5.3.2.2.2	<i>VIF para falha de rotor</i>	137
5.3.2.2.3	<i>VIF para falha de desgaste de rolamento</i>	139
5.3.2.3	Seleção dos atributos utilizando <i>Random Forest</i>	143

5.3.2.3.1	<i>Random Forest para falha de estator</i>	143
5.3.2.3.2	<i>Random Forest para falha de rotor</i>	145
5.3.2.3.3	<i>Random Forest para falha de desgaste de rolamento</i>	149
5.3.2.4	Resumo da Seleção dos Atributos	153
5.4	CONCLUSÃO DO CAPÍTULO	154
6	CONCLUSÃO	155
6.1	TRABALHOS FUTUROS	156
	REFERÊNCIAS	157
	APÊNDICE A – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE ÁUDIO DESENVOLVIDA .	167
	APÊNDICE B – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE VIBRAÇÃO DESENVOLVIDA	168
	APÊNDICE C – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE CORRENTE DESENVOLVIDA	169
	APÊNDICE D – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE TENSÃO DESENVOLVIDA	170

1 INTRODUÇÃO

Os motores de indução trifásico são as máquinas elétricas mais utilizadas na indústria, isso se deve a uma série de fatores, tais como baixo custo de aquisição e manutenção, por possuírem um bom desempenho frente a uma ampla variedade de solicitações mecânicas, além de serem máquinas robustas podendo operar em diversas condições de ambiente e nas mais variadas aplicações (BAZAN *et al.*, 2022).

Nos últimos anos a necessidade de manutenção preditiva vem ganhando popularidade em diversos campos, desde atividades industriais até mesmo em aplicações de tração elétrica (FROSINI, 2019). Muitas vezes a parada de uma máquina em um processo produtivo pode levar a perdas econômicas consideráveis, além de existir a possibilidade de outros danos materiais e até mesmo a causar acidentes pessoais.

As falhas em motores de indução trifásicos podem se apresentar nos mais variados componentes dessa máquina. Os principais componentes do motor que podem apresentar falhas são os rolamentos com cerca de 40% das falhas (ESFAHANI *et al.*, 2014; ALSAEDI, 2015), o estator com aproximadamente 38% das falhas e o rotor, com 10% das falhas (ESFAHANI *et al.*, 2014).

Diferentes técnicas de diagnóstico vêm sendo aplicadas aos motores de indução presentes na indústria. As técnicas de diagnóstico podem ser off-line, onde obtém-se os dados dos motores e após a obtenção dos dados é que é aplicada uma técnica de diagnóstico. As técnicas também podem ser on-line, onde a obtenção dos dados e o diagnóstico do motor é realizado de maneira praticamente simultânea, muitas vezes a partir de um hardware dedicado e projetado especificamente para esse fim (SEERA *et al.*, 2013).

A utilização de diversos tipos de sensores para obter informações que auxiliem no diagnóstico das falhas também é uma área de pesquisas recentes, sendo que algumas variáveis que atualmente são utilizadas para o diagnóstico de falhas em motores de indução trifásico são: corrente (BAZAN *et al.*, 2017), vibração (MARTINEZ *et al.*, 2017), áudio (SANTOS *et al.*, 2019), fluxo magnético (FILHO *et al.*, 2020), entre outros (MOHAMMED; DJUROVIC, 2021; De Pelegrin *et al.*, 2020; CHOUDHARY *et al.*, 2021).

A contribuição deste trabalho consiste no estudo e utilização de sensores de

vibração, corrente, áudio, tensão, fluxo de dispersão, torque e velocidade para a criação de um banco de dados de falhas de máquinas elétricas. Tal banco de dados foi criado a partir da simulação de defeitos de rolamento, estator e rotor em um motor de indução trifásico sujeito a diversas condições de alimentação, tais como desbalanceamento de tensão e solicitações mecânicas. Com o banco de dados de falhas obtido, realizou-se a validação dos dados, de modo a observar se os dados coletados pelos diversos sensores possuem características que permitem que os mesmos sejam utilizados em técnicas de análise de falhas. A validação consistiu na verificação da influência de alguns atributos estatísticos dos dados obtidos por cada sensor. E com isso, na seleção dos principais sensores e seus atributos que contribuem para a identificação das falhas presentes no banco de dados.

1.1 JUSTIFICATIVA

Verifica-se que, de acordo com o Balanço Energético Nacional de 2019, o consumo de energia elétrica pelo setor industrial representou cerca de 30% de toda a energia elétrica produzida no Brasil (EPE, 2020) Neste contexto, os maiores consumidores são os motores de indução trifásicos, responsáveis por cerca de 60% da energia consumida na indústria brasileira (WEG, 2020) e no mundo estima-se em 80% conforme (GARCIA-ESCUADERO *et al.*, 2017). Analisando o Brasil, de toda a energia elétrica consumida no país, cerca de 18% é consumida exclusivamente por motores elétricos.

Considerando os fatores apresentados na seção anterior relacionados às falhas de motores de indução, que pode levar a grandes perdas financeiras para o setor industrial e também causar danos às pessoas e outros equipamentos, é possível afirmar que a análise e diagnóstico das falhas em máquinas elétricas é um tema de extrema relevância no contexto atual.

Consta na literatura diversas pesquisas relacionadas ao diagnóstico de falhas em máquinas elétricas, sendo que as investigações contemplam três grandes áreas: i) o sensoriamento e seu condicionamento de sinais, ii) os métodos de extração de características com técnicas de processamento de sinais e iii) os métodos de classificação de padrões. Assim, as referidas pesquisas têm como objetivo o desenvolvimento de técnicas confiáveis para o diagnóstico e identificação da severidade das falhas em

máquinas elétricas.

1.2 OBJETIVOS

Nesta seção serão apresentados os objetivos deste trabalho.

1.2.1 Objetivo Geral

Este trabalho tem por objetivo utilizar o multissensoriamento para a criação de um banco de dados de falhas em motores de indução trifásicos operando sob diversas condições de trabalho, bem como sujeito às três falhas mais comuns; a saber: i) o curto-circuito no enrolamento do estator, ii) a quebra das barras do rotor e iii) o desgaste excessivo dos rolamentos.

1.2.2 Objetivos Específicos

De maneira mais específica, este trabalho tem por objetivo utilizar os sinais de corrente, tensão, vibração, emissão acústica e fluxo de dispersão provenientes de um motor de indução trifásico em condições normais de operação e com falhas de estator, rotor e rolamento, emulando diversas situações de operação na indústria. Neste contexto, alguns objetivos específicos do trabalho são:

- Estudar os conceitos ligados ao sensoriamento e ao multissensoriamento de motores de indução;
- Identificar as tendências de sensoriamento de motores de indução tanto no meio acadêmico quanto no meio industrial;
- Criar uma metodologia adequada e robusta para o ensaio dos motores de indução e criação do banco de dados;
- Utilizar sensores de relativo baixo custo para a obtenção dos sinais dos motores de indução;
- Validar os dados obtidos por meio da utilização de técnicas de seleção de parâmetros;

- Identificar os sensores que possuem as melhores características para a identificação de cada tipo de falha emulada.

1.3 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado como segue:

No Capítulo 2 são apresentados conceitos sobre falhas em motores de indução trifásicos, bem como técnicas apresentadas na literatura para o diagnóstico das condições do motor.

No Capítulo 3 são apresentados alguns métodos de obtenção dos sinais provenientes nos motores elétricos. Ao final do capítulo são apresentados alguns sistemas disponíveis comercialmente para o monitoramento dos motores de indução.

No Capítulo 4 é apresentada a metodologia utilizada na realização do trabalho.

No Capítulo 5 são apresentados os resultados obtidos com a realização deste trabalho, bem como é realizado uma análise desses resultado de modo a verificar a validade do banco de dados criado.

Por fim, no Capítulo 6 são apresentadas as considerações finais deste trabalho, bem como algumas sugestões para trabalho futuros.

2 FALHAS EM MOTORES DE INDUÇÃO

Os motores de induções trifásicos são máquinas amplamente utilizadas na indústria, devido às suas características tais como: robustez, baixa manutenção, facilidade de instalação, baixo custo e eficiência. Mesmo sendo um equipamento robusto, os mesmos podem, no decorrer de sua vida útil, apresentar problemas relacionados a falhas em um de seus componentes (HAROUN *et al.*, 2018).

Conforme apresentado por Nandi *et al.* (2005) as falhas que podem ocorrer em motores elétricos podem ser classificadas em:

- a) Falhas de estator devido a curto-circuito de uma ou mais fases dos enrolamentos do estator;
- b) Instalação incorreta dos enrolamentos do estator no processo de fabricação ou em processos de rebobinamento;
- c) Barras quebradas ou anel quebrado do rotor;
- d) Problemas relacionados à excentricidade;
- e) Torção no eixo;
- f) Curto-circuito nos enrolamentos do rotor;
- g) Falhas nos rolamentos e nos sistemas de transmissão.

Ainda, segundo Nandi *et al.* (2005), as falhas com maior incidência em máquinas elétricas são as falhas de rolamento, curto-circuito de estator, barras quebradas de rotor e problemas de excentricidade. Quando o motor apresenta alguma dessas falhas é possível observar algumas características indicativas da existência dessa, tais como (PALÁCIOS *et al.*, 2016; BAZAN, 2020):

- a) Corrente de linha desbalanceadas;
- b) Apresentação de pulsação no torque;
- c) Diminuição do torque médio;
- d) Aumento das perdas de energia, e conseqüentemente redução da eficiência energética do motor;
- e) Temperatura excessiva.

Assim, para a identificação das falhas apresentadas pelos motores de indução foram desenvolvidos uma série de técnicas de análise, tais como:

- a) Monitoramento do fluxo de dispersão;
- b) Medição de temperatura;
- c) Monitoramento de emissões de radiofrequências;
- d) Monitoramento de vibração;
- e) Medidas de emissão acústica;
- f) Análise da assinatura de corrente do motor;
- g) Técnicas de modelagem;
- h) Técnicas de processamento de sinais;
- i) Utilização de métodos de classificação padrões.

O diagnóstico correto, bem como a detecção precoce de uma condição de falha em um motor elétrico, pode resultar em uma manutenção mais rápida e simples do que aquela que ocorreria quando a falha apresentada pelo motor já estivesse em um estágio mais avançado. Além disso, também diminui a possibilidade de uma falha catastrófica do motor e reduz as perdas financeiras (BELLINI *et al.*, 2008).


Para que se consiga uma melhor compreensão acerca das possibilidades de falhas nos motores de indução é necessário inicialmente analisar a construção de um motor de indução trifásico.

2.1 ASPECTOS CONSTRUTIVOS DO MOTOR DE INDUÇÃO TRIFÁSICO

Segundo Kingsley *et al.* (2006), as máquinas de indução trifásicas possuem entre as suas partes construtivas os enrolamentos do estator, o rotor, o estator, os rolamentos, a carcaça e os terminais de ligação. O rotor desta máquina pode ser do tipo gaiola de esquilo, onde o enrolamento do mesmo é constituído por barras conectadas entre si. Há também os rotores bobinados, onde os enrolamentos do rotor são feitos por espiras geralmente de cobre. Na maioria das aplicações prefere-se a utilização de rotores em gaiola de esquilo devido, principalmente, ao seu menor custo, enquanto os motores de indução com rotores bobinados se restringem a aplicações especiais em que se faz necessário o acesso às conexões das bobinas do rotor.

A Figura 1 mostra as partes de uma máquina de indução trifásica com rotor em gaiola de esquilo. Pode-se observar as partes construtivas do motor, tais como o estator, o rotor, os enrolamentos do estator e os rolamentos.

Figura 1 – Partes de uma máquina de indução trifásica assíncrona



Fonte: WEG (2021).

Conforme pode ser observado na Figura 1, existem várias partes de um motor de indução trifásico que podem apresentar falhas quando em operação. Tais falhas podem ocorrer tanto em partes mecânicas, quanto em partes elétricas do motor.

2.2 FALHAS MECÂNICAS

As falhas mecânicas em motores de indução trifásicos são as mais presentes na indústria representando cerca de 45% a 55% das paradas indesejadas destas máquinas (GANGSAR; TIWARI, 2020). O defeito de origem mecânico que mais se observa em máquinas elétricas é a falha de rolamento, seguida pelas falhas no mecanismo de acoplamento/transmissão, além das falhas de excentricidade e desalinhamento.


2.2.1 Faha de Rolamento

Os rolamentos são os elementos que permitem com que o motor rotacione, proporcionando suporte e apoio à máquina girante. O rolamento pode ser dividido em 4 partes conforme ilustrado na Figura 2:

- Pista interna;
- Pista externa;
- Esfera;
- Gaiola.

Além disso, é possível observar na Figura 2 que os rolamentos possuem algumas características construtivas relacionadas às suas dimensões, sendo possível citar o diâmetro da esfera (D_b), diâmetro da gaiola (D_c) e o ângulo de contato entre a esfera e a pista externa (β).

Figura 2 – Partes de um rolamento



Fonte: Adaptado de Blodt *et al.* (2008).


As falhas de rolamento são as falhas mais comuns em motores de indução, dentre todas as possibilidades de falha no motor, respondendo por mais de 40% dessas falhas (ESFAHANI *et al.*, 2014; ALSAEDI, 2015). Os principais fatores que levam o

rolamento do motor a falhar são: i) o estresse mecânico, ii) o estresse térmico, iii) a fricção e contaminação do lubrificante, iv) a instalação incorreta do rolamento e v) a falta de lubrificação (GANGSAR; TIWARI, 2020).

Esse tipo de falha pode se apresentar de 4 maneiras distintas (GONGORA *et al.*, 2016), sendo elas:

- a) Falhas na pista externa (representada na Figura 3);
- b) Falhas na pista interna (representada na Figura 4);
- c) Falha nas esferas;
- d) Falha devido ao desgaste do rolamento ou a presença de algum contaminante no lubrificante do mesmo.

Figura 3 – Falha de pista externa




Fonte: Adaptado de Blodt *et al.* (2008).

Observa-se pelas Figura 3 e Figura 4 que a existência de falhas nos rolamentos poderá ocasionar um problema de excentricidade no motor.

As frequências de vibração características para cada tipo das falhas podem ser calculadas em função da geometria dos rolamentos, bem como da frequência do rotor do motor (BLODT *et al.*, 2008). A modelagem das frequências de vibração associadas a cada falha é ilustrada em Li *et al.* (2000) e podem ser descritas pelas Equação (1),

Figura 4 – Falha de Pista interna



Fonte: Adaptado de Blodt *et al.* (2008).

Equação (2) e Equação (3) para falhas na pista externa, falhas na pista interna e falha nas esferas respectivamente.

$$f_e = \left(\frac{N_b}{2}\right)f_r \left(1 - \frac{D_b \cos(\beta)}{D_c}\right) \quad (1)$$

$$f_i = \left(\frac{N_b}{2}\right)f_r \left(1 - \frac{D_b \cos(\beta)}{D_c}\right) \quad (2)$$

$$f_b = \frac{D_c}{(2D_b)}f_r \left(1 - \frac{D_b^2 \cos^2(\beta)}{D_c}\right) \quad (3)$$

onde f_b é a frequência de vibração em caso de falha nas esferas, f_i é a frequência de vibração em caso de falha na pista interna do rolamento, f_e é a frequência de vibração em caso de falha na pista externa do rolamento, N_B é o número de esferas, f_r é a frequência do rotor, D_b é o diâmetro da esfera, D_c é o diâmetro da gaiola e β é o ângulo de contato entre a esfera e a pista externa.

Blodt *et al.* (2008) ilustra que para rolamentos que contenham de 6 a 12 esferas, as expressões de frequência de vibração da Equação (1) e da Equação (2) podem ser simplificadas para a Equação (4) e Equação (5) respectivamente:

$$f_e = 0,4N_b f_r \quad (4)$$

$$f_i = 0,6N_b f_r \quad (5)$$

Nos casos em que se deseja analisar as falhas de rolamento a partir dos sinais de corrente no estator, pode-se utilizar a Equação (6), que representa a relação entre a vibração do rolamento e a corrente de estator. A vibração do rolamento causa a variação do entreferro entre o estator e o rotor do motor. A variação desse gap ocasiona a alteração da densidade de fluxo magnético e, conseqüentemente ocasiona a mudança do valor da relutância do circuito magnético do motor. Assim a variação da densidade de fluxo magnético no entreferro implica na alteração da corrente do estator em frequência múltiplas da frequência de alimentação do motor (SCHOEN *et al.*, 1995; GONGORA *et al.*, 2016; BLODT *et al.*, 2008).

$$f_h = |f \pm k \times f_{cf}| \quad (6)$$

onde f_h é a frequência harmônica característica de falha de rolamento na corrente do estator, k é um multiplicador (1, 2, 3 ...) f é a frequência de alimentação da motor de indução e f_{cf} é a frequência característica de falha no rolamento.

A partir das Equações de (1) a (6) apresentadas é possível identificar a partir dos sinais de vibração, de corrente, ou de outros tipos de sinais se um rolamento de determinado motor apresenta falha e a sua severidade.

2.3 FALHAS ELÉTRICAS

As falhas elétricas em motores de indução trifásicos são o segundo tipo de defeito mais presentes na indústria representando cerca de 30% a 40% dos problemas de manutenção associados aos motores de indução trifásicos conforme Gangsar e Tiwari (2017). A falha elétrica que mais se observa em máquinas elétricas é o curto-circuito no estator, seguida pelas falhas de rotor, e pelos problemas de desbalanceamento de tensão e falta de fase.

Neste trabalho será dada mais ênfase às falhas elétricas de curto-circuito no estator e de barra quebrada no rotor. Para os problemas relacionados à qualidade

de energia será considerado apenas o desbalanceamento de tensão de linha como problemas associados à qualidade de energia e instalação dos motores de indução trifásicos conforme metodologia apresentada por Palácios *et al.* (2017) e Bazan *et al.* (2022).

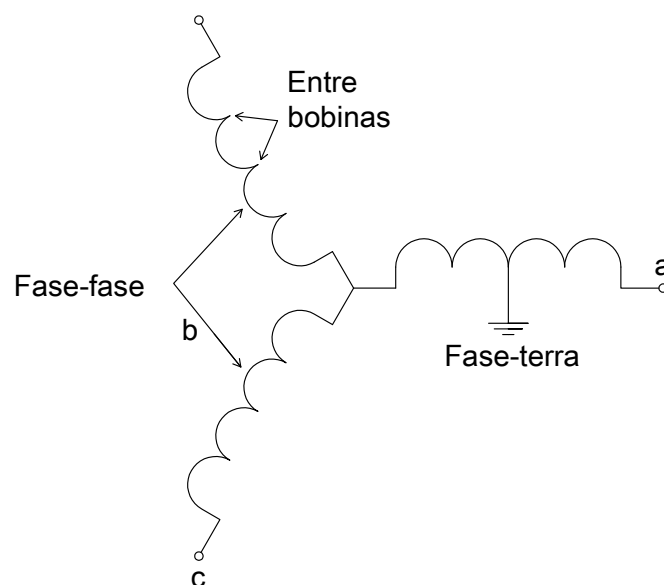
2.3.1 Falha de estator

As falhas de estator são as falhas elétricas mais comuns em motores de indução, respondendo por mais de 38% dessas falhas (ESFAHANI *et al.*, 2014). Os principais fatores que levam o estator do motor a falhar são: i) o estresse térmico que leva a problemas na isolação dos enrolamentos do estator, ii) os problemas de alinhamento que levam o rotor do motor encostar nos enrolamentos do estator; iii) a vibração, iv) os problemas de instalação e v) a contaminação do óleo lubrificante (GANGSAR; TIWARI, 2020).

Esse tipo de falha pode se apresentar como segue (GANGSAR; TIWARI, 2020):

- a) Curto-circuito entre enrolamentos;
- b) Curto-circuito entre duas fases;
- c) Curto-circuito entre fase e terra.

Figura 5 – Representação das falhas de curto-circuito de estator.



Fonte: Adaptado de Bazan *et al.* (2017).

A Figura 5 ilustra os tipos de falhas de curto-circuito que um estator pode apresentar. As frequências características da falha de estator quando é medido o fluxo axial da máquina pode ser calculada como (NANDI *et al.*, 2005) e (PENMAN *et al.*, 1994):

$$f_s = \left(k \pm \frac{n(1-s)}{p}\right) \times f \quad (7)$$

onde f_s é a frequência característica de falha de estator no sinal de corrente, k é um multiplicador (1, 2, 3...), n é um multiplicador relacionado ao número de pares de polos do motor (1, 2, ..., $(2p-1)$), s é o escorregamento, p é o número de polos e f é a frequência de alimentação da motor.

Uma falha de curto-circuito de estator é caracterizada inicialmente por um problema relacionado ao isolamento do condutor dos enrolamentos. A perda do isolamento no condutor evolui ao ponto de que em alguns locais dos enrolamentos do estator ocorre o curto-circuito dos condutores, ocasionando as falhas de curto-circuito do estator (BAZAN *et al.*, 2017; GODOY *et al.*, 2015; BELLINI *et al.*, 2008; HAROUN *et al.*, 2018).

A partir do momento em que ocorre a falha de curto-circuito de estator, observa-se que a evolução da falha é rápida, uma vez que o curto-circuito causa um aumento significativo de corrente no enrolamento. Assim ocorre o aumento da temperatura do mesmo, levando à deterioração de mais pontos da isolação, ocasionando assim o aumento da severidade da falha (PALÁCIOS *et al.*, 2017). Dessa maneira, a detecção rápida de uma falha de estator é essencial para que se evite uma falha catastrófica no motor (RIERA-GUASP *et al.*, 2015).


2.3.2 Falha de rotor

As falhas de rotor são a segunda falha elétrica mais comum em motores de indução. Dentre todas as possibilidades de falha no motor, o rotor responde por aproximadamente 10% dessas falhas (ESFAHANI *et al.*, 2014). Os principais fatores que levam o rotor do motor a falhar são: excessivos acionamentos, estresse térmico, torque eletromagnético desbalanceado, estresse magnético, problemas na fabricação do rotor (GANGSAR; TIWARI, 2020).

Esse tipo de falha pode se apresentar como segue (GANGSAR; TIWARI, 2020)

- a) Problemas de barra quebrada no rotor;
- b) Problemas com os anéis do rotor.

Figura 6 – Representação de uma falha de rotor.



Fonte: Adaptado de Gangsar e Tiwari (2020).

A Figura 6 ilustra uma falha pontual no rotor. A falha mais comum encontrada em rotores é a falha de barra-quebrada (GANGSAR; TIWARI, 2020), que se caracteriza pela apresentação de um defeito em uma ou mais barras do rotor, influenciando assim no circuito magnético do motor. Este defeito ocasiona, entre outros efeitos: i) a vibração em excesso, ii) o aquecimento excessivo, iii) o aumento do fluxo de dispersão do motor, iv) as flutuações na velocidade e na corrente e v) a pulsação no torque eletromagnético.

Em alguns estudos realizados observou-se que a partir do momento em que uma barra do rotor apresenta falha, as barras adjacentes tendem a sofrer uma sobrecarga. Dessa maneira, as barras adjacentes são mais suscetíveis a também apresentarem falhas (GYFTAKIS *et al.*, 2016).

Conforme Sizov *et al.* (2009) e Gyftakis *et al.* (2016) a falha de barra quebrada pode ocorrer em barras não subjacentes, sendo que a ocorrência de falhas nas barras parece ocorrer de maneira aleatória.

As frequências características da falha de rotor observadas nas correntes de estator do motor de indução podem ser calculadas como em Filippetti *et al.* (1998):

$$f_r = (1 \pm 2ks) \times f \quad (8)$$

onde f_r é a frequência característica de falha nas barras do rotor, k é um multiplicador (1, 2, 3...), s é o escorregamento e f é a frequência de alimentação do motor.

Uma falha de rotor está ligada em muitos aspectos ao processo de fabricação do mesmo assim como à aplicação em que ele se encontra (GYFTAKIS *et al.*, 2016). Um exemplo de um processo de fabricação que pode levar a falhas no rotor é o processo de fundição do alumínio. Mais especificamente, durante o processo de fundição podem surgir bolhas de ar dentro das barras, o que pode levar ao aumento da temperatura no entorno da barra com problema, e eventualmente fazer com que o motor apresente a quebra da barra do rotor (DORRELL *et al.*, 2009).

2.4 CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou uma breve revisão sobre alguns conceitos relacionados à falha de máquina e sobre metodologias utilizadas para identificação e classificação das mesmas.

Pode-se observar que a maioria das falhas em motores de indução trifásicos são as falhas de rolamento e as falhas de estator, que juntas correspondem em mais de 80% das falhas. Não se pode deixar de considerar também as falhas de rotor, pois as mesmas representam cerca de 10% das falhas em motores de indução trifásicos.

Observa-se que o estudo sobre falhas de máquinas elétricas e sobre técnicas para identificação e classificação dessas falhas é um assunto atual e importante, sendo que diversos métodos de sensoriamento, de processamento dos sinais e de extração de parâmetros são empregados.

3 SENSORIAMENTO APLICADO AOS MOTORES DE INDUÇÃO TRIFÁSICOS

A obtenção não invasiva dos sinais dos motores de indução trifásicos pode ser realizada a partir de sensores que fazem a medição de grandezas tanto elétricas quanto mecânicas, tais como sensores de tensão, corrente, fluxo magnético de dispersão, velocidade, vibração, emissão acústica, torque, temperatura, entre outros (HENAO *et al.*, 2014).

A utilização de diversos tipos de sensores é uma estratégia cada vez mais frequente para obter os sinais característicos dos motores de indução trifásicos. Em algumas pesquisas é observado o uso de sensores que objetivam a medição do fluxo magnético de dispersão do motor de indução, seja por meio de bobinas posicionadas próximas à carcaça do motor (FILHO *et al.*, 2020; IRHOUMAH *et al.*, 2019; PARK *et al.*, 2020), como com a utilização de sensores de efeito Hall para a medição dos fluxos de dispersão do motor. Estes sensores podem ser posicionados tanto internamente quanto externamente ao motor (MIRZAEVA; SAAD, 2018a; MIRZAEVA; SAAD, 2018b; DIAS; PEREIRA, 2018). Em Dias e Pereira (2018) utilizou-se sensores Hall na ranhura do estator para a mediação do fluxo no entreferro com o objetivo de diagnosticar falhas de rotor. Os autores do referido trabalho, considerando um motor operando em condições normais de carregamento, obtiveram entre 100% de taxa de acertos para a classificação utilizando Redes Neurais Artificiais, e 88% de taxa de acertos para a classificação utilizando SVM (Máquina de Vetores de Suporte, do inglês *Support Vector Machines*) ou kNN (k- Vizinhos Próximos, do inglês *k-Nearest Neighbors*). Em Irhoumah *et al.* (2019) utilizou-se duas bobinas na carcaça do motor para detectar o fluxo magnético de dispersão e posterior classificação de falhas de estator. O referido artigo apresenta 89% de taxa de acertos na classificação.

Outros tipos de sensores também são utilizados para o diagnóstico de falhas dos motores de indução trifásicos. A utilização, por exemplo, de fibra ótica foi empregada para obtenção de sinais de temperatura e vibração de motores de indução para posterior detecção e classificação de falhas de rolamentos (MOHAMMED; DJUROVIC, 2021; De Pelegrin *et al.*, 2020). Também para a classificação de falhas de rolamento, é possível encontrar trabalhos que utilizam a obtenção de sinais térmicos para o diagnóstico das falhas de rolamento, conforme apresentado em Choudhary *et al.* (2021). Neste trabalho,

com os sinais térmicos obtidos a partir de uma câmera térmica, foi possível atingir uma taxa de acertos entre 96,7% e 100%. Em Barusu e Deivasigamani (2021) utilizou-se sensores de micro-ondas para a detecção de vibração do motor e assim classificar falhas de rolamento, obtendo-se uma taxa de acertos superior a 93%.

Analisando-se as pesquisas recentes, observa-se que os sensores utilizados com mais frequência para obtenção dos sinais característicos dos motores de indução para a identificação e classificação das falhas são os sensores de tensão, de corrente, de vibração e de emissão acústica, isso ocorre devido à facilidade de posicionamento desses sensores para a obtenção dos sinais do motor, e também devido ao relativo baixo custo desses sensores. Dessa maneira, nas próximas seções desse trabalho será feita uma breve revisão sobre a utilização desses sensores em pesquisas relacionadas à detecção e classificação de falhas.

3.1 SENSORES DE CORRENTE

Os sinais de corrente são muito utilizados quando se deseja obter características em motores de indução trifásico. Normalmente, uma falha que ocorre em um motor de indução é refletida em sua alimentação como mencionado no capítulo anterior. Até mesmo as falhas mecânicas levam ao aparecimento de sinais característicos dessas falhas nas correntes de linha do motor. Como exemplo, pode-se citar as falhas de rolamento, que apresentam características de vibração específica de acordo com o tipo de falha e do rolamento instalado na máquina. A vibração apresentada por esse tipo de falha leva à mudanças no fluxo magnético da máquina, o que leva a alteração da corrente de alimentação da mesma, conforme mostrado na Equação (6).

Dessa forma, os sensores de corrente são uma alternativa em aplicações que envolvem o diagnóstico e classificação de falhas em motores de indução. Em Bazan *et al.* (2017), Bazan *et al.* (2019b) e Bazan *et al.* (2022) foram utilizados sinais de corrente do estator do motor de indução para a classificação de falhas de curto-circuito de estator a partir das medidas de informação, com a obtenção de acurácia de até 100%. Em Bazan *et al.* (2019a) essas medidas de informação foram utilizadas para classificar falhas de rolamentos nos motores de indução trifásicos.

A utilização dos sinais de corrente para diagnóstico de falhas de curto-circuito de estator também pode ser observado no trabalho apresentado por Godoy *et al.* (2015),

onde utilizou-se sinais de corrente no domínio do tempo de um motor alimentado por inversor de frequência, neste trabalho foi obtida uma taxa de acertos de até 86,31% para a determinação da severidade do curto-circuito entre espiras do motor. Em Palácios *et al.* (2016) e em Palácios *et al.* (2017) os sinais de corrente no domínio do tempo são utilizados para a identificação de falhas de estator a partir da utilização de sistemas inteligentes, nesses trabalhos a acurácia obtida variou de 60% a 100% a depender da severidade da falha. Em Souza *et al.* (2022) os sinais de corrente também são utilizados para identificação de falhas de curto-circuito de estator.

Blodt *et al.* (2008) propõe uma modelagem para relacionar a vibração causada por falhas em rolamentos de motores de indução trifásicos e as correntes de estator. Tal modelagem se baseia no fato da vibração da máquina ocasionar a variação do fluxo do entreferro, e essa variação do fluxo do entreferro ocasiona a alteração na corrente do estator em frequências específicas de acordo com o tipo de falha de rolamento. Tal modelagem é utilizada nas análises apresentadas por Esfahani *et al.* (2014), Duque-Perez *et al.* (2019) e Gongora *et al.* (2016).

Ainda, em Lopes *et al.* (2017) é apresentada a utilização de sinais de corrente de duas fases do motor de indução trifásico para identificar falhas de rolamento nesse motor. Em Filippetti *et al.* (1998) é proposta uma técnica de diagnóstico inteligente para classificação de falhas em máquinas elétricas a partir de dados de corrente e velocidade.

Com respeito ao rotor, tem-se no trabalho de Sizov *et al.* (2009) a utilização dos sinais de corrente para análise e diagnóstico de falhas de rotor com barras quebradas adjacentes e não adjacentes. Por fim, em Godoy *et al.* (2016) os sinais de corrente são utilizados para detectar e classificar falhas de barra quebrada em rotores de motores de indução trifásicos alimentados por inversor de frequência.

Observa-se que a utilização dos sinais das correntes de linha do estator têm sido muito explorada para determinação de falhas em motores de indução trifásicos. Diante disso, a seleção e utilização correta do sensor de corrente, bem como o condicionamento de seu sinal de saída é essencial para a extração de características e para a classificação de padrões das falhas dos motores de indução trifásico por meio dos dados das correntes de linha do motor.

3.2 SENSORES DE ÁUDIO

A utilização de sinais de acústicos vêm sendo empregada na obtenção de sinais característicos de máquinas elétricas. Os trabalhos existentes na literatura utilizam diversas abordagens para a obtenção dos sinais acústicos e, posteriormente, utilizar esses sinais para detecção e classificação de falhas em motores de indução.

Em Lucas *et al.* (2021) é utilizado um transdutor piezoelétrico para sinais acústicos. Neste artigo, a obtenção dos sinais acústicos possibilitou o monitoramento de problemas relacionados ao desbalanceamento de tensões na alimentação do motor. A taxa de acertos obtida foi de 87% a 100% no que diz respeito à existência desses problemas de desbalanceamento.

Em Santos *et al.* (2019) são utilizados dois microfones de uso profissional para a captação da emissão acústica do motor operando sob diversas condições de carga, alimentação e falha. Os dados obtidos foram processados e, a partir disso, realizou-se o diagnóstico da máquina a partir da utilização de Mapas Auto-Organizáveis de Kohonen e *Support Vector Machines* obtendo-se taxas de acerto acima de 99,9%.

A utilização de microfones existentes em aparelhos eletrônicos também é investigada para a obtenção dos sinais acústicos e posterior classificação de falhas em motores de indução (RZESZUCINSKI *et al.*, 2018). Ainda, na linha de captação de emissões acústicas utilizando microfones presentes em aparelhos eletrônicos, pode-se citar o emprego de um gravador de voz para captar os sinais acústicos objetivando a detecção de falhas de rotor, obtendo-se entre 88,19% e 100% de taxa de acertos (GLOWACZ, 2018). Ademais, é possível citar a utilização de um microfone de smartphone para captar os dados de emissão acústica de um motor de indução trifásico para detecção de falhas de rotor, obtendo-se 96,4% de taxa de acertos conforme Vaimann *et al.* (2018) e 98,74% e 99,86% de taxa de acertos em Yaman (2021).

Ainda, há pesquisas que buscam utilizar microfones para captação dos sinais acústicos e posterior classificação de falhas, como é o caso de Veras *et al.* (2019). No referido trabalho os autores utilizaram um microfone embarcado em uma plataforma Arduino® para detecção de problemas de excentricidade em motores CC *brushless*, alcançando 88,34% de taxa de acurácia. Por fim, em Sangeetha e Hemamalini (2019) é proposta a utilização de um microfone MEMS (Sistemas Micro Eletromecânicos)

para obtenção dos dados de emissão acústica de um motor de indução trifásico, e sua posterior utilização para estimação de torque e detecção de falhas do motor.

Observa-se que a utilização de sinais de áudio para identificação e classificação de falhas em motores de indução vêm proporcionando uma boa taxa de acertos nos diagnósticos realizados. Isso faz com que o sinal de áudio se torne uma opção para esse tipo de aplicação. A exemplo dos sensores de corrente, a correta seleção e o correto condicionamento dos sinais provenientes desses sensores são essenciais para que se consiga obter sinais que apresentem as características necessárias para a identificação e a classificação das falhas em motores de indução trifásicos.

3.3 SENSORES DE VIBRAÇÃO

A exemplo do uso de sinais acústicos, o emprego de sinais de vibração também vem sendo amplamente utilizado para obtenção de sinais característicos em motores de indução. Esta é uma estratégia que pode apresentar muitas vantagens, uma vez que, normalmente as falhas apresentadas pelos motores de indução levam a um aumento da vibração da máquina. Além disso, cada falha apresenta frequências específicas de vibração, onde é possível identificar a falha presente no motor. Martinez *et al.* (2017) apresentam uma equação que relaciona a vibração apresentada pelo motor com o número de barras quebradas do rotor.

A utilização de acelerômetros industriais para obtenção dos dados de vibração dos motores de indução é amplamente empregada nas pesquisas envolvendo diagnóstico e classificação de falhas. Gangsar e Tiwari (2017) e Ali *et al.* (2019) utilizam dados de vibração e de corrente de motores de indução para classificação de falhas do mesmo, obtendo taxas de acerto de 93,74% a 96,84% e de 97,6% a 100%, respectivamente. Já em Wang *et al.* (2021) é utilizado um acelerômetro industrial para o diagnóstico de falhas de rolamento, com acurácia de 99,8%. Por fim, em Gnacinski *et al.* (2019), é utilizado um acelerômetro industrial para identificar problemas relacionados a qualidade de energia na alimentação da mesma.

Outro tipo de sensor de vibração utilizado é o acelerômetro MEMS, pois o mesmo apresenta relativo baixo custo quando comparado aos acelerômetros industriais, além de ser amplamente disponível para aquisição. Por ser um sensor desenvolvido para outras aplicações que não a detecção de vibração em máquinas elétricas, se faz

necessário a avaliação da confiabilidade desses sensores para utilização nessa função. Assim, em Son *et al.* (2016) é apresentada uma pesquisa para avaliar a confiabilidade dos acelerômetros MEMS para utilização em classificação de falhas, neste trabalho obteve-se uma taxa de acerto entre 80% e 100%, garantindo que esses sensores são confiáveis para utilização em aplicações envolvendo detecção e classificação de falhas. Em Maruthi e Hegde (2016) é analisada a aplicabilidade de um acelerômetro MEMS para detectar as frequências características de falhas de rolamento. Já em Hegde e Rao (2017) utilizou-se um acelerômetro MEMS para detecção das frequências características de falhas de estator. Por fim, em Pedotti *et al.* (2017) utiliza-se um acelerômetro MEMS para analisar desbalanceamento em máquinas rotativas.

Observa-se que os sinais de vibração podem ser muito úteis para a identificação de falhas em motores de indução. Diversos trabalhos que utilizam sensores de vibração para identificar falhas em motores de indução apresentam uma alta taxa de acurácia no diagnóstico, especialmente quando o defeito está ligado aos rolamentos do motor. Dessa maneira, a exemplo dos sensores de corrente e de áudio, a correta seleção e o correto condicionamento dos sinais provenientes desses sensores são essenciais para que se consiga obter sinais que apresentem as características necessárias para a identificação e a classificação das falhas em motores de indução trifásicos.

3.4 MULTISSENSORIAMENTO

O multissensoriamento consiste na obtenção de sinais dos motores de indução trifásicos com dois ou mais sensores, de modo que os dados coletados destes sensores sejam utilizados na análise das condições de operação do motor de indução. A principal vantagem do multissensoriamento é o fato de que se obtém, simultaneamente, dados de duas ou mais variáveis físicas distintas, a fim de que a detecção e/ou classificação das falhas apresentadas pelos motores de indução trifásicos tenha suporte de mais de uma fonte de dados. A detecção de falhas mecânicas de rolamento, por exemplo, pode usar sinais de corrente e de vibração dos motores. Neste contexto, a análise dos dois sinais torna possível o aumento da precisão no diagnóstico e na classificação dessa falha.

Diversos estudos relacionados à detecção e classificação de falhas em máquinas elétricas utilizam a estratégia de multissensoriamento em suas análises, como é o

caso da utilização de acelerômetros industriais e sensores de corrente para classificação de falhas em motores de indução trifásicos, especialmente falhas associadas ao rotor e ao rolamento (GANGSAR; TIWARI, 2017; ALI *et al.*, 2019). Pode-se também citar o uso de sensores de corrente em conjunto com um sistema de medição do torque exigido pela carga acoplada ao motor para o diagnóstico de falhas associadas ao rolamento da máquina (WANG *et al.*, 2021).

Com respeito a utilização de sensores de microfones e acelerômetros, cita-se o artigo recente de Isavand *et al.* (2020). Neste trabalho são comparados os espectros de frequência dos sinais do microfone e do acelerômetro obtidos a partir de um motor de indução trifásico. Observou-se que as frequências características adquiridas por ambos os sensores foram as mesmas, o que garante que a utilização de sensores com sinais distintos proporciona um diagnóstico mais aprimorado.

Ainda, em Dineva *et al.* (2019) foram utilizados sensores de corrente e de vibração para a classificação de múltiplas falhas relacionadas ao desalinhamento e desbalanceamento do motor, bem como a severidade desse problema. Em Esfahani *et al.* (2014) são utilizados sensores de corrente, vibração e emissão acústica conectados através de uma plataforma de comunicação sem fio. No referido artigo os autores utilizaram a transformada de Hilbert-Huang para os sinais de vibração, corrente e emissão acústica na detecção e classificação de falhas de excentricidade e rolamento. Como resultado da utilização dos 3 sensores foi possível classificar um motor com falha com a precisão 99,9%. Além disso, o sistema distinguiu corretamente entre as categorias de falhas e sua severidade em 95% dos casos.

3.5 SISTEMAS COMERCIAIS DE MONITORAMENTO

Com o advento e a evolução dos métodos de manutenção preditivos tem surgido cada vez mais a necessidade de se utilizar técnicas que sejam capazes de realizar o diagnóstico de falhas em máquinas elétricas, especialmente em motores de indução trifásicos. Com esse intuito, várias empresas têm dedicado tempo e recursos financeiros para o desenvolvimento de sistemas capazes de fazer a identificação das condições do motor que está operando. A grande maioria das empresas utilizam sistemas que medem a vibração das máquinas elétricas, uma vez que, como já mencionado anteriormente, a presença de falhas em um motor de indução poderá apresentar vibração em

frequências específicas, permitindo que seja possível identificar o estado de operação da máquina. A seguir, encontra-se uma tabela com alguns sistemas comerciais de monitoramento de motores elétricos existentes, bem como algumas características apresentada pelos mesmos:

Tabela 1 – Sistemas comerciais para monitoramento de motores elétricos.

Produto	Faixa de frequência (Hz)	Vantagens	Desvantagens
ABB Ability Smart Sensor	10-1000	<ul style="list-style-type: none"> • Aplicável em motores de outras empresas; • Previsão de incluir técnicas de diagnóstico automatizado; • Possui magnetômetro para obter frequência de operação. 	<ul style="list-style-type: none"> • Não é possível substituir bateria
WEG Motor Scan	1-820	<ul style="list-style-type: none"> • Previsão de incluir técnicas de diagnóstico automatizado; • Pequeno e com montagem simplificada; • Aplicável em motores de outras empresas; • Possui magnetômetro para obter frequência de operação. 	<ul style="list-style-type: none"> • Não é possível substituir bateria
Siemens Simotic Connect	-	<ul style="list-style-type: none"> • É possível substituir a bateria; • Possui magnetômetro para obter frequência de operação. 	<ul style="list-style-type: none"> • Aplicável apenas em motores Siemens
Tediasens LN-Series	0,3-10000	<ul style="list-style-type: none"> • Ampla faixa de medição de vibração; • Comunicação sem fio com alcance até 150m. 	<ul style="list-style-type: none"> • Impossibilidade de diagnósticos automáticos
SKF CMWA 8800	10-1000	<ul style="list-style-type: none"> • Possui técnicas para diagnóstico de rolamento. 	<ul style="list-style-type: none"> • Não é possível substituir bateria
AMC Vibro AVS	1-10000	<ul style="list-style-type: none"> • Ampla faixa de medição de vibração; • Comunicação sem fio com alcance até 150m. 	<ul style="list-style-type: none"> • Impossibilidade de diagnósticos automáticos

(continua)

Tabela 1 – Sistemas comerciais para monitoramento de motores elétricos.

(continuação)

Produto	Faixa de frequência (Hz)	Vantagens	Desvantagens
Schaeffler Optime	-	<ul style="list-style-type: none"> • Malha de comunicação entre os sensores. 	-
Monitech JUNDPRED	Até 1000	<ul style="list-style-type: none"> • Baixo consumo; • Sistema prevê a existência de falha. 	<ul style="list-style-type: none"> • Faixa de frequência relativamente pequena
Dynamox	5 - 6000	<ul style="list-style-type: none"> • Ampla faixa de vibração; • Comunicação sem fio; • Facilidade de fixação. 	<ul style="list-style-type: none"> • Necessário equipamento extra para a comunicação entre os sensores
Bluevib	Até 8000	<ul style="list-style-type: none"> • Medição de vibração e temperatura; • Realiza um pré-diagnóstico com os dados obtidos; • Resistente a ambientes com condições extremas. 	-

Autoria própria.

3.6 CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou uma breve revisão sobre os principais sensores utilizados na obtenção de sinais característicos dos motores de indução trifásicos. Observa-se que existem vários sensores que podem ser utilizados na aquisição de dados e posterior diagnóstico do motor.

Deu-se especial atenção a três tipos de sensores, os sensores de corrente, de vibração e de áudio. Pode-se observar que a utilização desses sensores para a classificação de falhas em motores de indução é amplamente empregada tanto em ambientes de pesquisa quanto em produtos disponíveis ao mercado.

4 METODOLOGIA DA PESQUISA

Neste capítulo serão abordados os aspectos utilizados para a realização deste trabalho, levando em consideração os sensores que serão utilizados para a aquisição dos dados, seu processamento e as ferramentas utilizadas para a determinação dos melhores sensores e atributos para utilização na classificação das falhas estudadas.

Conforme explicitado na Seção 1.2, o principal objetivo deste trabalho consiste em realizar o multissensoriamento de um motor de indução trifásico sob diversas condições de carga, alimentação e falhas, a fim de criar um amplo banco de dados de falha em motores de indução trifásico.

A Figura 7, apresentada a seguir, ilustra de maneira simplificada qual abordagem adotou-se no decorrer do trabalho, de modo a obter o banco de dados de falhas, bem como realizar a validação destes dados a partir da determinação dos sensores que apresentaram as melhores respostas para a classificação de determinada falha. As etapas realçadas em vermelho indicam as duas principais contribuições deste trabalho.

Conforme fluxograma apresentado na Figura 7 o trabalho pode ser dividido em 5 partes principais, sendo elas:

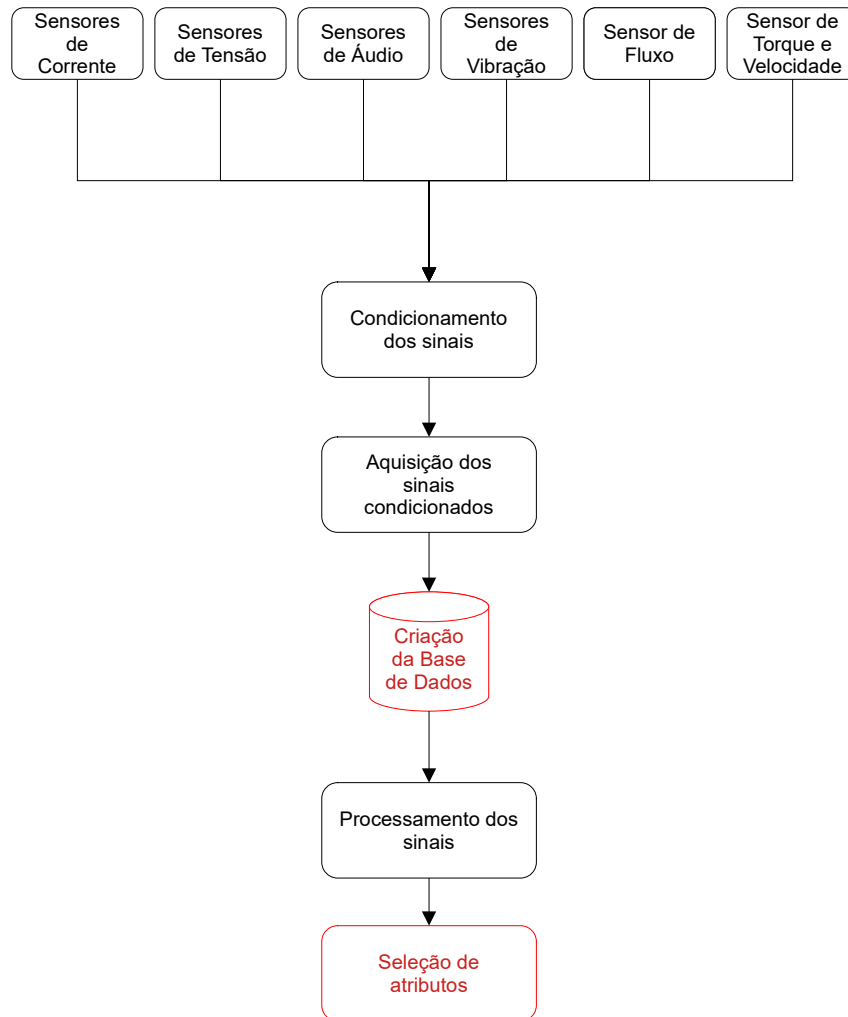
- a) Análise, seleção e acondicionamento dos sensores utilizados;
- b) Condicionamento dos sinais
- c) Aquisição dos sinais condicionados e criação da base de dados;
- d) Processamento dos sinais;
- e) Seleção de atributos.

Para facilitar a explicação das 5 partes do trabalho elencadas acima, cada uma dessas partes será apresentada em uma seção distinta.

4.1 ANÁLISE, SELEÇÃO E ACONDICIONAMENTO DOS SENSORES UTILIZADOS

Para a realização do multissensoriamento optou-se por utilizar sensores de corrente, tensão, vibração, áudio, velocidade, torque e fluxo, sendo este último proveniente do trabalho realizado por Louzada *et al.* (2022). A utilização desses sensores propiciou a obtenção dos dados do motor de indução trifásico sob diversas condições

Figura 7 – Etapas realizadas na realização do trabalho



Fonte: Autoria Própria.

de operação, criando-se uma base de dados ampla, com os sinais do motor medidos por diversos tipos de sensores.

Além disso, um ponto importante a se considerar é que a maioria dos sensores utilizados são de relativo baixo custo. Como exemplo é possível citar os sensores de vibração e áudio utilizados neste trabalho que, em sua maioria, são sensores empregados em aparelhos eletrônicos tais como smartphones, tablets, videogames, entre outros.

Outro ponto importante a se considerar é a variação da resposta dos sensores com a variação da temperatura do motor. Como os sensores utilizados não iriam ficar em contato direto com o motor, a variação de temperatura do motor não influenciará

nos dados obtidos pelos sensores.

Assim, antes de iniciar a coleta de dados do motor de indução trifásico os sensores de vibração e áudio adquiridos foram analisados para verificar se eles apresentam as respostas adequadas para a aquisição de sinais que possibilitem identificar e classificar falhas em motores de indução.

4.1.1 Sensores de áudio e de vibração

Os sensores de vibração e de áudio utilizados neste trabalho são dispositivos que utilizam a tecnologia MEMS, com exceção de um dos sensores de vibração que é um sensor de vibração industrial, que utiliza a tecnologia de cerâmica PZT. A tecnologia MEMS é utilizada para criar pequenos dispositivos integrados ou sistemas que combinam tanto componentes mecânicos quanto componentes elétricos (LAYTON; ADAMS, 2010). A fabricação dos mesmos é similar ao processo realizado para fabricação de circuito integrados (BEEBY, 2004).


4.1.1.1 Sensores de áudio

Os microfones MEMS são transdutores de áudio que utilizam a tecnologia de fabricação de sistemas microeletromecânicos e sua construção é ilustrada na Figura 8. Tais microfones possuem funcionamento similar a um capacitor de placas paralelas, onde uma de suas placas é fixa, enquanto a outra placa é móvel (também conhecida como membrana). A placa fixa é coberta por um eletrodo e contém diversos orifícios que permitem a entrada do som. Com a entrada do ar proveniente do som nos orifícios presentes na placa fixa, a membrana se move de acordo com a pressão sonora, ocasionando a alteração da distância entre as placas fixa e móvel. Assim, Altera-se assim a capacitância entre elas, e conseqüentemente permitindo a captação do áudio pelo microfone (ST, 2017).

A modelagem de um microfone MEMS é complexa e depende de alguns parâmetros construtivos do mesmo. Para maiores detalhes é possível verificar os trabalhos presentes em Honzík *et al.* (2015), Peña-García *et al.* (2018) e Ozdogan *et al.* (2020).

Dentre as opções de sensores de áudio MEMS disponíveis no mercado optou-

Figura 8 – Transdutor de áudio MEMS.



Fonte: Adaptado de ST (2017).

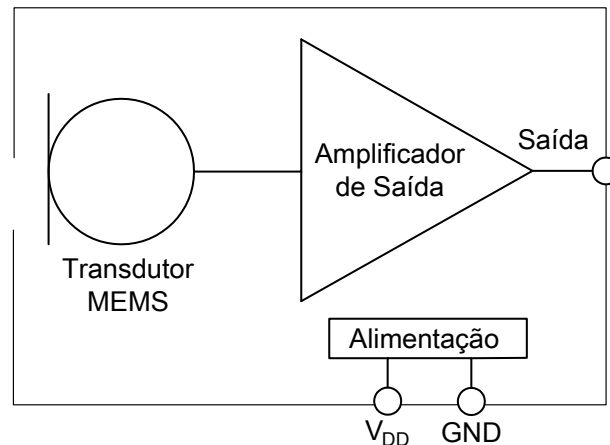
se por utilizar microfones MEMS analógicos. Sua escolha se justifica pela obtenção do sinal acústico o mais puro possível. Dessa maneira, a utilização de microfones com saída digital, seja PDM (do inglês *Pulse Density Modulation*), seja I²S (do inglês, *Inter-IC Sound*), faz com que exista um processamento do sinal sonoro, o que pode provocar alterações nas características desses sinais. As Figura 9, Figura 10 e Figura 11 ilustram o diagrama de microfones MEMS com saída analógica, PDM e I²S respectivamente.

Na Figura 9 observa-se que o sinal de saída do microfone é analógico. Neste tipo de sensor MEMS é possível verificar a existência do transdutor de áudio, responsável pela transformação do sinal de áudio em sinal elétrico. No referido dispositivo consta um estágio de amplificação do sinal, de modo que a saída do sinal do transdutor seja amplificada para tensões entre VDD e GND, que são as tensões de alimentação e referência, respectivamente.

Na Figura 10 observa-se que o sinal de saída do microfone é um sinal PDM. Neste tipo de sensor MEMS é possível verificar, além dos elementos presentes nos sensores analógicos, elementos referentes à digitalização do sinal. Após a amplificação do sinal do transdutor, o sinal de saída do amplificador é amostrado por um conversor analógico digital. Após a conversão, o sinal digital ainda é convertido em pulsos a partir de um modulador PDM. Dessa maneira, a saída de um microfone PDM é um sinal modulado por densidade de pulso, similar a um sinal PWM.

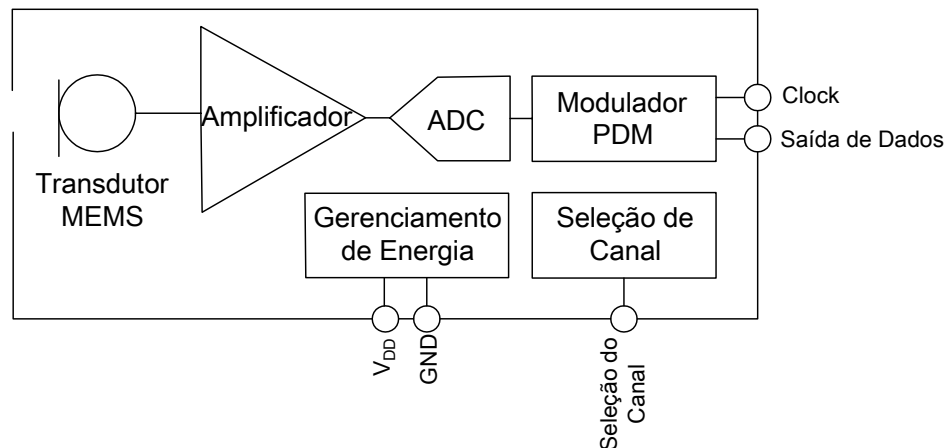
Por fim, na Figura 11 observa-se que o sinal de saída do microfone é um sinal I²S. Neste tipo de sensor MEMS é possível verificar, além dos elementos presentes nos sensores analógicos, elementos referentes à digitalização do sinal, a exemplo do que

Figura 9 – Diagrama de um microfone MEMS com saída analógica.



Fonte: Adaptado de Lewis (2013).

Figura 10 – Diagrama de um microfone MEMS com saída PDM.

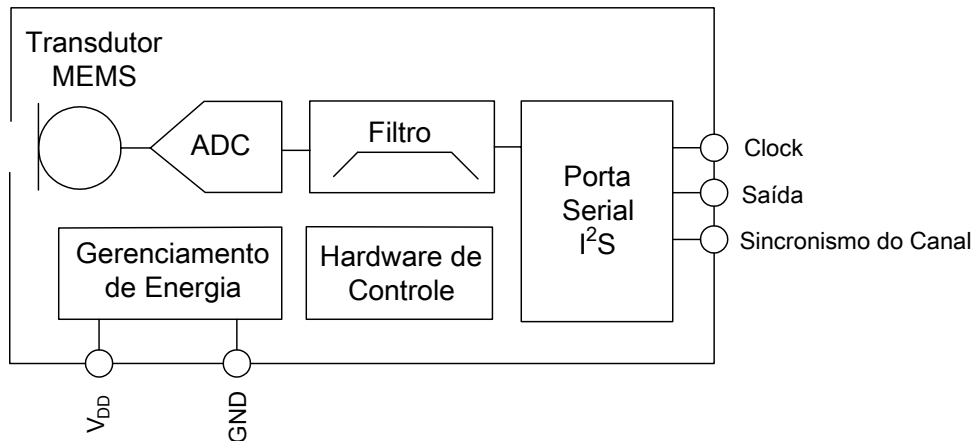


Fonte: Adaptado de Lewis (2013).

acontece nos microfones com saída PDM. Após a amplificação do sinal do transdutor, o sinal de saída do amplificador é amostrado por um conversor analógico digital, sendo filtrado após a digitalização. Dessa maneira, a saída de um microfone I²S é um sinal digital, similar a um sinal SPI ou I²C.

Pode-se observar a partir das Figura 9, Figura 10 e Figura 11 que os microfones MEMS com saídas digitais (PDM e I²S) possuem uma etapa de processamento da informação recebida do transdutor, quantificando os sinais analógicos do transdutor em sinais digitais, sendo que para o microfone com saída I²S ainda existe uma etapa de filtragem do sinal, o que interfere no sinal sonoro captado inicialmente. Dessa maneira, para garantir que o sinal de áudio obtido do sensor possua a menor interferência possível, e também levando em conta os equipamentos disponíveis na etapa de

Figura 11 – Diagrama de um microfone MEMS com saída I²S.



Fonte: Adaptado de Lewis (2013).

aquisição dos dados, optou-se por utilizar microfones MEMS analógicos.


Os microfones MEMS utilizados nesse trabalho são os que seguem:

- a) CMM-2718AT-42308-TR, produzido pelo fabricante CUI Devices;
- b) AMM-3738-B-R, produzido pelo fabricante PUI Audio Inc.;
- c) CMM-2718AB-38308-TR, produzido pelo fabricante CUI Devices;
- d) CMM-3312AT-44308-TR, produzido pelo fabricante CUI Devices;
- e) SPW2430, produzido pelo fabricante Knowles Electronics.

A utilização dos microfones MEMS analógico neste trabalho foi feita em conjunto com um sistema de condicionamento de sinais de modo a permitir que o sinal de saída dos microfones sejam condicionados para faixas de valores que pudessem ser melhor quantizadas pelo sistema de aquisição de dados.

Para a captação dos áudios dos microfones utilizou-se uma caixa para acomodar todos os microfones. Tal caixa foi então instalada acima do motor a ser avaliado, a uma distância de cerca de 30 cm de altura em relação à carcaça do motor. Além disso, a caixa com os microfones ficou posicionada no centro do motor. Para manter a caixa com os microfones na posição correta utilizou-se um pedestal e fixou-se a caixa na extremidade do mesmo. A Figura 12 ilustra os microfones acomodados na caixa, enquanto a Figura 13 ilustra a posição relativa entre os microfones e o motor utilizado nos ensaios.

Figura 12 – Acomodação dos microfones.




Fonte: Autoria própria.

4.1.1.2 Sensores de vibração

Neste trabalho, são utilizados dois sensores de vibração, sendo um sensor de vibração industrial e um acelerômetro MEMS. O sensor de vibração industrial foi utilizado para permitir a comparação futura dos sinais obtidos entre esse e o acelerômetro MEMS. O sensor industrial de vibração utilizado nesse trabalho é PHD-

Figura 13 – Posição dos microfones em relação ao motor.



Fonte: Autoria própria.

SR510A. A Figura 14 ilustra o acelerômetro utilizado nesse trabalho, enquanto a Tabela 2 mostra algumas de suas especificações.

O outro sensor de vibração utilizado é um acelerômetro MEMS. Seu princípio de funcionamento é similar ao microfone MEMS explicado na seção anterior, o qual se baseia na variação da capacitância entre a placa fixa e a placa móvel do sensor. A placa móvel é constituída por uma massa inercial. Assim, a partir do movimento do

Figura 14 – Sensor de Vibração PHD-SR510A.



Fonte: Autoria própria.

Tabela 2 – Características do acelerômetro industrial neste trabalho.

Item	Especificação
Sensibilidade	500 mV/g
Resposta em frequência($\pm 5\%$)	0,9 - 10kHz
Amplitude máxima	$\pm 10g$
Elemento sensitivo	PZT cerâmica

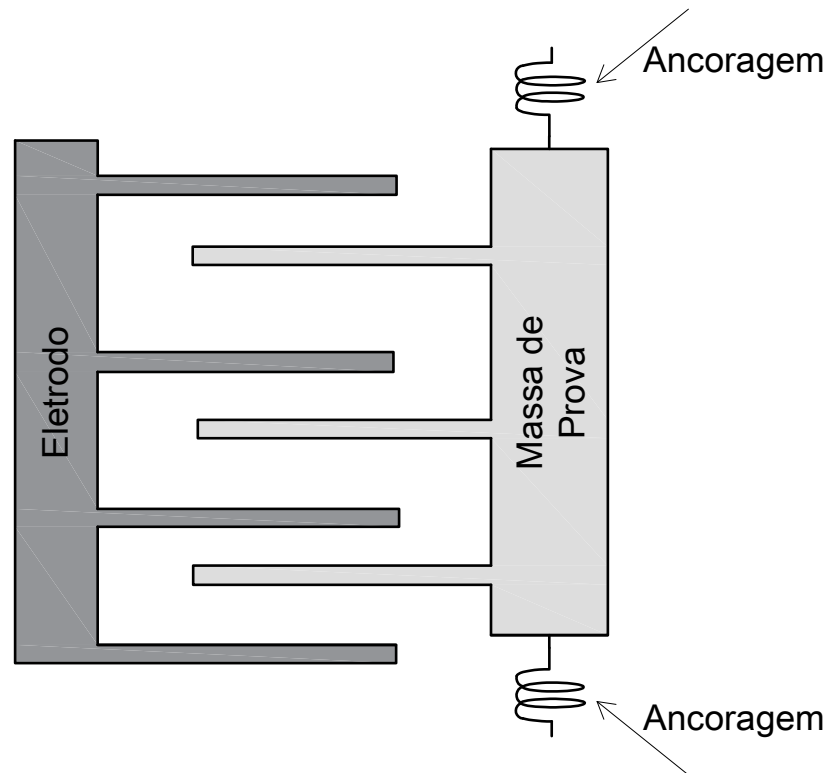
Fonte: PHD (2023).

sensor, existe a alteração da capacitância do mesmo. A Figura 15 ilustra a construção básica de um acelerômetro MEMS.

Para considerações sobre a modelagem do acelerômetro MEMS é possível verificar os trabalhos presentes em Ang *et al.* (2006), Park e Gao (2006), Kannan (2008) e Lyu *et al.* (2021).

Dentre as opções de sensores de vibração MEMS disponíveis no mercado optou-se por utilizar um acelerômetro MEMS analógico, pois a utilização de acelerômetros cuja saída é digital, seja SPI, seja I²C, faz com que exista um processamento

Figura 15 – Construção básica de um acelerômetro MEMS.



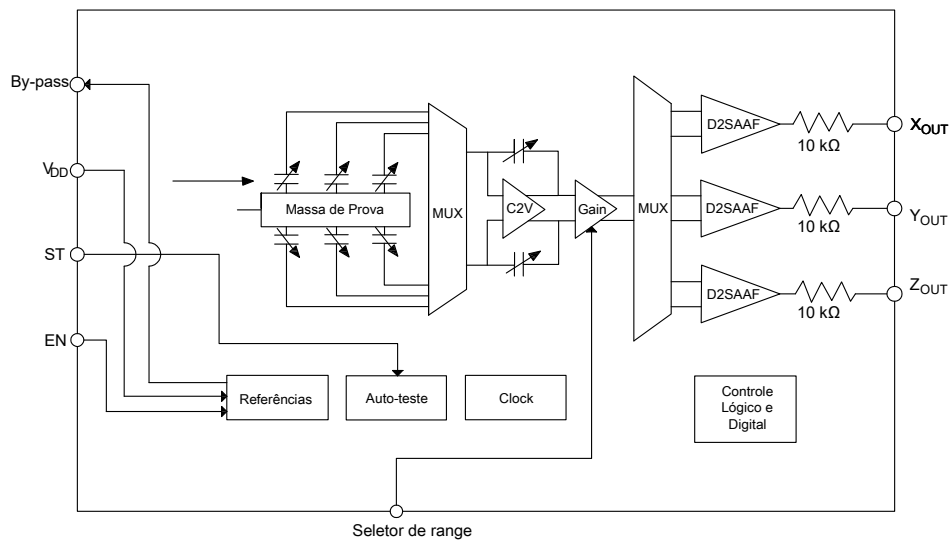
Fonte: Adaptado de Rad (2019).

do sinal de vibração, o que pode provocar alterações nas características desses sinais. Além disso, o sistema de aquisição de dados utilizado de dados não possuía a capacidade de leitura de sinais digitais. A Figura 16 ilustra o diagrama de blocos do acelerômetro usado neste trabalho.

O sensor de vibração utilizado se trata de um acelerômetro FXLN8372Q, produzido pelo fabricante NXP Semiconductors, com as seguintes características:

- Tensão de alimentação: 1,71V a 3,6V;
- Faixa de operação: +/-4g ou +/-16g;
- Consumo de corrente: 180 μ A;
- Largura de banda: 2,7kHz;
- Temperatura de operação: -40°C a 105°C
- Captação de sinais nos 3 eixos (X, Y e Z).

Figura 16 – Diagrama de blocos do acelerômetro analógico que se pretende utilizar no trabalho.



Fonte: Adaptado de FREESCALE (2014).

A exemplo dos microfones, a utilização do acelerômetro MEMS analógico neste trabalho foi feito em conjunto com um sistema de condicionamento de sinais de modo a permitir que o sinal de saída do acelerômetro fosse condicionado para faixas de valores que pudessem ser utilizadas pelo sistema de aquisição de dados, A Figura 17 ilustra o acelerômetro utilizado neste trabalho.


O acelerômetro MEMS utilizado neste trabalho foi inicialmente posicionado em uma caixa, e para garantir que o mesmo não se moveria durante a realização dos ensaios, a caixa com o acelerômetro foi preenchida com uma resina epóxi própria para utilização em circuitos eletrônicos da fabricante Retapol.

Os dois acelerômetros utilizados neste trabalho foram posicionados na tampa do lado do acoplamento do motor, em uma posição de cerca de 15° em relação à vertical. A Figura 18 ilustra as posições dos acelerômetros no motor do ensaio.

4.1.2 Sensores de corrente e de tensão

Neste trabalho, para obtenção dos sinais de corrente e tensão nos terminais de alimentação do motor foram utilizados 3 sensores de corrente e 3 sensores de tensão. Os sensores de corrente foram utilizados para a medição da corrente de linha e os sensores de tensão foram utilizados para a medição das tensões de linha, sendo que

Figura 17 – Acelerômetro FXLN8372Q, produzido pelo fabricante NXP Semiconductors.



Fonte: Autoria própria

as tensões e correntes medidas foram as tensões de alimentação do estator do motor de indução trifásico.


4.1.2.1 Sensor de Corrente

Existem diversas maneiras para medir a corrente de um circuito, sendo que a uma delas consiste na utilização de um Transformador de Corrente (TC). Em linhas gerais um transformador de corrente é um transformador que possui enrolamentos somente em seu secundário, sendo que o seu primário é composto apenas pelo fio do circuito o qual circula a corrente, conforme ilustrado na Figura 19.

A partir da corrente que circula no primário, existe a indução de tensão no secundário do transformador. Normalmente, o secundário do TC é composto por várias espiras, enquanto o primário possui apenas uma espira, assim, existe a diminuição da corrente elétrica proporcionalmente à relação do número de espiras. Dessa maneira, a relação entre a corrente no primário e a corrente no secundário de um TC é definida pela Equação (9).

Figura 18 – Posição dos sensores de vibração no motor.

Caixa com o acelerômetro MEMS



Acelerômetro Industrial


Tampa do lado do
acoplamento do motor

Fonte: Autoria própria

$$\frac{i_1}{i_2} = \frac{N_2}{N_1} \quad (9)$$

onde i_1 é a corrente no primário, i_2 é a corrente no secundário, N_1 é o número de espiras no primário ($N_1 = 1$ para o TC) e N_2 é o número de espiras no secundário.

O sensor de corrente utilizado nesse trabalho é um TC do tipo garra, modelo CCT323047-100-16-00, com as seguintes características (TDK, 2016):

Figura 19 – Transformador de corrente.

Fonte: Autoria Própria.

- Corrente de entrada: 0,1Arms a 100Arms;
- Seção do clamp de corrente: 16mm;
- Relação de transformação: 3000:1;
- Precisão de saída: 33,3mA+/-1% (para 100A);
- Resistência do secundário: 285 Ω ;
- Proteção para circuito aberto: 7,5V.

A Figura 20 ilustra o posicionamento dos transformadores de corrente para medir as correntes de linha que alimentam o motor em que se está realizando o ensaio. A exemplo dos microfones e dos acelerômetros, a utilização do TC neste trabalho foi feita em conjunto com um sistema de condicionamento de sinais. Assim, condicionou-se o sinal de saída do TC para faixas de valores compatíveis com a entrada do sistema de aquisição de dados.

Figura 20 – Posicionamento dos TCs para a medição das correntes de linha.

TC para a fase A

TC para a fase B

TC para a fase C



Fonte: Autoria Própria.

4.1.2.2 Sensor de Tensão

O sensor de tensão utilizado neste trabalho é o transformador de potencial (TP) da fabricante Esteves cuja entrada foi projetada para alimentação em 220V e sua saída fornecer $\pm 3V$.


O funcionamento do TP é similar ao funcionamento do TC exemplificado na Subseção 4.1.2.1. A principal diferença entre os dois tipos de transformadores é que o TP possui enrolamentos com várias espiras tanto no primário quanto no secundário. No caso de um TP, seu lado primário possui mais espiras que o lado do secundário, fazendo com que haja o rebaixamento da tensão para valores adequados a serem usados em equipamentos de medição. A relação entre a tensão do primário e a tensão do secundário de um TP pode ser definida pela Equação (10).

$$\frac{V_1}{V_2} = \frac{N_1}{N_2} \quad (10)$$

onde V_1 é a tensão no primário, V_2 é a tensão no secundário, N_1 é o número de espiras no primário e N_2 é o número de espiras no secundário.

Neste trabalho o TP foi utilizado para a medição das tensões de linha que alimentavam o motor. A Figura 21 ilustra os TPs utilizados neste trabalho.

Figura 21 – TPs utilizados para a medição da tensão de alimentação do motor.



Entradas das Tensões para medição

Fonte: Autoria Própria.

4.1.3 Sensor de Fluxo

Conforme observado no Capítulo 3, uma das formas utilizadas para o sensoria-mento de motores de indução trifásicos consiste na utilização de sensores que medem o fluxo disperso da máquina.

Um motor de indução, assim como qualquer outra máquina eletromecânica, apesar de ser construído com materiais magnéticos de alta permeabilidade, tem-se uma parcela do fluxo magnético produzido pelas bobinas do estator disperso na parte externa da carcaça do motor. Assim, essa parcela do fluxo que não circula no circuito magnético do estator pode ser utilizada para medir as condições de operação do motor.

Neste contexto, o trabalho de Louzada *et al.* (2022) investigou a utilização de um sensor de fluxo de dispersão para determinar falhas de estator em motores de indução. As aquisições dos dados com o sensor de fluxo de dispersão ocorreram no mesmo momento que as aquisições com os sensores desse trabalho. Assim, os dados obtidos pelo sensor de fluxo de dispersão também compõe o banco de dados criado neste trabalho, de modo a fornecer a informação de mais um sensor para o estudo de falhas em motores de indução trifásicos.


O sensor de dispersão foi projeto e confeccionado por Louzada *et al.* (2022), sendo as principais características desse sensor as que seguem:

- Núcleo em forma de "U", com as seguintes especificações
 - Material do núcleo: Grade M4, com laminação de 0,27mm;
 - Comprimento médio do núcleo: 14cm;
 - Área do núcleo: 276,77mm²
- 2 conjuntos de bobinas contendo 600 espiras cada, com as seguintes especificações:
 - Fio utilizado: AWG 39;
 - Resistência das bobinas: 82,7 Ω e 82,4 Ω ;
 - Indutância total com o sensor no motor: 327mH;

A Figura 22 ilustra o sensor de fluxo posicionado na parte central do motor, sendo que uma das extremidades do sensor foi apoiada sobre uma aleta de ventilação

do motor, enquanto a outra extremidade do sensor foi apoiada sobre a placa de identificação do mesmo, além disso, observa-se que para garantir uma melhor fixação do sensor na carcaça do motor foram utilizados tecidos elásticos.

Figura 22 – Sensor de fluxo de dispersão projetado por Louzada *et al.* (2022) posicionado no motor a ser ensaiado




Fonte: Autoria Própria.

4.1.4 Sensor de Torque e Velocidade

Para a medição de torque e da velocidade do motor foi utilizado um torquímetro da fabricante Kistler. Esse torquímetro é acoplado ao eixo da máquina e consegue, a partir da utilização de extensômetros, medir o torção no eixo do sensor, e assim determinar o torque mecânico o qual o motor está sujeito durante o ensaio. A Figura 23 ilustra o princípio de funcionamento do torquímetro utilizado. A seguir encontram-se algumas especificações do torquímetro utilizado neste trabalho:

- Faixa de torque: 0-50Nm;
- Sinal de saída: 0 - 5V;
- Acurácia: 0,2Nm;
- Número de pulsos do encoder: 360 pulsos por volta;
- Velocidade máxima: 12000 rpm.

Figura 23 – Esquema de funcionamento do torquímetro.



Fonte: Autoria Própria.

Observa-se pela Figura 23 que o torquímetro Kistler possui saídas analógicas para o envio das informações de torque e de velocidade. Neste trabalho utilizou-se a saída do torquímetro em conjunto com um sistema de condicionamento de sinais que será mostrado na Seção 4.2.

4.2 CONDICIONAMENTO DOS SINAIS

Neste trabalho, todos os sinais provenientes dos sensores são analógicos. No entanto, cada sensor envia seu sinal com uma amplitude específica, sendo necessária a realização do condicionamento dos sinais provenientes dos sensores para, então, enviar esses sinais para o sistema de aquisição de dados utilizado. Nesta seção, serão apresentadas as características dos sistemas de condicionamento de sinais para cada tipo de sensor. Na maioria dos sensores o condicionamento dos sinais se resume apenas à aplicação de um ganho no sinal.


4.2.1 Condicionamento dos sinais de áudio

O sinais de áudio provenientes dos sensores de áudio MEMS utilizados neste trabalho são sinais que possuem valores entre 0 e 3,3V, devido à alimentação desses dispositivos. No entanto, os sensores utilizados neste trabalho foram comprados já montados em uma placa de avaliação que possui, em cada saída do sensor, um capacitor, fazendo, assim, com que a componente CC do sinal do sensor seja filtrada.

Dessa maneira, a saída obtida é uma saída em tensão alternada que varia de acordo com as características do sinal que está sendo medido.

Para os sensores de áudio, considerando que a saída disponível é alternada, conforme explicado anteriormente, o condicionamento dos sinais desses sensores funciona com a aplicação de um ganho no sinal fornecido pelos sensores. A Figura 24 mostra a placa de condicionamento de sinais para os sensores de áudio, e seu esquemático pode ser obtido no Apêndice A.

Figura 24 – Placa de condicionamento de sinais para os sensores de áudio.



Sinal de Entrada e Alimentação do sensor

Fonte: Autoria Própria.

A placa de condicionamento dos sinais de áudio é composta por um circuito de ganho com o uso do amplificador operacional TL072, o uso desse amplificador operacional se justifica devido à sua boa resposta e disponibilidade para aquisição. O ganho utilizado para os sinais de áudio foi de 100 vezes. Tal ganho se justifica pois os sinais de áudio provenientes dos sensores apresentam baixa amplitude, o que afetaria a resolução dos sinais no momento da aquisição, além disso, esse ganho garante que o sinal não sofrerá distorções no processo de amplificação utilizando o amplificador selecionado. Nesta placa ainda está presente um conector para a alimentação do amplificador operacional ($\pm 15V$) e do sensor (3,3V), a entrada do sinal do sensor,

a saída de alimentação para o sensor, bem como a saída condicionada do sinal do sensor.

Para diminuir os ruídos nos sinais dos sensores de áudio, utilizou-se cabos blindados desde a saída dos sensores até a entrada do sinal na placa de condicionamento. Também foram utilizados cabos blindados da saída do condicionamento até a entrada do sistema de aquisição.

4.2.2 Condicionamento dos sinais de vibração

Os sinais de vibração provenientes do sensor industrial utilizado neste trabalho foram condicionados a partir de um sistema de aquisição comercial, o MTN/8066 g-mac, que permite com que o sinal de vibração condicionado apresente sinais de grande amplitude a partir de altas frequências de vibração no motor (MONITRAN, 2023). A Figura 25 ilustra o sistema de condicionamento de sinais do sensor de vibração industrial.

Figura 25 – Sistema de condicionamento de sinais do sensor de vibração industrial




Fonte: Aatoria Própria.

Por outro lado, os sinais de vibração provenientes do acelerômetro MEMS utilizado neste trabalho, a exemplo dos sinais de áudio, são sinais que possuem valores entre 0 e 3,3V, devido à alimentação desses sensores. Assim como os sensores de áudio, a placa em que está soldado o acelerômetro MEMS possui capacitores em sua saída, filtrando a componente em corrente contínua do sinal.

Assim como para os sensores de áudio, para o acelerômetro MEMS aplicou-se o ganho de 100 vezes. A Figura 26 mostra a placa de condicionamento de sinais para

o acelerômetro MEMS, e seu esquemático pode ser obtido no Apêndice B.

Figura 26 – Placa de condicionamento de sinais para o acelerômetro MEMS.



Fonte: Autoria Própria.

A placa de condicionamento dos sinais do acelerômetro MEMS é composta por um circuito de ganho com o uso de amplificador operacional cujo modelo é o TL074 da fabricante Texas Instruments, por um conector para a alimentação da placa ($\pm 15V$), a saída de alimentação para o sensor, as saídas condicionadas dos sinais do sensor nos 3 eixos, a entrada dos sinais do sensor nos 3 eixos, bem como a configuração do sensor. A configuração do sensor se faz necessária para selecionar o modo de operação do sensor, a saber:

- Pino de auto-teste do sensor: Configurado para nível lógico baixo (permite que o sensor opere normalmente);
- Pino de habilitação: Configurado para nível lógico alto (permite que o sensor opere normalmente);
- Pino de seleção da amplitude do sinal: Configurado para nível lógico baixo (amplitude do sinal configurada para $\pm 16g$).

Assim como ocorreu com os sensores de áudio, para o acelerômetro MEMS forem utilizados cabos blindados da saída do sensor até a entrada da placa de condicionamento e da saída placa de condicionamento até a entrada da placa de aquisição.

4.2.3 Condicionamento dos sinais de corrente e de tensão

Os sinais de corrente e de tensão provenientes dos TCs e TPs, respectivamente, são sinais alternados que, a exemplo dos sinais de áudio e do acelerômetro MEMS passam por um processo de ganho.


Para os TCs, antes do sinal receber um ganho, é necessário converter a saída de corrente proveniente do sensor em tensão. Para isso, utilizou-se um resistor shunt. O valor do resistor shunt foi definido de acordo com o valor máximo da tensão da proteção para o circuito aberto, que é de 7,5V, conforme Subseção 4.1.2.1. Dessa maneira, considerando a saída máxima de 33mA (saída quando há 100A no primário do TC), utilizou-se um resistor shunt de 220Ω .

Após a conversão da corrente de saída do TC em tensão por meio do resistor shunt, o sinal é amplificado. Considerando que os motores utilizados nos ensaios são de pequeno porte (1CV e 2CV), pode-se afirmar que a máxima corrente de linha para esses motores, considerando condições nominais de operação, será de 8,42A. Dessa maneira, determinou-se que o ganho razoável para a placa de condicionamento do sinal dos sensores de corrente fosse de 6,7 vezes, uma vez que esse ganho garante que o sinal de corrente condicionado esteja dentro da faixa de entrada do sistema de aquisição ($\pm 10V$). A Figura 27 mostra a placa de condicionamento dos sinais de corrente, e seu esquemático pode ser obtido no Apêndice C.

Para os TPs, como a saída já é em tensão, não é necessária nenhuma conversão, apenas a aplicação do ganho. Considerando que quando alimentado com 220V o TP fornecerá uma tensão de pico de cerca de 4,25V no secundário do transformador, determinou-se que o ganho razoável para a placa de condicionamento do sinal dos sensores de tensão fosse de 1,8 vezes, uma vez que esse ganho garante que o sinal de corrente condicionado esteja dentro da faixa de entrada do sistema de aquisição ($\pm 10V$). A Figura 28 mostra a placa de condicionamento de sinais de tensão, e seu esquemático pode ser obtido no Apêndice D.


Com os sinais de corrente e de tensão condicionados, foram utilizados cabos

Figura 27 – Placa de condicionamento de sinais para os TCs.



Fonte: Autoria Própria.

Figura 28 – Placa de condicionamento de sinais para os TPs.



Fonte: Autoria Própria.

blindados para a conexão da saída da placa de condicionamento até a entrada da placa de aquisição dos sinais.

4.2.4 Condicionamento dos sinais de torque e velocidade

Conforme explicitado na Subseção 4.1.4, o torquímetro utilizado neste trabalho fornece tanto os dados de torque, quanto os dados de velocidade. Tais dados são fornecidas a partir de sinais analógicos. Os sinais provenientes do torquímetro são enviados para um sistema de condicionamento, o CoMo Torque Tipo 4700, do fabricante Kistler, que fornece um ganho a esse sinal de acordo com a configuração do mesmo. Para o sinal de Torque, o ganho no sinal é de 0,5V/Nm, enquanto que para o sinal de velocidade o ganho aplicado é de 2mV/rpm. A Figura 29 mostra o sistema de condicionamento de sinais do torquímetro.

Figura 29 – Sistema de condicionamento de sinais para o torquímetro.



Fonte: Autoria Própria.

4.3 AQUISIÇÃO DOS DADOS E CRIAÇÃO DA BASE DE DADOS

Nesta seção, serão apresentados as ferramentas e metodologias adotadas para a criação do banco de dados proposto neste trabalho. Inicialmente serão apresentados algumas características do sistema de aquisição de dados, bem como dos motores utilizados para a realização dos ensaios. Nas subseções seguintes serão apresentados os processos utilizados para a inserção de falhas nos motores. E, por fim, será apresentado o sistema de *tags* utilizado no banco de dados para que seja

possível identificar a qual ensaio determinado conjunto de dados pertence.

4.3.1 Características do Sistema de Aquisição

O sistema de aquisição de dados utilizado neste trabalho é composto por duas placas de aquisição de dados da National Instruments. Os modelos utilizados foram os seguintes:

- NI USB-6210;
- NI USB-6221;

Ambas as placas de aquisição possuem as seguintes características:

- Máximo de 16 entradas digitais;
- Resolução de 16 bits;
- Taxa de Amostragem total de 250 mil amostras por segundo;
- Faixa de tensão de aquisição de $\pm 10V$.

A placa NI USB-6210 foi utilizada para a aquisição dos seguintes sinais provenientes dos sensores utilizados:

1. Fluxo;
2. Corrente na fase A;
3. Corrente na fase B;
4. Corrente na fase C;
5. Tensão entre A e B;
6. Tensão entre B e C;
7. Tensão entre C e A;
8. Vibração no eixo X;
9. Vibração no eixo Y;


10. Vibração no eixo Z;
11. Vibração do sensor industrial;
12. Torque;
13. Velocidade.

Já a placa NI USB-6221 foi utilizada para a aquisição dos seguintes sinais provenientes dos sensores utilizados:

1. Emissão acústica do sensor de áudio 1 (CMM-2718AT-42308-TR);
2. Emissão acústica do sensor de áudio 2 (AMM-3738-B-R);
3. Emissão acústica do sensor de áudio 3 (CMM-2718AB-38308-TR);
4. Emissão acústica do sensor de áudio 4 (CMM-3312AT-44308-TR);
5. Emissão acústica do sensor de áudio 5 (SPW2430).


As Figura 30 e Figura 31 ilustram, respectivamente, as conexões realizadas nos terminais de entradas das placas de aquisição NI USB-6210 e NI USB-6221.

Figura 30 – Conexões nos terminais da placa NI USB-6210.



Fonte: Autoria Própria.

Figura 31 – Conexões nos terminais da placa NI USB-6221.



Fonte: Autoria Própria.

Para a placa NI USB-6210 a frequência de amostragem dos sinais utilizada foi de 16kHz, enquanto que para a placa NI USB-6221 a frequência de amostragem utilizada foi de 50kHz. A Tabela 3 mostra o resumo das taxas de aquisição utilizadas para cada tipo de sensor.

Tabela 3 – Resumo das taxas de aquisição para cada tipo de sensor utilizado.

Tipo de sensor	Taxa de aquisição
Vibração	16kHz
Tensão	16kHz
Corrente	16kHz
Áudio	50kHz
Fluxo	16kHz
Velocidade	16kHz
Torque	16kHz

Fonte: Autoria própria.

4.3.2 Características dos Motores Utilizados no Ensaio

Os motores utilizados nos ensaios realizados nesse trabalho são motores de 1CV e 2CV da fabricante WEG. Algumas características desses motores são apresentados na Tabela 4. É importante ressaltar que os motores em questão foram utilizados para a inserção das falhas estudadas neste trabalho.

Tabela 4 – Características dos motores utilizados neste trabalho.

Item	Motor	
Potência nominal	2CV	1CV
Torque nominal	8,02Nm	4,05Nm
Modelo	W22 Plus	W22 Plus
Tipo de Carcaça	90S	80
Tensão de alimentação	220/380 V	220/380 V
Corrente nominal	5,98/3,46 A	3,02/1,75 A
Velocidade nominal	1750 rpm	1730 rpm
Frequência nominal	60 Hz	60 Hz
Relação entre a corrente de partida e a corrente nominal	7,1	6,6
Fator de potência	0,78	0,81
Rendimento	84,20%	80,5%
Classe de isolamento	F	F
Rolamento do lado do acoplamento	6205	6204

Fonte: Autoria própria.

4.3.3 Processo de inserção das falhas

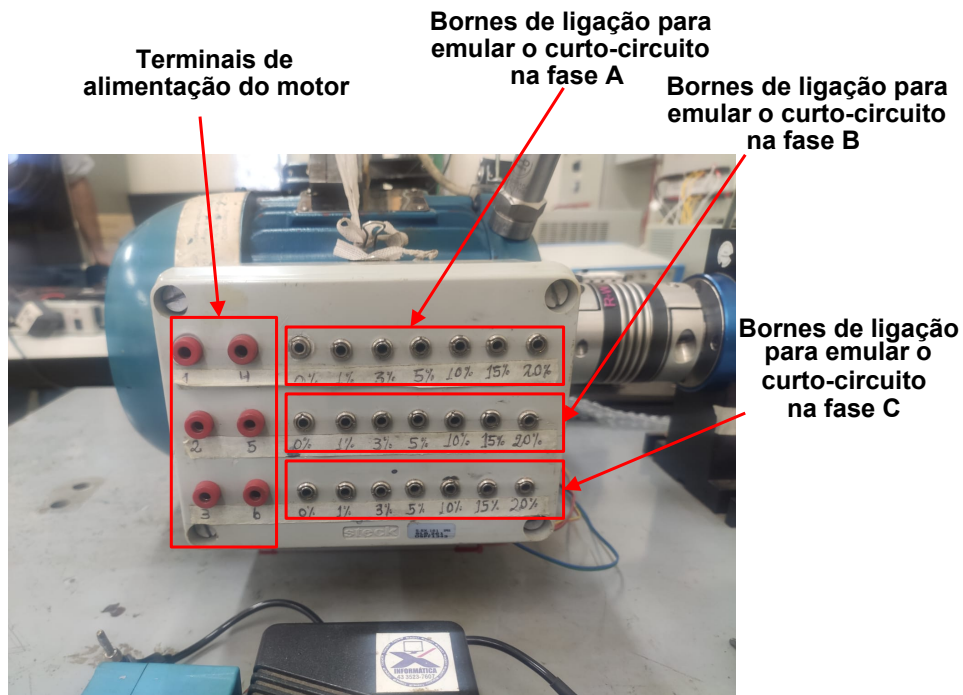
Nesta seção, serão apresentados os procedimentos utilizados para a emulação das falhas de estator, rotor e rolamento nos motores de indução utilizados neste trabalho.

4.3.3.1 Emulação da falha de curto-circuito de estator

A emulação da falha de curto-circuito de estator foi possível a partir do processo de rebobinamento dos motores que compõe esse estudo. Durante o processo de rebobinamento, a cada intervalo definido pela porcentagem de bobinas em cada fase foi realizado uma conexão de derivação, permitindo que em cada conexão de derivação ficasse disponível uma porcentagem das bobinas de cada fase para que se realizasse o curto-circuito. Para os motores utilizados nesse trabalho, as porcentagens de curto-circuito emuladas foram: a) 1%; b) 3%; c) 5%; d) 10%.

Cada derivação realizada nas bobinas foi disponibilizada por meio de bornes de conexão em uma caixa externa aos motores, conforme Figura 32, de modo a permitir que a seleção do curto-circuito desejado fosse realizado através da ligação de conectores.

Figura 32 – Caixa de ligação do curto-circuito.



Fonte: Autoria Própria.


4.3.3.2 Emulação da falha de barra quebrada de rotor

A emulação da falha de barras quebradas de rotor foi realizada com a utilização de uma furadeira, de modo a fazer um furo na barra, ou nas barras, a que se pretendia danificar, emulando dessa maneira a falha de barra quebrada. As condições de barras quebradas de rotor utilizados nesse trabalho foram:

- a) 1 barra quebrada;
- b) 2 barras quebradas consecutivas;
- c) 2/2 barras quebradas (2 barras quebradas diametralmente opostas em relação a outras 2 barras quebradas);
- d) 4 barras quebradas consecutivas;

As Figura 33(a), Figura 33(b), Figura 33(c) e Figura 33(d) ilustram respectivamente o rotor com 1 barra quebrada, 2 barras quebradas, 2/2 barras quebradas e 4 barras quebradas.

Figura 33 – Rotores com emulação de barras quebradas.



Fonte: Autoria Própria.

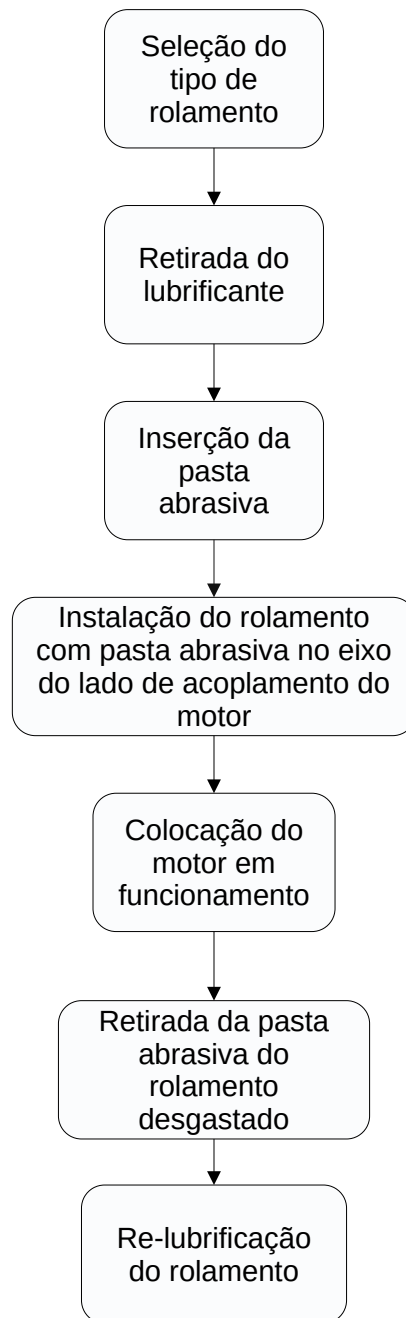
4.3.3.3 Emulação da falha de desgaste de rolamento

A emulação das falhas de desgaste de rolamento foi possível a partir do processo ilustrado na Figura 34. O desgaste foi realizado no rolamento do lado do acoplamento, pois este, em situações de operação normais, tende a ser o rolamento que está mais sujeito às ações de desgaste.

Observa-se nesse fluxograma que o processo de desgaste teve as seguintes etapas:

- a) Seleção do tipo de rolamento: Para este trabalho, considerando que o rolamento seria desgastado, e portanto desmontado no processo, optou-se por utilizar rolamentos com capas do tipo DDU, pois estas capas podem ser retiradas com certa facilidade. A Figura 35 ilustra um dos rolamentos sem a capa de proteção utilizado neste trabalho;
- b) Retirada do lubrificante original do rolamento: Antes de iniciar os processo de desgaste, para garantir o desgaste das pistas, foi retirado completamente

Figura 34 – Fluxograma utilizado para o desgaste dos rolamentos.



Fonte: Autoria própria.

o lubrificante original do rolamento, conforme Figura 36;

- c) Inserção de pasta abrasiva: A inserção de pasta abrasiva nos rolamentos foi a opção escolhida para que se realizasse o desgaste do rolamento. A pasta abrasiva utilizada foi uma pasta abrasiva fina composta de carbureto de silício e óxido de alumínio, pasta essa tipicamente utilizada para o esmerilhamento de válvulas da fabricante Vonder. A quantidade de pasta

abrasiva inserida em cada rolamento foi de 2 gramas para o rolamento 6204 (rolamento utilizado no lado do acoplamento do motor de 1CV) e de 3 gramas para o rolamento 6205 (rolamento utilizado no lado do acoplamento do motor de 2CV). A Figura 37 ilustra um dos rolamento utilizados neste trabalho com a pasta abrasiva inserida;

- d) Instalação do rolamento no eixo de acoplamento do motor: Com o rolamento com a pasta abrasiva no lugar do lubrificante, instalou-se o mesmo no rotor do motor e marcou-se a posição de 6h do mesmo (posição sujeita à aplicação da força normal, ou seja, a posição sujeita ao maior esforço entre a pista externa do rolamento e a tampa do motor). Essa marcação se deve ao fato de que é a posição que sofre mais ação da carga, uma vez que é a posição de maior apoio do rolamento devido à força da gravidade que é exercida sobre essa posição;
- e) Colocação do motor em funcionamento: O rolamento com a pasta abrasiva foi instalado no motor e colocou-se o mesmo em funcionamento. O tempo de funcionamento do motor com rolamento com pasta abrasiva variou da seguinte maneira: a) 15 minutos; b) 30 minutos; c) 60 minutos; d) 90 minutos;
- f) Retirada do rolamento e da pasta abrasiva: Com a realização do desgaste pelo tempo determinado realizou-se a retirada do rolamento desgastado do motor com a utilização de uma ferramenta denominada saca-polia, bem como retirou-se totalmente a pasta abrasiva do rolamento;
- g) Re-lubrificação do rolamento: Após a total retirada da pasta abrasiva do rolamento foi inserido novamente o lubrificante no mesmo.

4.3.4 Ensaios Realizados

Nessa seção serão apresentados as condições definidas para os ensaios, bem como os procedimentos utilizados para aquisição dos dados de cada uma das falhas.

Inicialmente se faz necessário a alimentação à qual os motores serão submetidos. A alimentação deve ser condizente com aquela encontrada em ambiente industrial. Para isso, utilizou-se como referência as diretrizes preconizadas pelo módulo 8 da resolução normativa ANEEL nº 956, que trata da qualidade do fornecimento de energia

Figura 35 – Rolamento sem a capa de proteção.



Fonte: Autoria Própria.

Figura 36 – Rolamento sem lubrificação.



Fonte: Autoria Própria.

elétrica (ANEEL, 2021).

Segundo ANEEL (2021), considerando como referência os pontos de conexão de fornecimento com tensão entre fase e neutro de 127V, as tensões de fornecimento nesse ponto podem ser classificadas conforme ilustrado na Tabela 5.

Dessa maneira, seguindo as referências constantes em ANEEL (2021), em

Figura 37 – Rolamento com pasta abrasiva.



Fonte: Autoria Própria.

Tabela 5 – Faixas de tensões de atendimento para sistemas 220V/127V.

Tensão de Atendimento	Faixa de Variação da Tensão de Leitura (TL)
Adequada	$117V \leq TL \leq 133V$
Precária	$110V \leq TL < 117V$ ou $133V < TL \leq 135V$
Crítica	$TL < 110V$ ou $TL > 135V$

Fonte: Adaptado de ANEEL (2021).

ABNT (2018) e também considerando a metodologia adotada em diversos trabalhos realizados dentro do Laboratório de Sistemas Inteligentes (LSI), dentre os quais pode-se citar os trabalhos de Bazan *et al.* (2017), Bazan *et al.* (2019a), Bazan (2020), Bazan *et al.* (2022), Godoy *et al.* (2015), Godoy *et al.* (2016), Godoy *et al.* (2020), Gongora *et al.* (2016), Palácios *et al.* (2015), Palácios *et al.* (2016) e Palácios *et al.* (2017), as faixas de tensão de alimentação por fase que foram utilizadas para os ensaios deste presente trabalho foram:

- a) Alimentação equilibrada;
- b) Sobretensão de 2% na fase A;
- c) Sobretensão de 4% na fase A;
- d) Sobretensão de 6% na fase A;
- e) Sobretensão de 8% na fase A;

- f) Sobretensão de 10% na fase A;
- g) Sobretensão de 2% na fase B e subtensão de 2% na fase C;
- h) Sobretensão de 4% na fase B e subtensão de 4% na fase C;
- i) Sobretensão de 6% na fase B e subtensão de 6% na fase C;
- j) Sobretensão de 8% na fase B e subtensão de 8% na fase C;
- k) Sobretensão de 10% na fase B e subtensão de 10% na fase C;


Para o ajuste das condições de alimentação do motor que está sendo ensaiado fez-se uso de um painel contendo 3 autotransformadores variáveis (Variacs), sendo que cada um desses dispositivos é responsável por controlar a tensão de alimentação de cada uma das fases do sistema. A Figura 38 mostra o painel de alimentação utilizado para configurar as tensões de alimentação.

Após a definição das condições de alimentação, definiu-se as condições de carga impostas a cada motor. As cargas que foram impostas para cada motor foram definidas considerando, entre outros aspectos, o torque nominal de cada motor, conforme utilizado nos trabalhos de Bazan *et al.* (2017), Bazan *et al.* (2019a), Bazan (2020), Bazan *et al.* (2022), Godoy *et al.* (2015), Godoy *et al.* (2016), Godoy *et al.* (2020), Gongora *et al.* (2016), Palácios *et al.* (2015), Palácios *et al.* (2016) e Palácios *et al.* (2017), as valores de torque utilizados para os ensaios foram os que seguem:

a) Motor de 1CV:

- 0,5 Nm (condição de operação a vazio);
- 1 Nm;
- 1,5 Nm;
- 2 Nm;
- 2,5 Nm;
- 3 Nm;
- 3,5 Nm;
- 4 Nm (condição de torque nominal);
- 4,5 Nm;
- 5 Nm.

Figura 38 – Painel de alimentação.



Fonte: Autoria Própria.

b) Motor de 2CV:

- 0,5 Nm (condição de operação a vazio);
- 1 Nm;
- 2 Nm;
- 3 Nm;

- 4 Nm;
- 5 Nm;
- 6 Nm;
- 7 Nm;
- 8 Nm (condição de torque nominal);
- 9 Nm.

4.3.4.1 Curto-circuito de Estator

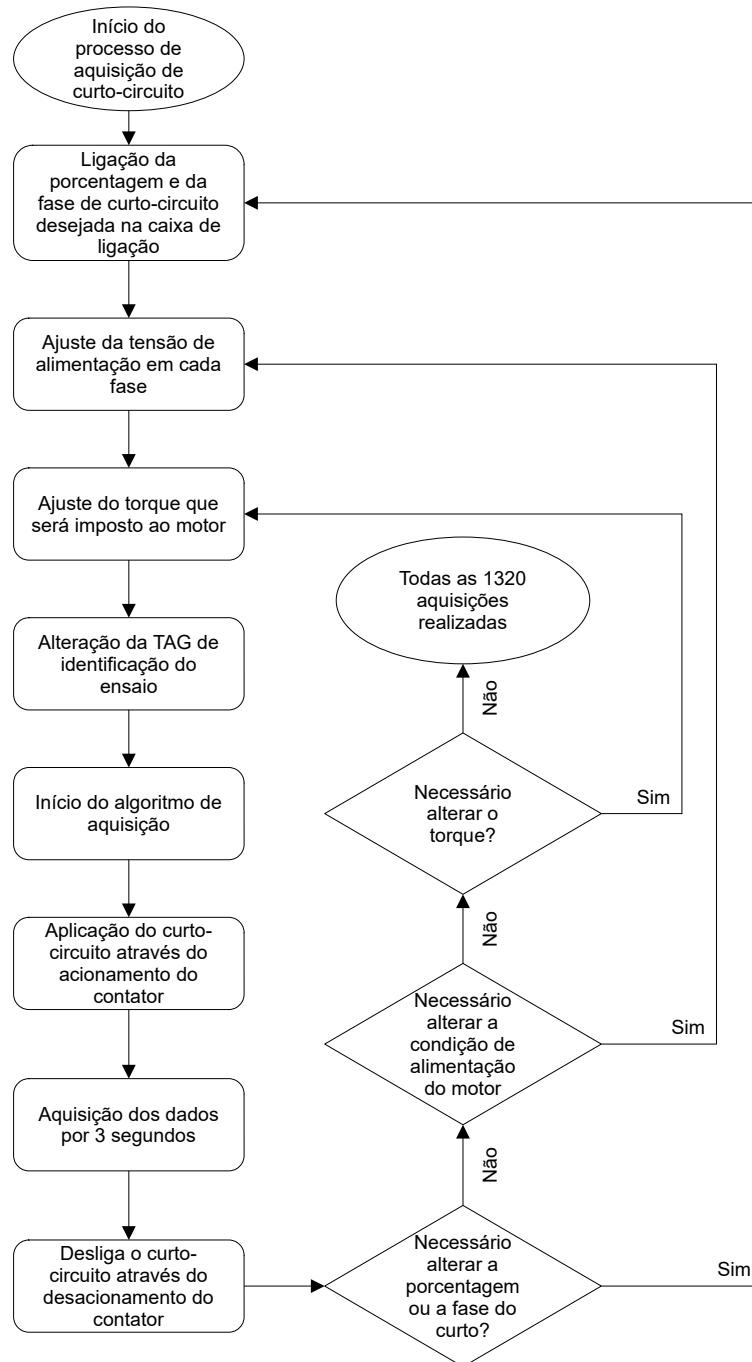
Nesta seção, será explicada a metodologia utilizada para a obtenção dos dados de curto-circuito de estator para cada um dos motores. A Figura 39 apresenta o fluxograma simplificado do processo de aquisição dos dados de curto-circuito.

Analisando-se o exposto no fluxograma da Figura 39 observa-se que inicialmente é necessário definir qual o nível de curto circuito bem como em qual fase será aplicado o curto circuito na máquina. A partir disso, faz-se a ligação do curto-circuito na caixa de ligação disponível na máquina conforme ilustrado na Figura 32. Um dos conectores da ligação do curto-circuito é inserido na posição de 0%, enquanto o outro conector é inserido na porcentagem de curto a que se deseja aplicar no motor. Cada linha da caixa de ligação representa as porcentagens de curto-circuito disponíveis em cada fase da máquina (A, B e C), sendo que é imprescindível inserir os dois conectores sempre na mesma linha. Caso os conectores sejam inseridos em linhas diferentes, ocorrerá um curto-circuito entre as fases do estator, o que levaria à ocorrência de uma elevada corrente no curto-circuito, queimando as bobinas presentes nesse curto. Nas Figura 40(a), Figura 40(b) e Figura 40(c) são ilustradas a ligação de um curto-circuito de 5% nas fases A, B e C respectivamente.

Após a realização do curto-circuito na caixa de ligação é necessário ajustar as tensões de fase que alimentarão a máquina conforme as regras definidas na Subseção 4.3.4.

Após o ajuste da tensão, altera-se o torque imposto ao motor a partir da mudança da tensão de alimentação do enrolamento de campo da máquina de corrente contínua acoplada ao motor. Os torques impostos a cada um dos motores deste estudo estão mostrados na Subseção 4.3.4.

Figura 39 – Fluxograma do processo de aquisição de dados para curto-circuito de estator




Fonte: Autoria Própria.


Após o ajuste das tensões de alimentação do motor e do torque de carga imposto ao mesmo, altera-se a TAG de identificação do ensaio de modo a garantir que cada ensaio tenha sua TAG específica de acordo com a definição das TAGs explicada na Subseção 4.3.5.

Com todos os passos acima realizados, inicia-se a aquisição de dados a partir


Figura 40 – Rotores com emulação de barras quebradas.



(a) Curto-circuito de 5% aplicado na fase A.



(b) Curto-circuito de 5% aplicado na fase B.



(c) Curto-circuito de 5% aplicado na fase C.

Fonte: Autoria Própria.

da colocação em funcionamento do algoritmo de coleta. O algoritmo de coleta, quando iniciado, faz com que a placa de aquisição NI-USB6210 envie um sinal digital de nível alto para um relé que faz com que o contator acione, iniciando o curto-circuito. Para garantir que o curto-circuito está de fato ocorrendo, definiu-se um tempo de espera de 500ms, tempo esse suficiente para garantir que o curto-circuito está de fato sendo aplicado ao motor ensaiado.

Após o tempo de espera é iniciada a aquisição dos dados condicionados dos sensores por intermédio das placas NI-USB6210 e NI-USB6121. A aquisição tem o tempo de duração total de 3 segundos. Como as placas de aquisição utilizadas foram configuradas para trabalhar com taxas de aquisição diferentes (16kHz e 50kHz), os dados obtidos são guardados em duas variáveis diferentes. Essas variáveis são salvas em um arquivo que tenha como nome a TAG definida para o ensaio que está sendo realizado.

Após a aquisição dos dados é definida uma nova pausa de 500ms para desligar o contator que promove o curto-circuito. Essa pausa foi inserida pois garante que toda

a aquisição de dados estava completa antes do curto-circuito ser desligado.

Após esse processo deve-se verificar a necessidade de alterar a porcentagem ou a fase do curto-circuito. Em caso negativo (ainda não foram realizados os 110 ensaios previstos para a condição atual), verificam-se quais as condições de operação da máquina (tensões de alimentação e torque de carga) deverão ser alteradas.

Os ensaios de curto-circuito de estator são encerrados se todos os ensaios previstos forem realizados, o que totaliza 1320 ensaios. Os 1320 ensaios de curto-circuito de estator são justificados pois para cada fase foram realizados 440 ensaios de curto-circuito (110 ensaios para o curto-circuito de 1%, 110 ensaios para o curto-circuito de 3%, 110 ensaios para o curto-circuito de 5% e 110 ensaios para o curto-circuito de 10%).

4.3.4.2 Barra Quebrada de Rotor

Nesta seção, será explicada a metodologia utilizada para a obtenção dos dados de barras quebradas de rotor para cada um dos motores. A Figura 41 ilustra o fluxograma simplificado do processo de aquisição dos dados de barras quebradas.

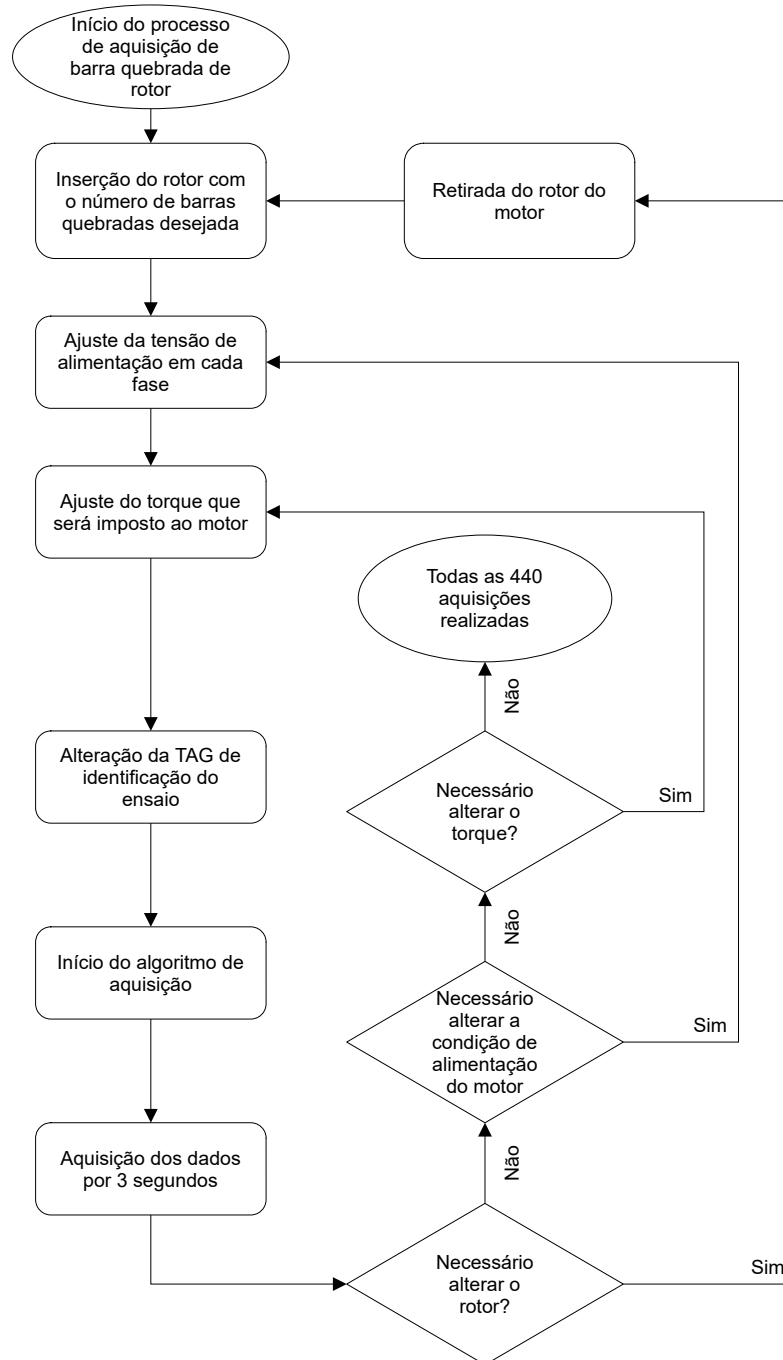
Analisando-se o exposto no fluxograma da Figura 41 observa-se que inicialmente é necessário definir qual o rotor que se deseja realizar o ensaio (quantidade e posição das barras quebradas). As Figura 33(a), Figura 33(b), Figura 33(c) e Figura 33(d) ilustram respectivamente o rotor com 1 barra quebrada, 2 barras quebradas, 2/2 barras quebradas e 4 barras quebradas. A partir disso, desmonta-se o motor e instala-se no motor o rotor específico para o ensaio da máquina. Após a instalação do rotor desejado no motor, instala-se novamente o motor e os sensores.

Após a inserção do rotor com a quantidade de barras quebradas desejada é necessário ajustar as tensões de fase que alimentarão a máquina conforme as regras definidas na Subseção 4.3.4.

Após o ajuste da tensão, altera-se o torque imposto ao motor a partir da mudança da tensão alimentação do enrolamento de campo da máquina de corrente contínua acoplada ao motor. Os torques impostos a cada um dos motores deste estudo estão mostrados na Subseção 4.3.4.

Após o ajuste das tensões de alimentação do motor e do torque de carga imposto ao mesmo, altera-se a TAG de identificação do ensaio de modo a garantir que

Figura 41 – Fluxograma do processo de aquisição de dados para barra quebrada de rotor.



Fonte: Autoria Própria.

cada ensaio tenha sua TAG específica de acordo com a definição das TAGs explicada na Subseção 4.3.5.

Com todos os passos acima realizados, inicia-se a aquisição de dados. A aquisição tem tempo de duração total de 3 segundos. Como as placas de aquisição utilizadas foram configuradas para trabalhar com taxas de aquisição diferentes (16kHz

e 50kHz), os dados obtidos são guardados em duas variáveis diferentes. Assim, essas variáveis são salvas em um arquivo que tenha como nome a TAG definida para o ensaio que está sendo realizado.

Após a aquisição dos dados deve-se verificar se é necessário alterar o rotor, em caso negativo (ainda não foram realizados os 110 ensaios previstos para a condição atual), é necessário verificar quais condições de operação da máquina (tensões de alimentação e torque de carga) deverão ser alteradas.

Os ensaios de barra quebrada de rotor se encerram quando todos os ensaios previstos forem realizados, o que totaliza 440 ensaios. A realização desses 440 ensaios de barra quebrada de rotor são justificados pois para cada cada condição de barra quebrada são necessários 110 ensaios, a saber: i) 110 ensaios para 1 barra quebradas; ii) 110 ensaios para 2 barras quebradas; iii) 110 ensaios para 2/2 barras quebradas e iv) 110 ensaios para 4 barras quebradas.

4.3.4.3 Desgaste de Rolamento

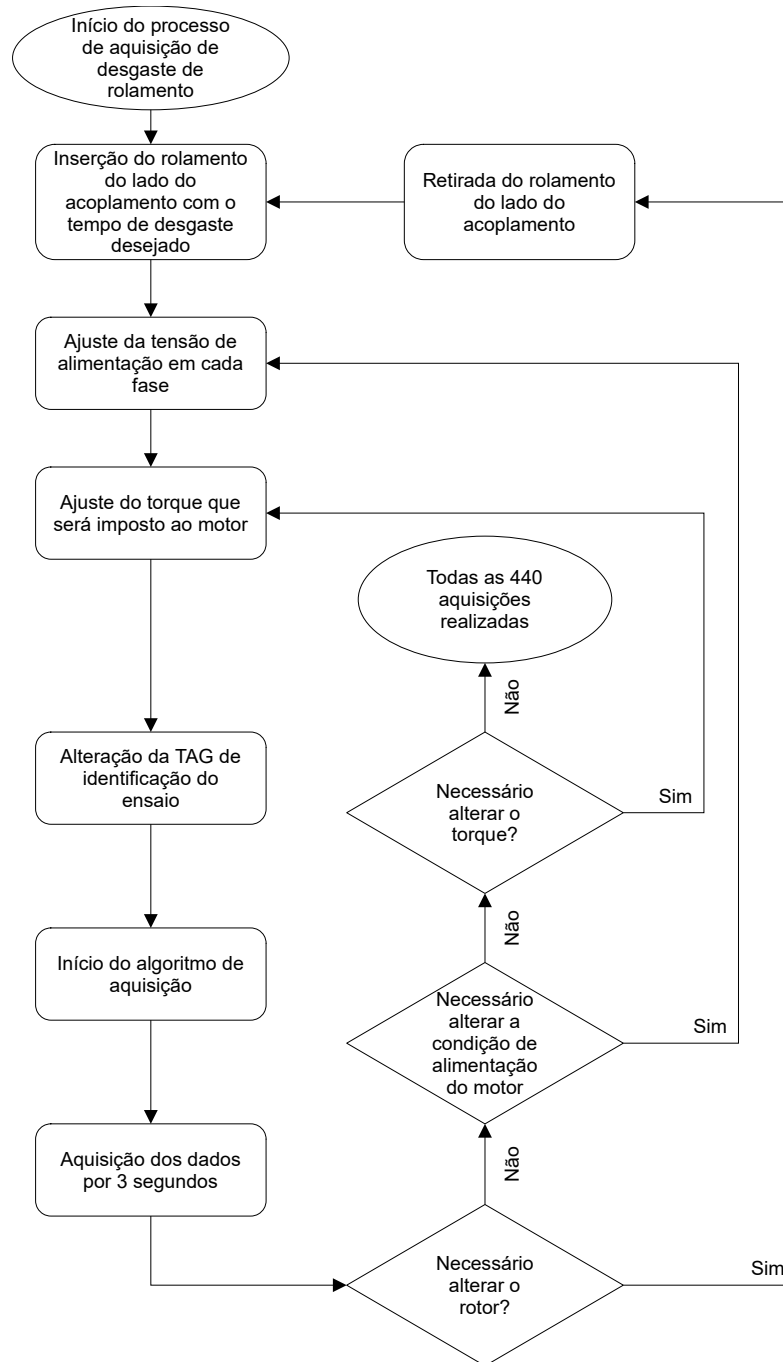
Nesta seção, será explicada a metodologia utilizada para a obtenção dos dados de desgaste de rolamento para cada um dos motores. A Figura 42 ilustra o fluxograma simplificado do processo de aquisição dos dados de rolamento.

Analisando-se o exposto no fluxograma da Figura 42 observa-se que inicialmente é necessário definir qual o rolamento que se deseja realizar o ensaio (tempo de desgaste). A partir disso, desmonta-se o motor e instala-se no eixo de acoplamento do motor o rolamento específico para o ensaio máquina. A instalação do rolamento ocorreu com o aquecimento do rolamento a partir do direcionamento de fluxo de ar quente sobre o mesmo. O processo de aquecimento do rolamento se fez necessário para que o mesmo dilatasse de modo a permitir que sua instalação no eixo do motor fosse feita de maneira suave, sem a necessidade de aplicação de forças que pudessem danificar as pistas do rolamento.

Após a instalação do rolamento desejado no rotor, o motor é novamente montado e fixado na bancada. Ainda, posicionam-se todos os sensores e ligam-se os terminais dos enrolamentos do motor na alimentação.

Após a inserção do rolamento com o tempo de desgaste desejado é necessário ajustar as tensões de fase que alimentam a máquina conforme as regras definidas na

Figura 42 – Fluxograma do processo de aquisição de dados para desgaste de rolamento.



Fonte: Autoria Própria.

Subseção 4.3.4.

Após o ajuste da tensão, altera-se o torque imposto ao motor a partir da mudança da tensão alimentação do enrolamento de campo da máquina de corrente contínua acoplada ao motor. Os torques impostos a cada um dos motores deste estudo estão mostrados na Subseção 4.3.4.

Após o ajuste das tensões de alimentação do motor e do torque de carga

imposto ao mesmo, alterasse a TAG de identificação do ensaio de modo a garantir que cada ensaio tenha sua TAG específica de acordo com a definição das TAGs explicada na Subseção 4.3.5.

Com todos os passos acima realizados, iniciasse a aquisição de dados. A aquisição tem duração total de 3 segundos. Como as placas de aquisição utilizadas fora configuradas para trabalhar com taxas de aquisição diferentes (16kHz e 50kHz), os dados obtidos são guardados em duas variáveis diferentes, e essas variáveis são salvas em um arquivo que tenha como nome a TAG definida para o ensaio que está sendo realizado.

Após a aquisição dos dados deve-se verificar se é necessário alterar o rolamento. Em caso negativo (ainda não foram realizados os 110 ensaios previstos para a condição atual), é necessário verificar quais condições de operação da máquina (tensões de alimentação e torque de carga) deverão ser alteradas.

Os ensaios de desgaste de rolamento do eixo de acoplamento, só se encerrarão se todos os ensaios previstos forem realizados, o que totaliza 440 ensaios. Os 440 ensaios de desgaste de rolamento são justificados pois para cada condição de desgaste do rolamento são necessários 110 ensaios, a saber: i) 110 ensaios para desgaste de 15 minutos; ii) 110 ensaios para desgaste de 30 minutos; iii) 110 ensaios para desgaste de 60 minutos e iv) ensaios para desgaste de 90 minutos.

4.3.5 Definição das TAGs

Para que se conseguisse diferenciar os dados coletados de um ensaio para o outro foi necessário definir uma metodologia de identificação (TAG) que permitisse o reconhecimento do ensaio ao qual os dados se referem. Dessa maneira, o sistema de identificação (TAG) utilizado possui um prefixo contendo 3 letras, um radical contendo 3 números e um sufixo também contendo 3 números. O prefixo radical e sufixo da TAG sempre fica separado por um subtraço (*underline*). Dessa maneira, a TAG terá a seguinte forma:

ABC_RST_XYZ

O prefixo 'ABC' define o tipo de falha a qual o motor está sendo submetido. Optou-se por utilizar as abreviaturas já utilizadas na literatura para determinar o tipo de

falha, assim, o prefixo pode assumir os seguintes valores:

- 'STW' para indicar falha de estator;
- 'BRB' para indicar falha de rotor;
- 'BEA' para indicar falha de rolamento.

O primeiro algarismo do radical 'RST' define em qual fase está ocorrendo a falha, sendo que esse algarismo apresentará valores diferente de zero apenas nos casos de ensaios em que é aplicado um curto-circuito em um dos enrolamentos do motor. Assim, o primeiro algarismo do radical pode assumir os seguintes valores:

- '0' para indicar motor saudável, com falha de rotor ou com falha de rolamento;
- '1' para indicar curto-circuito na fase A;
- '2' para indicar curto-circuito na fase B;
- '3' para indicar curto-circuito na fase C;

O segundo algarismo do radical 'RST' define a potência do motor que se realizou o ensaio. Assim, o segundo algarismo do radical pode assumir os seguintes valores:

- '1' para indicar que o ensaio foi realizado no motor de 1CV;
- '2' para indicar que o ensaio foi realizado no motor de 2CV;

O terceiro algarismo do radical 'RST' define qual a severidade da falha na qual o ensaio foi realizado, assim, o terceiro algarismo do radical pode assumir os seguintes valores:

- '0' para indicar que ensaio foi realizado com motor sem falha;
- '1' para indicar que ensaio foi realizado com motor apresentando falha com severidade baixa;
 - Para falha de estator: 1% de curto-circuito;
 - Para falha de rotor: 1 barra quebrada;
 - Para falha de rolamento: 15 minutos de desgaste;

- '2' para indicar que ensaio foi realizado com motor apresentando falha com severidade média;
 - Para falha de estator: 3% de curto-circuito;
 - Para falha de rotor: 2 barras quebradas;
 - Para falha de rolamento: 30 minutos de desgaste;
- '3' para indicar que ensaio foi realizado com motor apresentando falha com severidade alta;
 - Para falha de estator: 5% de curto-circuito;
 - Para falha de rotor: 2/2 barras quebradas (barras quebradas diametralmente opostas);
 - Para falha de rolamento: 60 minutos de desgaste;
- '3' para indicar que ensaio foi realizado com motor apresentando falha com severidade muito alta;
 - Para falha de estator: 10% de curto-circuito;
 - Para falha de rotor: 4 barras quebradas;
 - Para falha de rolamento: 90 minutos de desgaste;

Os primeiro e segundo algarismos do sufixo 'XYZ' indicam o nível de tensão da alimentação da máquina, assim, os primeiro e segundo algarismos do sufixo podem assumir os seguintes valores:

- '00' para indicar alimentação equilibrada nas 3 fases;
- '01' para indicar sobretensão de 2% na fase A;
- '02' para indicar sobretensão de 4% na fase A;
- '03' para indicar sobretensão de 6% na fase A;
- '04' para indicar sobretensão de 8% na fase A;
- '05' para indicar sobretensão de 10% na fase A;
- '06' para indicar sobretensão de 2% na fase B e subtensão de 2% na fase C;

- '07' para indicar sobretensão de 4% na fase B e subtensão de 4% na fase C;
- '08' para indicar sobretensão de 6% na fase B e subtensão de 6% na fase C;
- '09' para indicar sobretensão de 8% na fase B e subtensão de 8% na fase C;
- '10' para indicar sobretensão de 10% na fase B e subtensão de 10% na fase C;

O terceiro algarismo do sufixo 'XYZ' indica o torque aplicado ao eixo do motor que está sendo ensaiado, assim, o terceiro algarismo do sufixo 'XYZ' pode assumir os seguintes valores:

- '0' para indicar torque de 0,5Nm;
- '1' para indicar torque de 1Nm;
- '2' para indicar torque de:
 - 1,5Nm para o motor de 1CV;
 - 2Nm para o motor de 2CV;
- '3' para indicar torque de:
 - 2Nm para o motor de 1CV;
 - 3Nm para o motor de 2CV;
- '4' para indicar torque de:
 - 3,5Nm para o motor de 1CV;
 - 4Nm para o motor de 2CV;
- '5' para indicar torque de:
 - 3Nm para o motor de 1CV;
 - 5Nm para o motor de 2CV;
- '6' para indicar torque de:
 - 3,5Nm para o motor de 1CV;
 - 6Nm para o motor de 2CV;

- '7' para indicar torque de:
 - 4Nm para o motor de 1CV;
 - 7Nm para o motor de 2CV;
- '8' para indicar torque de:
 - 4,5Nm para o motor de 1CV;
 - 8Nm para o motor de 2CV;
- '9' para indicar torque de:
 - 5Nm para o motor de 1CV;
 - 9Nm para o motor de 2CV;

Para o melhor entendimento do sistema de identificação utilizado, a seguir constam dois exemplos indicando a maneira correta de leitura da TAG para identificação do tipo de ensaio que foi realizado.

a) STW_213_086:

- O prefixo dessa TAG é 'STW', portanto indica que se trata de um ensaio de falha de estator;
- O radical dessa TAG é '213', portanto indica que se trata de um ensaio de um motor de 1CV (segundo algarismo do radical), com curto-circuito de 5% (terceiro algarismo do radical) aplicado na fase B do motor (primeiro algarismo do radical);
- O sufixo dessa TAG é '086', portanto indica que a alimentação aplicada ao motor nesse ensaio possui sobretensão de 6% na fase B e subtensão de 6% na fase C (primeiro e segundo algarismos do sufixo), e o torque aplicado ao motor é de 3,5Nm (terceiro algarismo do sufixo, lembrando que se trata de um motor de 1CV).

b) BEA_022_048

- O prefixo dessa TAG é 'BEA', portanto indica que se trata de um ensaio de falha de rolamento;

- O radical dessa TAG é '022', portanto indica que se trata de um ensaio de um motor de 2CV (segundo algarismo do radical), com rolamento desgastado por 30 minutos (terceiro algarismo do radical);
- O sufixo dessa TAG é '048', portanto indica que a alimentação aplicada ao motor nesse ensaio possui sobretensão de 8% na fase A (primeiro e segundo algarismos do sufixo), e o torque aplicado ao motor é de 8Nm (terceiro algarismo do sufixo, lembrando que se trata de um motor de 2CV).

4.4 PROCESSAMENTO DOS SINAIS

Com a criação dos banco de dados contendo as informações dos sensores utilizados neste trabalho os sinais do banco de dados são processados e analisados.

Como o banco de dados criado possui uma quantidade significativa de dados, optou-se por utilizar medidas estatísticas que resumissem os dados de cada um dos ensaios realizados. Dessa maneira, a quantidade de dados utilizada na etapa de seleção dos sensores é menor. Assim, otimizando o tempo de processamento necessário para a seleção dos sensores, conforme será apresentado na Seção 4.5.

O processamento dos sinais neste trabalho consistiu na determinação de algumas medidas estatísticas dos sinais para os ensaios realizados com o motor de 1CV. Tais medidas estatísticas foram calculadas tanto com os sinais no domínio do tempo, conforme apresentado na Subseção 4.4.1, quanto com os sinais no domínio da frequência, conforme apresentado na Subseção 4.4.2.

4.4.1 Medidas Estatísticas no Domínio do Tempo

Para o cálculo das medidas estatísticas no domínio do tempo neste trabalho utilizou-se toda extensão dos dados de cada ensaio para cada sensor. Ou seja, utilizou-se estes 3 segundos de amostras de cada sensor para o cálculo das medidas estatísticas.

As medidas estatísticas no domínio do tempo são algumas das medidas propostas nos trabalhos de Lei *et al.* (2008) e Haroun *et al.* (2018), sendo elas:

- a) Média: Para o cálculo da média no domínio tempo realizou-se a soma de

todas as amostras do ensaio e dividiu-se pelo total de amostras do ensaio, a Equação (11) mostra o procedimento para o cálculo da média;

$$X_{media} = \frac{\sum_{n=1}^N X(n)}{n} \quad (11)$$

onde X_{media} é a média no domínio do tempo, N é o número total de amostras do conjunto, $X(n)$ é o valor da amostra e n é a quantidade de amostradas consideradas.

- b) Mediana: Define o valor em que 50% dos dados do ensaio são menores que esse valor, e conseqüentemente, 50% dos dados do ensaio são maiores que esse valor;
- c) Moda: Indica o valor que mais se repete no conjunto de dados analisado;
- d) Máximo: Indica o máximo valor positivo apresentado pelas amostras do ensaio, conforme Equação (12):

$$X_{max} = \max(X(n)) \quad (12)$$

onde X_{max} é o valor máximo e $X(n)$ é o valor da amostra 'n'.

- e) Valor eficaz: É definido como o cálculo da raiz quadrada média desse sinal, ou valor RMS (do inglês *Root Mean Square*). A Equação (13) mostra o procedimento para o cálculo do valor eficaz:

$$X_{Eficaz} = \sqrt{\frac{1}{N} \sum_{n=1}^N X(n)^2} \quad (13)$$

onde X_{Eficaz} é o valor eficaz do sinal, N é o número total de amostras do conjunto e $X(n)$ é o valor da amostra.

- f) 1º Quartil: Define o valor em que 25% dos dados do ensaio são menores que esse valor, e conseqüentemente, 75% dos dados do ensaio são maiores que esse valor;
- g) 3º Quartil: Define o valor em que 25% dos dados do ensaio são maiores que esse valor, e conseqüentemente, 75% dos dados do ensaio são menores que esse valor;
- h) Distância entre o 1º e o 3º Quartis: Define o valor entre o 1º Quartil e o 3º Quartil, a distância entre esses quartis é definido pela (Equação (14)):

$$X_{DistQ1eQ3} = Q3_{tempo} - Q1_{tempo} \quad (14)$$

onde $X_{DistQ1eQ3}$ é a distância entre o primeiro e o segundo Quartis no domínio do tempo, $Q3_{tempo}$ é o valor do 3º Quartil no domínio do tempo e $Q1_{tempo}$ é o valor do 1º Quartil no domínio do tempo.

- i) Desvio Padrão: É uma medida de dispersão, indicando a distância dos valores do conjunto de dados do ensaio para a média desses valores, a Equação (15) mostra o método de cálculo do desvio padrão;

$$X_{DesvioPadrao} = \sqrt{\frac{\sum_{n=1}^N (X(n) - X_{media})^2}{N - 1}} \quad (15)$$

onde $X_{DesvioPadrao}$ é o desvio padrão no domínio do tempo, X_{media} é a média no domínio do tempo, N é o número total de amostras do conjunto, $X(n)$ é o valor da amostra.

- j) Desvio Médio Absoluto: Indica a média da distância absoluta entre os valores do conjunto de dados do ensaio e a média, a Equação (16) mostra o método de cálculo do desvio médio absoluto:

$$X_{DesvioMedioAbsoluto} = \frac{\sum_{n=1}^N |X(n) - X_{media}|}{N} \quad (16)$$

onde $X_{DesvioMedioAbsoluto}$ é o desvio médio absoluto no domínio do tempo, X_{media} é a média no domínio do tempo, N é o número total de amostras do conjunto, $X(n)$ é o valor da amostra.

- k) Variância: É uma medida de dispersão que indicando, assim como o desvio padrão, a distância dos valores do conjunto de dados do ensaio para a média desses valores, a Equação (17) mostra o método de cálculo da variância:

$$X_{Variancia} = \frac{1}{N - 1} \sum_{n=1}^N |X(n) - X_{media}|^2 \quad (17)$$

onde $X_{Variancia}$ é a variância no domínio do tempo, X_{media} é a média no domínio do tempo, N é o número total de amostras do conjunto, $X(n)$ é o valor da amostra.

- l) Coeficiente de Variação: É definido a partir da relação entre o desvio padrão e a média do conjunto de dados do ensaio, conforme Equação (18):

$$X_{Coef.deVariacao} = \frac{X_{DesvioPadrao}}{X_{media}} \quad (18)$$

onde $X_{Coe\text{f.deVariacao}}$ é o coeficiente de variação no domínio do tempo, X_{media} é a média no domínio do tempo e $X_{DesvioPadrao}$ é o desvio padrão no domínio do tempo.

4.4.2 Medidas Estatísticas no Domínio da Frequência

Neste trabalho também foram utilizadas medidas no domínio da frequência, pois os sinais de áudio, vibração, corrente e fluxo possuem características específicas no espectro de frequência do sinal que pode ser útil na identificação e classificação de falhas em motores elétricos. Conforme observado nas Equação (1) a Equação (8) presentes neste trabalho, as falhas presentes no MIT podem ser analisadas a partir de suas frequências características. Dessa maneira, a utilização de medidas estatísticas também no domínio da frequência pode ser útil para a identificação dos melhores sensores para utilização no trabalho de identificação e classificação de falhas.

A obtenção das frequências de um sinal contínuo é determinada pela transformada de Fourier. A Equação (19) mostra o cálculo para obtenção da magnitude da transformada de Fourier (ROMERO-TRONCOSO, 2016).

$$|X(j2\pi f)| = \left| \int_{-\infty}^{\infty} e^{-j2\pi ft} x(t) dt \right| \quad (19)$$

onde $|X(j2\pi f)|$ é o espectro de frequência, $x(t)$ é o sinal contínuo e f é a frequência.

Para sinais discretos, a transformada de Fourier pode ser reescrita como a Transformada Discreta de Fourier (DFT, do inglês Discrete Fourier Transform) conforme ilustrado na Equação (20).

$$X(k) = \sum_{n=0}^{N-1} e^{-j2\pi kn/N} x(n) \quad (20)$$

onde $X(k)$ é o valor da DFT em determinada frequência, $k = 0, 1, 2, \dots, N - 1$ é a frequência discretizada, N é o número de pontos e $x(n)$ é o sinal discreto.

A DFT exige um grande esforço computacional, o que acaba lavando a lentidão e problemas de processamento dos dados da mesma. Dessa maneira, se faz o uso de algoritmos que buscam otimizar o cálculo da DFT, como é o caso da FFT.

A partir do uso da FFT foram obtidos os espectros de frequências dos sinais. As informações obtidas a partir do espectro de frequência foram utilizadas para a obtenção de medidas estatísticas no domínio da frequência. Para o cálculo das medidas

estatísticas no domínio da frequência utilizadas neste trabalho emprega-se o espectro de frequência entre 0 e 2000Hz. As medidas estatísticas no domínio da frequência são algumas das medidas propostas nos trabalhos de Lei *et al.* (2008) e Haroun *et al.* (2018), sendo elas:

- a) Média: Para o cálculo da média no domínio da frequência realizou-se a soma de todas as amostras do espectro de frequência até 2000Hz e dividiu-se pelo total de amostras do espectro de frequência até 2000Hz. A Equação (21) apresenta o cálculo da média;

$$S_{media} = \frac{\sum_{k=1}^K s(k)}{k} \quad (21)$$

onde S_{media} é a média no domínio da frequência, K é o número total de amostras do conjunto, $s(k)$ é o valor da amostra e k é a quantidade de amostradas consideradas.

- b) Mediana: Define o valor em que 50% dos dados do ensaio são menores que esse valor, e conseqüentemente, 50% dos dados do ensaio são maiores que esse valor;
- c) Moda: Indica o valor que mais se repete no conjunto de dados analisado;
- d) Máximo: Indica o máximo valor positivo apresentado pelas amostras do ensaio, conforme Equação (22):

$$S_{max} = \max(s(k)) \quad (22)$$

onde S_{max} é o valor máximo no domínio da frequência e $s(k)$ é o valor da amostra 'k'.

- e) Média Ponderada da Frequência: É definido como o cálculo da média ponderada da frequência do espectro entre 0 e 2000Hz, utilizando como fator ponderador a amplitude do sinal de frequência em cada frequência correspondente. A Equação (23) mostra o procedimento para o cálculo da média ponderada da frequência:

$$S_{mediapond.freq.} = \frac{\sum_{k=1}^K s(k) * f(k)}{\sum_{k=0}^K s(k)} \quad (23)$$

onde $S_{mediapond.freq.}$ é o valor da média ponderada da frequência, $s(k)$ é o valor da amostra 'k', $f(k)$ é o valor da frequência para a amostra 'k' e K é o número total de amostras.

- f) 1º Quartil: Define o valor em que 25% dos dados do ensaio são menores que esse valor, e conseqüentemente, 75% dos dados do ensaio são maiores que esse valor;
- g) 3º Quartil: Define o valor em que 75% dos dados do ensaio são maiores que esse valor, e conseqüentemente, 25% dos dados do ensaio são menores que esse valor;
- h) Distância entre o 1º e o 3º Quartis: Define o valor entre o 1º Quartil e o 3º Quartil. A distância entre esses quartis é definido pela Equação (24):

$$S_{DistQ1eQ3} = Q3_{freq} - Q1_{freq} \quad (24)$$

onde $S_{DistQ1eQ3}$ é a distância entre o primeiro e o segundo Quartis no domínio da frequência, $Q3_{freq}$ é o valor do 3º Quartil no domínio da frequência e $Q1_{freq}$ é o valor do 1º Quartil no domínio da frequência.

- i) Desvio Padrão: É uma medida de dispersão, indicando a distância dos valores do conjunto de dados do ensaio para a média desses valores, onde a Equação (25) apresenta o método de cálculo do desvio padrão;

$$S_{DesvioPadrao} = \sqrt{\frac{\sum_{k=1}^K s(k) - S_{media}}{K - 1}} \quad (25)$$

onde $S_{DesvioPadrao}$ é o desvio padrão no domínio da frequência, S_{media} é a média no domínio da frequência, K é o número total de amostras do conjunto, $S(k)$ é o valor da amostra.

- j) Desvio Médio Absoluto: Indica a média da distância absoluta entre os valores do conjunto de dados do ensaio e a média. Neste contexto, a Equação (26) apresenta o método de cálculo do desvio médio absoluto:

$$S_{DesvioMedioAbsoluto} = \frac{\sum_{k=1}^K |s(k) - X_{media}|}{K} \quad (26)$$

onde $S_{DesvioMedioAbsoluto}$ é o desvio médio absoluto no domínio da frequência, S_{media} é a média no domínio da frequência, K é o número total de amostras do conjunto, $s(k)$ é o valor da amostra.

- k) Variância: É uma medida de dispersão que indica, assim como o desvio padrão, a distância dos valores do conjunto de dados do ensaio para a

média desses valores. A Equação (27) mostra o método de cálculo da variância:

$$S_{Variância} = \frac{1}{K-1} \sum_{k=1}^K |s(k) - S_{media}|^2 \quad (27)$$

onde $S_{Variância}$ é a variância no domínio da frequência, S_{media} é a média no domínio da frequência, K é o número total de amostras do conjunto, $s(k)$ é o valor da amostra.

- l) Coeficiente de Variação: É definido a partir da relação entre o desvio padrão e a média do conjunto de dados do ensaio, conforme Equação (28):

$$S_{Coef.deVariacao} = \frac{S_{DesvioPadrao}}{S_{media}} \quad (28)$$

onde $S_{Coef.deVariacao}$ é o coeficiente de variação no domínio da frequência, S_{media} é a média no domínio da frequência e $S_{DesvioPadrao}$ é o desvio padrão no domínio da frequência.

4.5 SELEÇÃO DOS ATRIBUTOS

Para a determinação dos melhores sensores para a identificação de cada tipo de falha, utilizam-se 3 métodos de seleção de atributos, a saber: i) Informação mútua; ii) *Variance Inflation Factor* (VIF) e iii) *Random Forest*. Tais métodos de seleção de atributos foram aplicados com o auxílio da linguagem Python, e das *toolboxes* scikit-learn, Pandas e Matplotlib.

A seleção de atributos é uma etapa muito importante no processo identificação e classificação de falhas a partir de sistemas inteligentes. A filtragem dos atributos, além de diminuir o esforço computacional na etapa de identificação e classificação, permite identificar os atributos que são mais relevantes para a identificação e classificação das falhas.

Neste trabalho a seleção de atributos ocorreu tanto para os dados do motor de 1CV quanto para os dados do motor de 2CV. Ao final da etapa de seleção de atributos foi realizada uma comparação entre os atributos selecionados para cada tipo de motor, de modo a verificar se os atributos selecionados eram comuns entre os motores.

4.5.1 Informação Mútua

A utilização da informação mútua para a seleção dos melhores atributos em um conjunto de dados se baseia na ideia de que a informação mútua é uma medida da quantidade de informação que uma determinada variável tem sobre outra variável (VERGARA; ESTÉVEZ, 2014).

A informação mútua entre duas variáveis discretas pode ser definida de acordo com a Equação (29). Nessa equação se relaciona as funções de densidade de probabilidade entre as variáveis e as funções de probabilidade marginais das variáveis analisadas (ESTÉVEZ *et al.*, 2009).

$$I(X,Y) = \sum \sum p(x,y) \log_{10} \frac{p(x,y)}{p(x)p(y)} \quad (29)$$

onde $I(X,Y)$ é a informação mútua, $p(x,y)$ é a distribuição conjunta de probabilidade das variáveis, $p(x)$ e $p(y)$ são as distribuições marginais de probabilidade.

Analisando-se a Equação (29) observa-se que se $I(X,Y)$ entre as duas variáveis for muito alta, significa que as variáveis X e Y estão muito relacionadas entre si. Caso contrário, as variáveis X e Y não são relacionadas entre si (LIU *et al.*, 2009).

Ao se realizar o cálculo da informação mútua entre os atributos de um conjunto de dados e a variável alvo, pode-se determinar quais atributos influenciam mais na variável alvo. Com isso, é possível diminuir a quantidade de atributos que serão utilizados em modelos de análise dos dados.

Neste trabalho utilizou-se a informação mútua para determinar quais atributos possuem a maior relação com a variável alvo. A partir do cálculo da informação mútua entre os atributos e a variável alvo selecionou-se os 20 atributos que apresentaram a maior informação mútua com a variável alvo.

4.5.2 Variance Inflation Factor (VIF)

O fator de inflação de variância, ou simplesmente VIF (do inglês *Variance Inflation Factor*) é um método de seleção de atributos que verifica a independência das variáveis que compõe um conjunto de dados. De modo a determinar quais variáveis são correlacionadas entre si, ou seja, quais variáveis possuem dependência linear entre si (KATRUTSA; STRIJOV, 2017).

Em um conjunto de dados no qual há variáveis que possuem uma alta taxa de correlação entre si, pode-se dizer que essas variáveis têm multicolinearidade. Segundo Alin (2010), a multicolinearidade pode ser entendida como sendo a relação linear entre duas ou mais variáveis em um conjunto de dados, de modo que, caso essas variáveis sejam totalmente correlacionadas entre si, um conjunto de k vetores acaba podendo ser representado em um subespaço menor que k . Na maioria dos casos, para se considerar que existe multicolinearidade em um problema não é necessário que os dados de determinadas variáveis sejam totalmente dependentes entre si, mas que possuam uma taxa razoável de dependência linear.

A multicolinearidade em um conjunto de dados pode prejudicar o desempenho, causando diversos problemas nos modelos de análise dos dados utilizados, sendo que alguns desses problemas são (CHENG *et al.*, 2022):

- Estimação instável de parâmetros;
- Modelos não confiáveis;
- Capacidade preditiva fraca

Para evitar que se utilizem variáveis com multicolinearidade entre si em um modelo de análise é possível utilizar o VIF. Esta técnica permite que se exclua do modelo as variáveis com multicolinearidade. Neste método compara-se uma variável com todas as outras, de modo a verificar quais variáveis são mais correlacionadas entre si. O cálculo do VIF é realizado conforme apresentado na Equação (30) (VU *et al.*, 2015).

$$VIF_j = \frac{1}{(1 - R_j^2)} \quad (30)$$

onde VIF_j é o valor do VIF para a variável j , R_j^2 é o coeficiente de determinação de regressão linear da variável j , e seu valor está contido entre 0 e 1.

O coeficiente de determinação (R^2) pode ser obtido a partir da Equação (31).

$$R^2 = \frac{(\bar{x} * \bar{y} - \overline{x * y})^2}{(\overline{x^2} - \bar{x}^2) * (\overline{y^2} - \bar{y}^2)} \quad (31)$$

onde x e y são variáveis e a barra é utilizada para denotar o cálculo da média.

A partir da análise da Equação (30) é possível observar que quanto maior o valor de R_j^2 , maior o valor de VIF, indicando que as variáveis possuem alto valor de multicolinearidade.

Neste trabalho, para a seleção dos melhores atributos, utilizou-se o VIF como uma das técnicas. Com todos os atributos de todos os ensaios calculados, calculou-se o valor de VIF entre cada um dos atributos, de modo a verificar a multicolinearidade entre esses valores. Para que uma variável fosse considerada independente foi considerado um VIF menor que 5. Ou seja, qualquer variável que apresentasse VIF maior ou igual a 5 seria retirada das variáveis candidatas para ser utilizada em uma futura classificação dos sinais.

4.5.3 *Random Forest*

A última ferramenta de seleção de atributos utilizada neste trabalho é a ferramenta denominada de floresta aleatória, do inglês *Random Forest*. A ferramenta *Random Forest* utiliza a ideia de classificação por meio de árvores de decisão para selecionar a melhor resposta para o problema que se deseja resolver (XUAN *et al.*, 2021).

Uma das principais vantagens da utilização de *Random Forest* ao invés de árvores de decisão é que o método *Random Forest* utiliza a ideia de separar o conjunto de dados em subconjuntos aleatórios, e combiná-los em várias árvores de decisão, que formam florestas aleatórias, e a decisão final do modelo de predição é definido a partir das respostas individuais de cada árvore (HUANG; CHEN, 2021).

O *Random Forest* aplicado na seleção de atributos utiliza o coeficiente de Gini ou a permutação de atributos que não foram selecionados para compor as árvores como uma medida para calcular a importância de cada atributo (ZUBAIR; KIM, 2022).

Neste trabalho, para a utilização do *Random Forest* na seleção de atributos, inicialmente realizou-se a busca em grade para determinar quais parâmetros deveriam ser utilizados para a construção da floresta aleatória. Com a busca em grade foi possível determinar o número de árvores de decisão, o número de níveis e de atributos em cada árvore de decisão. O critério para determinar a melhor configuração da floresta foi a acurácia apresentada pela busca em grade, os parâmetros selecionados foram referentes à configuração que apresentasse maior acurácia na identificação da

condição de operação do motor (falha e não falha).

Para a busca em grade foram considerados os seguintes parâmetros como sendo os candidatos para a composição do *Random Forest*:

- Número de árvores de decisão: 10, 20, 40, 70, 90, 100, 120, 130 ou 150 árvores;
- Número de níveis de cada árvore de decisão: 2, 4, 6, 9, 10, 11, 12, 13, 14 ou 15 níveis;
- Número máximo de atributos em cada árvore de decisão: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 15, 20, 25 ou 30 atributos.

Dessa forma, para a realização da busca em grade para definir a melhor configuração do *Random Forest* foram considerados 9 possibilidades de quantidade de árvores de decisão, 10 possibilidade de níveis em cada árvore e 16 possibilidades de atributos que seriam utilizados em cada árvore. Dessa maneira, haviam 1440 configurações candidatas, sendo que cada configuração foi testada 5 vezes (validação cruzada).

A partir da obtenção dos parâmetros da floresta realizou-se a seleção dos atributos que melhor identificam o tipo de falha no conjunto de dados sob análise.

4.6 CONCLUSÃO DO CAPÍTULO

Neste capítulo foi apresentada a metodologia utilizada para a realização deste trabalho. Uma das contribuições deste trabalho se pauta na construção do banco de dados. Assim, tem-se especial atenção a esse item na seção de metodologia.

Também foram apresentados as técnicas utilizadas para a seleção e determinação dos atributos que melhor representam determinada condição de falha. Tais técnicas são importantes pois determinam quais sensores apresentam as melhores características para a utilização de seus dados em um futuro processo de classificação. Além disso, a utilização de medidas estatísticas que resumem cada ensaio do banco de dados e a seleção desses atributos contribui para a redução do número de atributos a serem utilizados, permitindo que o sistema de classificação utilize menor esforço computacional.

5 RESULTADOS

Esta seção apresenta os resultados obtidos com a realização deste trabalho. Inicialmente são apresentados os resultados referente à construção do banco de dados. Na sequência, apresentam-se os resultados obtidos a partir da seleção dos atributos e identificação dos sensores que melhor generalizam o problema de diagnóstico das falhas.

5.1 EVOLUÇÃO DO DESGASTE DE ROLAMENTO

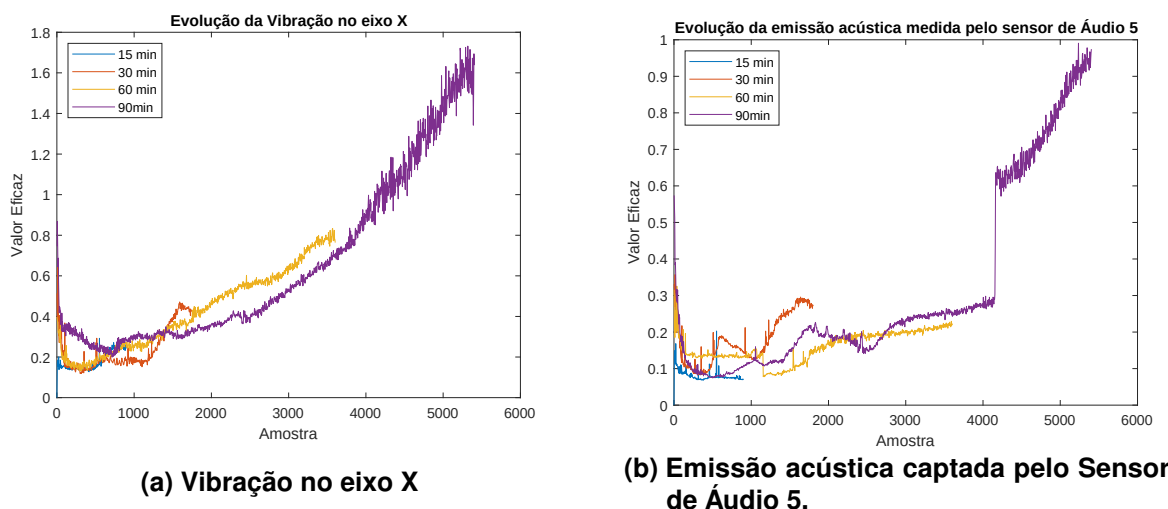
Conforme informado no Capítulo 4, para a construção do banco de dados contendo as falhas de rolamento inicialmente fez-se o processo de desgaste desses rolamentos conforme apresentado na Subseção 4.3.3.3.

5.1.1 Desgaste do rolamento do motor de 1CV

Durante o processo de desgaste dos rolamentos, realizou-se as aquisições dos dados dos sensores para verificar a evolução do desgaste em função do tempo do desgaste do rolamento com pasta abrasiva em seu interior. As Figura 43(a) e Figura 43(b) ilustram o valor eficaz da evolução do desgaste dos rolamentos dos sinais provenientes do sensor de vibração no eixo X e do sensor de áudio 5 para o desgaste de rolamento do motor de 1CV, tais sinais foram selecionados pois os mesmos ilustram com maior riqueza de detalhes a evolução dos desgastes dos rolamentos.

A partir das Figura 43(a) e Figura 43(b) observa-se que conforme o tempo de desgaste aumenta, maior a amplitude dos sinais de vibração e emissão acústica proveniente do motor. Observa-se também que no início do processo de desgaste os referidos sinais apresentaram picos. Esses picos se devem ao fato de que no início do processo de desgaste a pasta abrasiva presente nos rolamentos ainda possuía uma grande quantidade de elementos abrasivos e, conforme as esferas do rolamento passam por esses elementos abrasivos, estes são esmagados, ocasionando o aumento momentâneo na vibração da máquina. Conforme o tempo de desgaste aumenta, observa-se a redução da quantidade de picos na amplitude dos sinais de vibração e

Figura 43 – Evolução do desgaste dos rolamentos no motor de 1CV.



Fonte: Autoria Própria.

emissão acústica, pois a quantidade de elementos abrasivos reduz-se gradativamente.

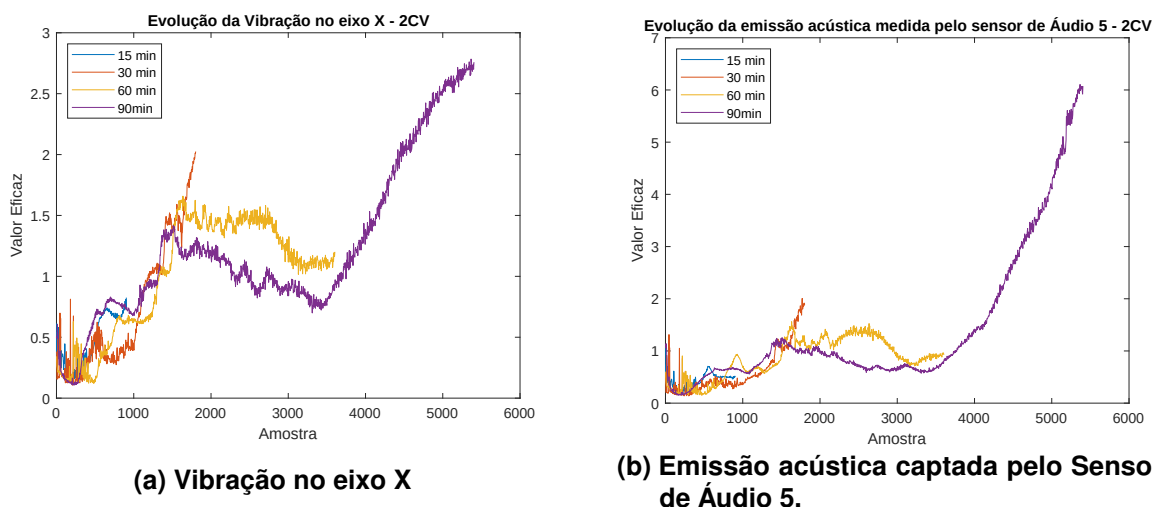
Para os rolamentos que sofreram o desgaste com maior tempo, em especial o rolamento que foi desgastado por 90 minutos, observou-se a elevação dos valores RMS dos sinais apresentados na Figura 43. Esse desgaste final foi ocasionado devido ao atrito entre os elementos metálicos do rolamento, ou seja, o atrito entre as esferas e as pistas interna e externa do rolamento.

Ao fim do processo de desgaste dos rolamentos, e a retirada dos rolamentos desgastados do eixo do motor, observou-se que a pasta abrasiva foi reduzida quase que inteiramente a uma pasta sem elemento abrasivo. Tal fato pode ser observado a partir da comparação da resistência ao esforço mecânico manualmente imposto ao rolamento antes e após o desgaste. Antes do desgaste, o rolamento com a pasta abrasiva apresentava uma grande resistência ao aplicar uma força em sua pista, o que impedia que o mesmo rotacionasse. Após o desgaste, o rolamento não apresentava quase nenhuma resistência à aplicação de uma força sobre o mesmo.

5.1.2 Desgaste do rolamento do motor de 2CV

O mesmo processo de desgaste foi realizado com o rolamento do motor de 2CV. As Figura 44(a) e Figura 44(b) ilustram o valor eficaz da evolução do desgaste dos rolamentos dos sinais provenientes do sensor de vibração no eixo X e do sensor de áudio 5 para o desgaste de rolamento do motor de 2CV.

Figura 44 – Evolução do desgaste dos rolamentos no motor de 2CV.



Fonte: Autoria Própria.

No processo de desgaste do rolamento de 2CV observa-se a oscilação dos níveis de ruído e vibração dos sensores. Esse fenômeno pode ser explicado devido às dimensões maiores do rolamento do motor de 2CV (rolamento 6205) quando comparados às dimensões do motor de 1CV (rolamento 6204). Como o rolamento para o motor de 2CV é um rolamento maior, foi inserido 1g a mais de pasta abrasiva nesse rolamento. A maior dimensão do rolamento, aliado à maior quantidade de pasta abrasiva inserida no mesmo, são fatores que podem acarretar no aumento do tempo em que há elemento abrasivo no rolamento, permitindo assim que houvesse a evolução de vibração em tempos intermediários de desgaste.

Após a eliminação quase que completa do elemento abrasivo, o rolamento passou por um processo de estabilização da vibração. Para o rolamento com desgaste 90 minutos, como o tempo de desgaste foi longo, a evolução da vibração se deu a partir do atrito entre as pistas e as esferas do rolamento.

Por fim, observa-se que apesar dos rolamentos utilizados possuírem a mesma especificação, para um mesmo tipo de rolamento a evolução do desgaste em um mesmo tempo não são iguais. Apesar de ser lógico que rolamentos iguais, com a mesma quantidade de pasta abrasiva, instalado em motor com as mesmas condições de operação apresentem a mesma dinâmica de evolução, essa ideia não está exatamente correta. Algumas hipóteses podem ser apresentadas: i) os rolamentos possuem erros no processo de fabricação que são aceitáveis dentro de um padrão de qualidade; ii) o processo de colocação da pasta abrasiva no rolamento foi feito de maneira manual, o

Tabela 6 – Total de ensaios realizados.

Condição		Quantidade de Ensaios		Totais		
		Motor de 1CV	Motor de 2CV	Por falha	Por Severidade	
	Saudável	110	110	220	330	
	Fase A	110	110			
1% de Curto-Circuito	Fase B	110	110		660	
	Fase C	110	110			
	Fase A	110	110			
Falha de Estator	3% de Curto-Circuito	Fase B	110	110	2640	660
		Fase C	110	110		
		Fase A	110	110		
5% de Curto-Circuito	Fase B	110	110		660	
	Fase C	110	110			
	Fase A	110	110			
10% de Curto-Circuito	Fase B	110	110		660	
	Fase C	110	110			
	Fase A	110	110			
Falha de Rotor	1 Barra Quebrada	110	110		110	
	2 Barras Quebradas	110	110	880	110	
	2/2 Barras Quebradas	110	110		110	
	4 Barras Quebradas	110	110		110	
	15 Minutos de Desgaste	110	110		110	
Falha de Rolamento	30 Minutos de Desgaste	110	110	880	110	
	60 Minutos de Desgaste	110	110		110	
	90 Minutos de Desgaste	110	110		110	
Total Geral		2310	2310	4620		

Fonte: Autoria própria.

que faz com que, inicialmente, a disposição da pasta abrasiva no interior do rolamento não seja igual para ambos os casos e iii) as condições ambientais externas, tais como temperatura no momento do ensaio, ou até mesmo condições de transporte dos rolamentos podem afetar a dinâmica de desgaste.

5.2 BANCO DE DADOS

Conforme ilustrados nas Subseção 1.2.2 e Subseção 4.3.4 um dos principais objetivos deste trabalho é a criação de um banco de dados sobre falhas em motores de indução contendo informações de diversos sensores nos mais variados ensaios. A Tabela 6 mostra o total de ensaios realizados na construção do banco de dados de falhas em motores.

Desse quantitativo de ensaios ainda é possível dividi-los em quantidade de dados por sensores, sendo que em cada ensaio existem 20 variáveis, sendo 14 variáveis

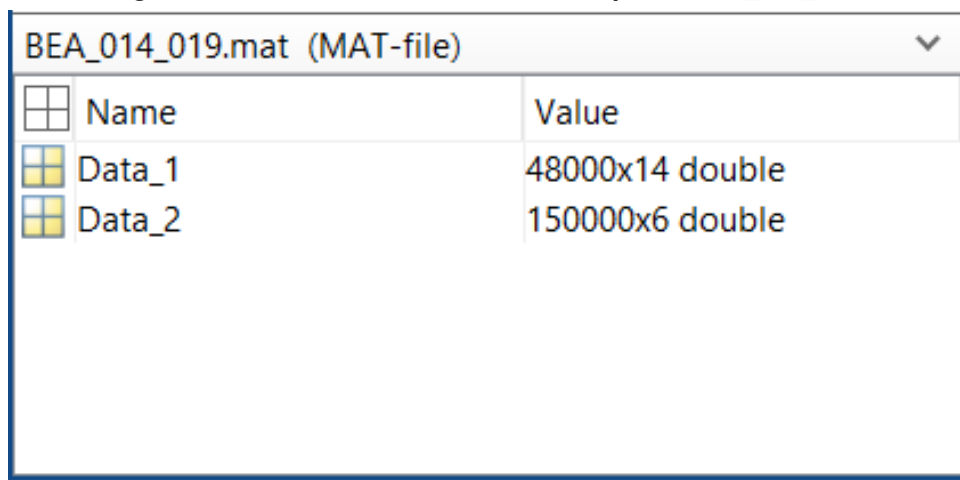
com taxa de amostragem de 16kHz, e 6 variáveis com taxa de amostragem de 50kHz. A ordenação dos dados nas duas variáveis é como segue no exemplo considerando o ensaio 'BEA_014_019', ou seja, ensaio de falha de desgaste de rolamento do motor de 1CV, com tempo severidade muito alta (desgaste de 90 minutos), com torque de 5Nm e sobretensão de 2% na alimentação da fase A.

O arquivo contendo esse ensaio possui duas variáveis, sendo elas:

- Data_1: Que contém os dados das variáveis adquiridas a 16kHz;
- Data_2: Que contém os dados das variáveis adquiridas a 50kHz.

A Figura 45 ilustra o ensaio 'BEA_014_019' com as duas variáveis mencionadas.

Figura 45 – Duas variáveis dentro do arquivo 'BEA_014_019'.



Name	Value
Data_1	48000x14 double
Data_2	150000x6 double

Fonte: Autoria Própria.

Observa-se que a variável Data_1 possui 14 amostras e cada amostra contém 48 mil pontos. A variável Data_2 possui, por sua vez, 6 amostras e cada amostra possui 150 mil pontos. As referidas amostras equivalem a 3 segundos de aquisição de dados para cada uma das variáveis.

Dentro da variável Data_1 a ordem dos dados apresentados é a que segue:

- Coluna 1: Fluxo;
- Coluna 2: Corrente na Fase A;
- Coluna 3: Corrente na Fase B;

- Coluna 4: Corrente na Fase C;
- Coluna 5: Tensão entre as fase A e B;
- Coluna 6: Tensão entre as fase B e C;
- Coluna 7: Tensão entre as fase C e A;
- Coluna 8: Vibração no eixo X;
- Coluna 9: Vibração no eixo Y;
- Coluna 10: Vibração no eixo Z;
- Coluna 11: Vibração do sensor industrial;
- Coluna 12: Velocidade do motor;
- Coluna 13: Torque do motor;
- Coluna 14: Tempo;

Dentro da variável Data_2 a ordem dos dados apresentados é a que segue:

- Coluna 1: Áudio do Sensor 1;
- Coluna 2: Áudio do Sensor 2;
- Coluna 3: Áudio do Sensor 3;
- Coluna 4: Áudio do Sensor 4;
- Coluna 5: Áudio do Sensor 5;
- Coluna 6: tempo;

Cada ensaio realizado possui dados com tamanho de cerca de 9MB (megabytes), o que totaliza um banco de dados de falha de motor contendo cerca de 40GB (gigabytes).

5.2.1 Dados adicionais

Conforme mencionado na Seção 5.1, criou-se um banco de dados contendo os dados de desgaste de rolamento tanto para o motor de 1CV (rolamento 6204) quanto para o motor de 2CV (rolamento 6205). Este banco possui a mesma estrutura do banco de dados de falhas, exceto pelo tempo de aquisição que é de 1s.

Mais especificamente, o banco de dados de desgaste de rolamento possui as seguintes características:

- 210 conjuntos de dados para o desgaste de 15 minutos no rolamento do motor de 1CV;
- 435 conjuntos de dados para o desgaste de 30 minutos no rolamento do motor de 1CV;
- 874 conjuntos de dados para o desgaste de 60 minutos no rolamento do motor de 1CV;
- 1308 conjuntos de dados para o desgaste de 90 minutos no rolamento do motor de 1CV;
- 218 conjuntos de dados para o desgaste de 15 minutos no rolamento do motor de 2CV;
- 437 conjuntos de dados para o desgaste de 30 minutos no rolamento do motor de 2CV;
- 869 conjuntos de dados para o desgaste de 60 minutos no rolamento do motor de 2CV;
- 1305 conjuntos de dados para o desgaste de 90 minutos no rolamento do motor de 2CV.

Considerando que cada conjunto de dados desse banco de dados possui cerca de 3MB (megabytes), e que esse banco de dados possui 5656 conjuntos de dados, esse banco de dados possui um tamanho total de cerca de 17GB (gigabytes).

5.3 SELEÇÃO DOS ATRIBUTOS E SENSORES

Com o banco de dados criado, calculam-se os atributos estatísticos para os dados obtidos com o motor de 1CV e 2CV mencionados nas Subseção 4.4.1 e Subseção 4.4.2. Assim, para cada ensaio, obteve-se 12 atributos estatísticos no domínio do tempo e 12 atributos estatísticos no domínio da frequência para cada sensor utilizado na etapa de seleção de atributos (15 sensores no total). Dessa maneira, obteve-se 360 atributos estatísticos para cada ensaio realizado.

Neste trabalho são utilizadas as técnicas de seleção de atributos mencionadas nas Subseção 4.5.1, Subseção 4.5.2 e Subseção 4.5.3. As Subseção 5.3.1 e Subseção 5.3.2 mostram os resultados obtidos com os métodos de seleção utilizados para falhas nos motores de 1CV e 2CV, respectivamente.

5.3.1 Seleção para o motor de 1CV

Neste seção serão mostrados os sensores e seus respectivos atributos selecionados para os ensaios realizados com o motor de 1CV.

5.3.1.1 Seleção dos atributos utilizando informação mútua

Para a seleção dos melhores atributos utilizando informação mútua, foram selecionados os 20 atributos que apresentassem o melhor ganho de informação para a variável alvo (falha ou não falha).

Nas Subseção 5.3.1.1.1, Subseção 5.3.1.1.2 e Subseção 5.3.1.1.3 são apresentados os resultados obtidos utilizando a informação mútua entre as variáveis.

5.3.1.1.1 Informação mútua para falha de estator

Aplicando a medida de informação mútua para os ensaios saudável e com falha de estator obteve-se os atributos mostrados na Tabela 7 como sendo os melhores para a identificação deste tipo de falha, enquanto na Figura 46 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 7 – Atributos selecionados a partir da informação mútua para falha de estator no motor de 1CV.

Sensor	Domínio	Atributo
Corrente A	Tempo	Média
Corrente C	Tempo	Média
		Coefficiente de Variação
Tensão entre B e C	Tempo	1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º quartis
Vibração em X	Tempo	Média
	Frequência	3º Quartil
Vibração em Y	Tempo	Media
		Valor eficaz
		Máximo
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
		Coefficiente de Variação
Vibração em Z	Tempo	Mediana

Autoria própria.

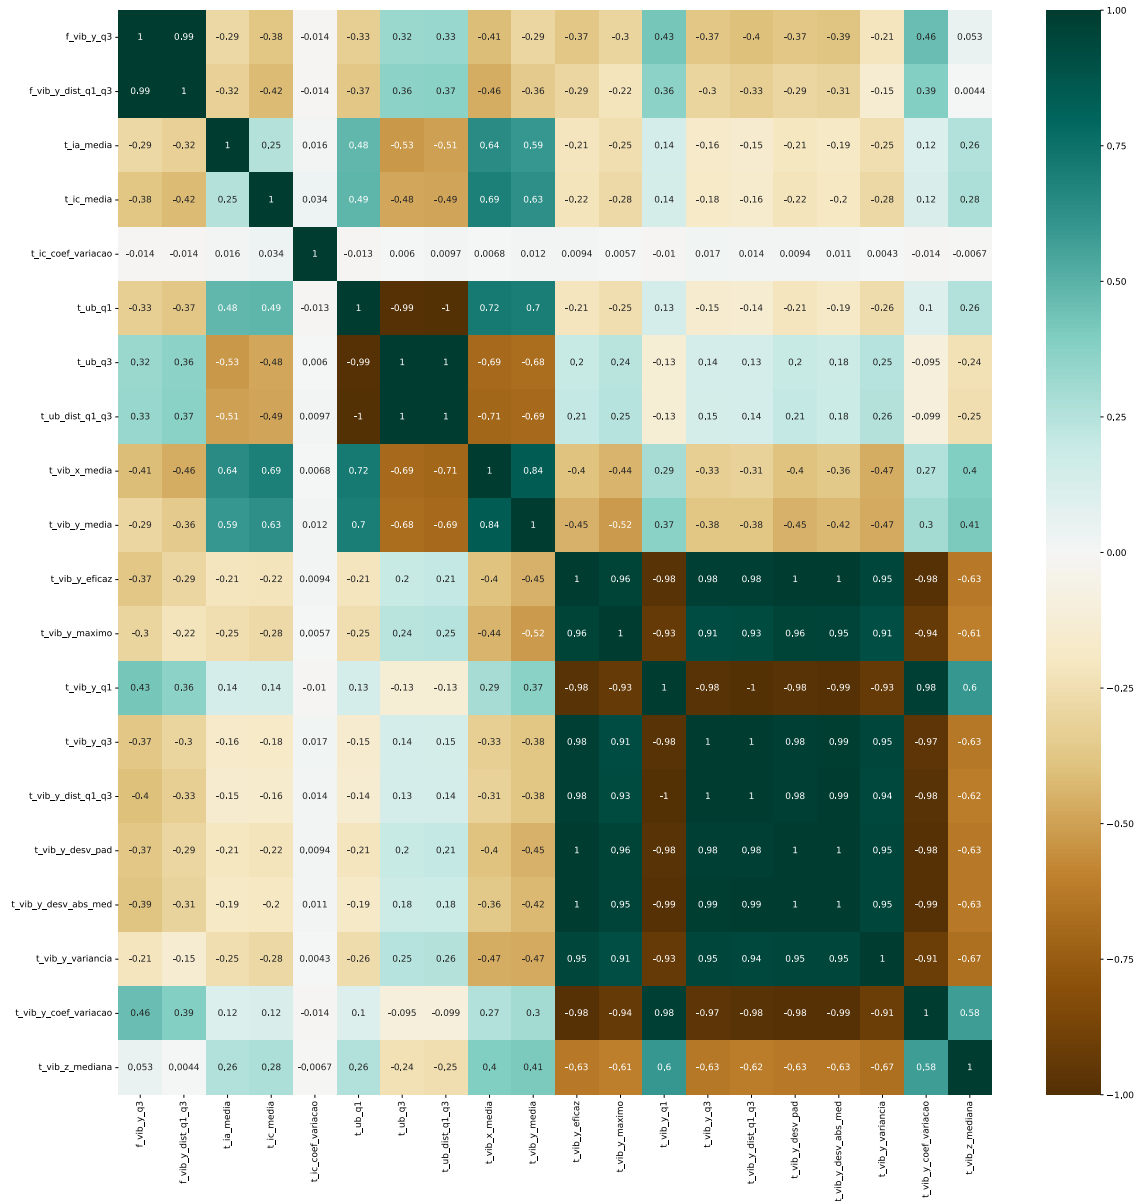
Analisando-se os resultados apresentados verifica-se os 20 atributos selecionados são provenientes de 6 sensores diferentes, a saber: i) Corrente na Fase A (1 atributo); ii) Corrente na Fase C (2 atributos); iii) Tensão entre B e C (3 atributos); iv) Vibração em X (1 atributo); v) Vibração em Y (12 atributos); vi) Vibração em Z (1 atributo).

Observando-se a Figura 46 verifica-se que, devido aos atributos selecionados serem majoritariamente da vibração no eixo Y do motor, e em especial de atributos no domínio do tempo (10 dos 12 atributos de vibração no eixo Y), existe uma grande correlação entre os atributos, o que por si só pode ser considerado um ponto de atenção, uma vez que uma grande correlação indica que esses atributos apresentam multicolinearidade.

5.3.1.1.2 Informação mútua para falha de rotor

Aplicando a medida de informação mútua para os ensaios saudável e com falha de rotor obteve-se os atributos mostrados na Tabela 8 como sendo os melhores para a identificação deste tipo de falha. Já na Figura 47 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Figura 46 – Correlação entre os atributos selecionados utilizando informação mútua para falha de estator no motor de 1CV.



Fonte: Autoria Própria.

Tabela 8 – Atributos selecionados a partir da informação mútua para falha de rotor no motor de 1CV.

Sensor	Domínio	Atributo
Tensão entre A e B	Frequência	Desvio Padrão
		Variância
Tensão entre B e C	Tempo	Moda
Tensão entre C e A	Frequência	Desvio Padrão
		Variância
Vibração em X	Frequência	Desvio Absoluto Médio
	Tempo	Média
		Média
Vibração em Y	Tempo	Valor Eficaz

(continua)

Tabela 8 – Atributos selecionados a partir da informação mútua para falha de rotor no motor de 1CV.

(continuação)

Sensor	Domínio	Atributo
		Máximo
		Desvio Padrão
		Variância
Audio 1	Frequência	Média Ponderada da Frequência
		Média
	Tempo	Máximo
Audio 2	Frequência	Média Ponderada da Frequência
Áudio 3	Frequência	Média Ponderada da Frequência
Áudio 4	Tempo	Média
		Coeficiente de Variação
Áudio 5	Frequência	Média Ponderada da Frequência

Autoria própria.

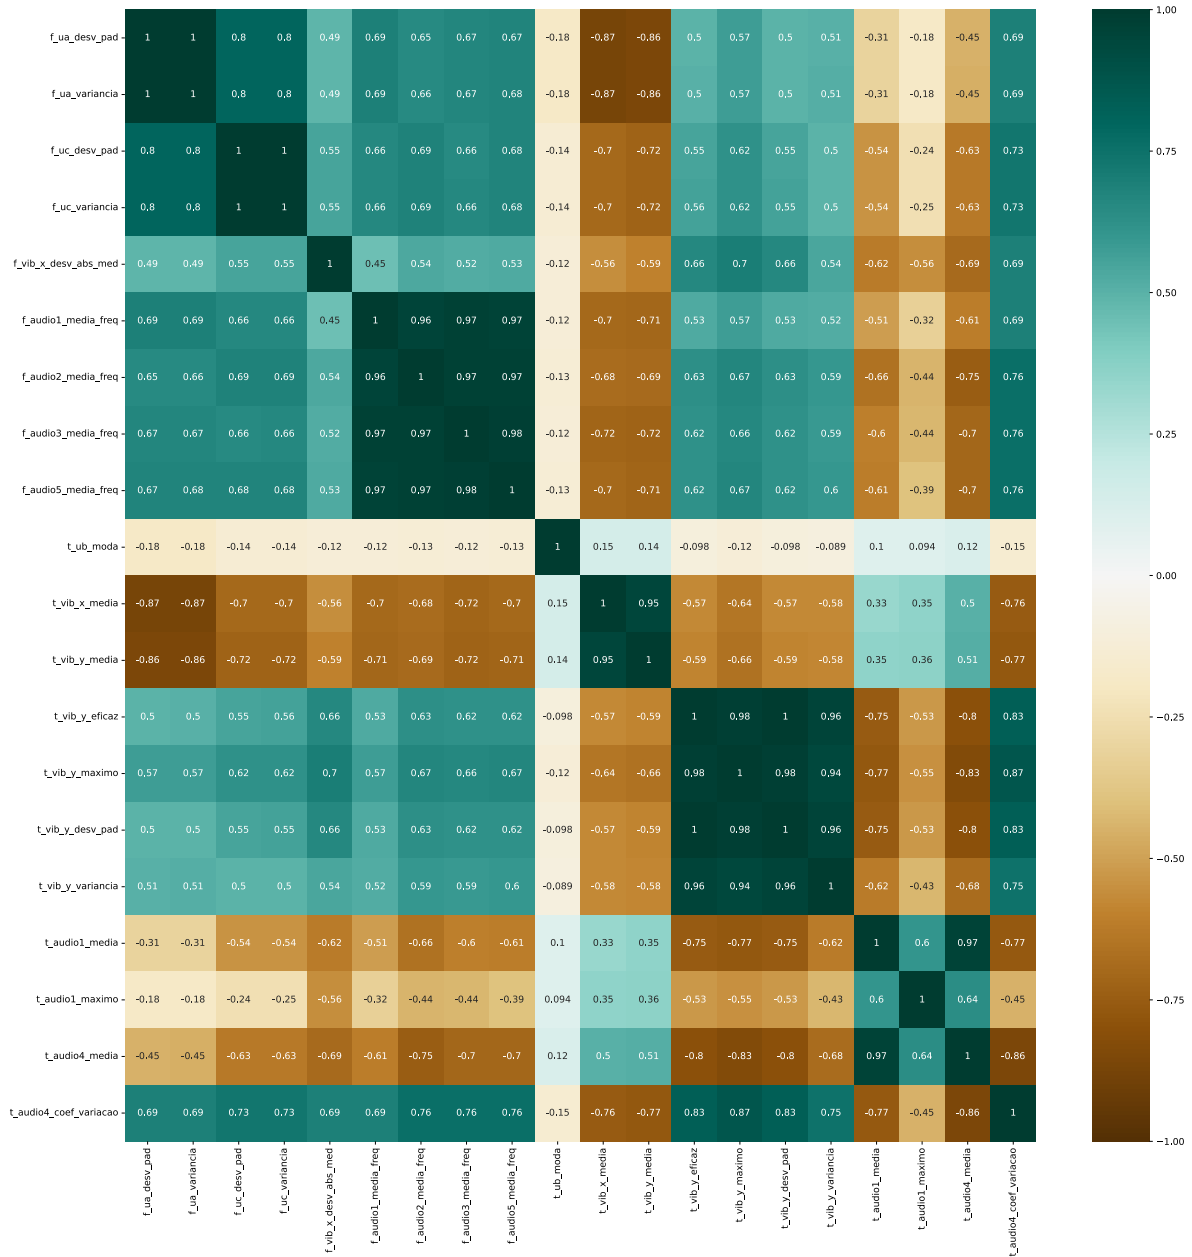
Analisando-se os resultados apresentados verifica-se que para esse tipo de falha, os 20 atributos selecionados através da informação mútua foram provenientes de 10 sensores, a saber: i) Tensão entre A e B (2 atributos); Tensão entre B e C (1 atributo); iii) Tensão entre C e A (2 atributos); iv) Vibração em X (2 atributos); v) Vibração em Y (5 atributos); vi) Áudio 1 (3 atributos); vii) Áudio 2 (1 atributo); viii) Áudio 3 (1 atributo); ix) Áudio 4 (2 atributos); x) Áudio 5 (1 atributo).

Observa-se que para falhas de rotor, os atributos selecionados não são majoritariamente do sensor de Vibração em Y, diferentemente do que ocorreu para a seleção utilizando informação mútua para falha de estator, conforme pode ser observado na Seção 5.3.1.1.1.

Para as falhas de rotor, considerando os 20 melhores atributos, foram selecionados alguns atributos de áudio, diferentemente do que ocorreu para as falhas de estator. Assim, considerando somente o ganho de informação, pode-se afirmar que os dados provenientes da emissão acústica da máquina podem ser úteis para a identificação e classificação de falhas de rotor.

Observando-se a Figura 47, verifica-se que as maiores correlações entre os atributos e sensores selecionados ocorre entre os atributos do sensor de vibração em Y, assim como observado na Seção 5.3.1.1.1, e os atributos dos sensores de áudio, haja visto que os sensores de áudio apresentam a informação do mesmo sinal.

Figura 47 – Correlação entre os atributos selecionados utilizando informação mútua para falha de rotor no motor de 1CV.



Fonte: Autoria Própria.

5.3.1.1.3 Informação mútua para falha de desgaste de rolamento

Aplicando a medida de informação mútua para os ensaios saudável e com falha de rolamento obtém-se os atributos mostrados na Tabela 9. A Figura 48 ilustra os coeficientes de correlação entre os atributos selecionados.

Tabela 9 – Atributos selecionados a partir da informação mútua para falha de desgaste de rolamento no motor de 1CV.

Sensor	Domínio	Atributo
Áudio 3	Tempo	Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
Áudio 4	Tempo	Média
		Valor Eficaz
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
Áudio 5	Tempo	Média
		Valor Eficaz
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância

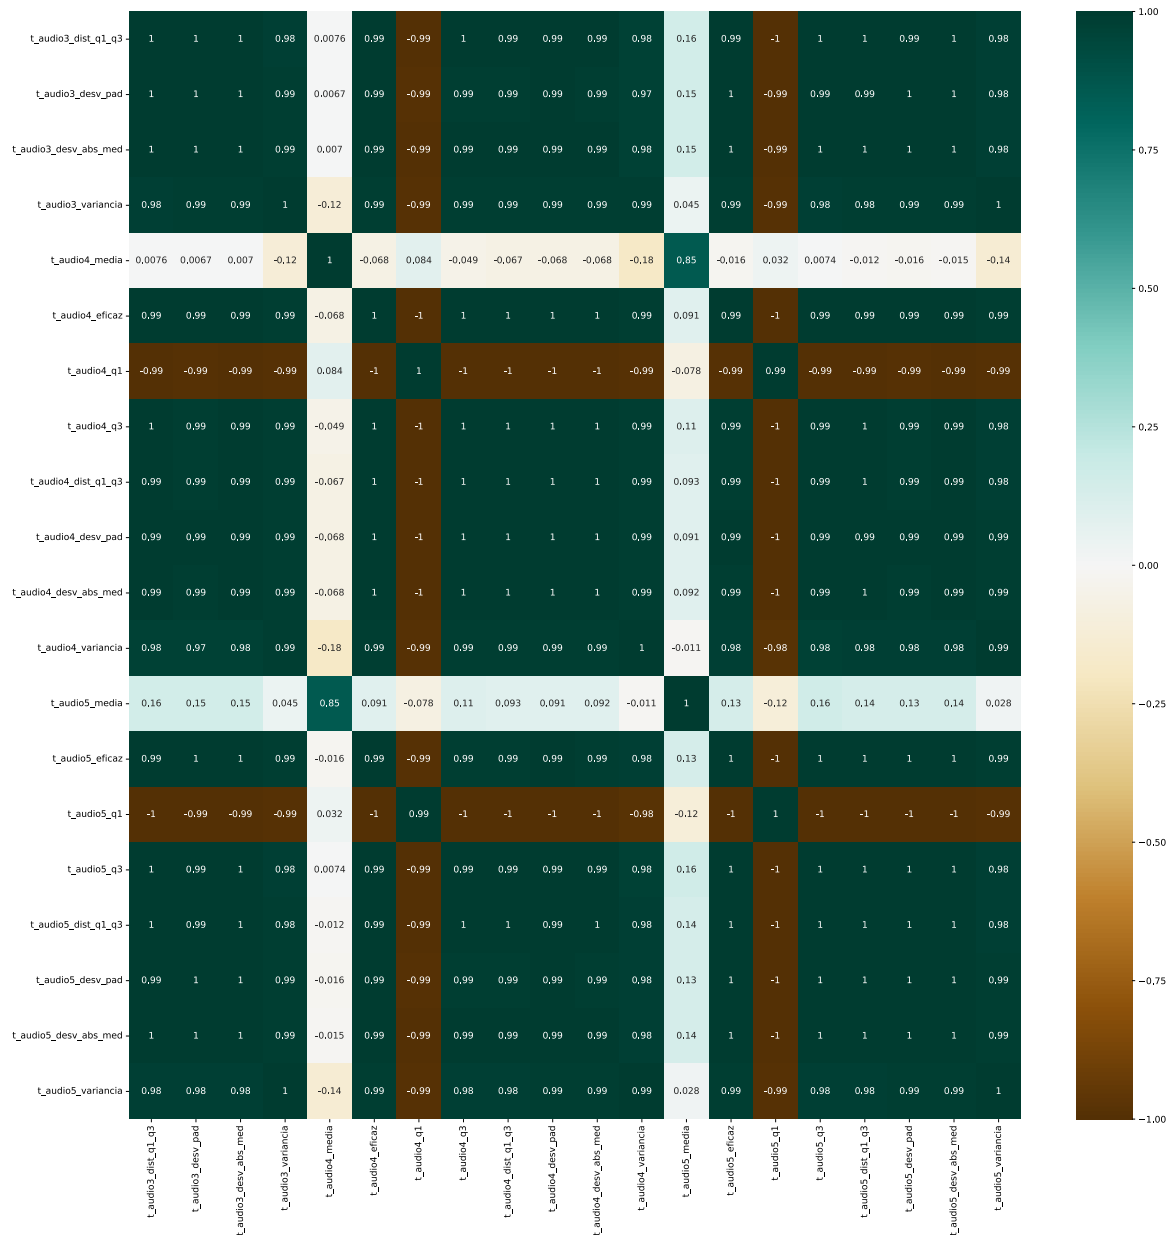
Autoria própria.

Analisando-se os resultados apresentados verifica-se que para falha de rolamento os atributos de áudio são mais relevantes, sendo que os 20 atributos selecionados através da informação mútua foram provenientes de 3 sensores, a saber: i) Áudio 3 (4 atributos); ii) Áudio 4 (4 atributos); iii) Áudio 5 (8 atributos).

O fato de todos os atributos selecionados através da informação mútua serem de sensores de áudio ocorreu pois quando um motor apresenta falha de rolamento, a emissão acústica da máquina é maior do que para os outros tipos de falhas. Isso faz com que os sensores de áudio apresentem um maior ganho de informação quando comparados aos sensores das demais variáveis.

A seleção somente de atributos de sensores de áudio trouxe o problema da multicolinearidade conforme apresentado na Figura 48. A multicolinearidade apresentada pelos atributos dos sensores de áudio se deve ao fato da resposta desses sensores serem muito parecidas entre si. Assim, pode-se inferir que existe uma grande correlação entre as respostas de um sensor de áudio quando comparadas com a resposta de outro sensor de áudio.

Figura 48 – Correlação entre os atributos selecionados utilizando informação mútua para falha de desgaste de rolamento no motor de 1CV.



Fonte: Autoria Própria.

5.3.1.2 Seleção dos atributos utilizando VIF

Nesta seção são apresentados os melhores atributos utilizando VIF. Para isso, foi definido que seriam selecionados os atributos que apresentassem VIF menor que 5. Nas Subseção 5.3.1.2.1, Subseção 5.3.1.2.2 e Subseção 5.3.1.2.3 são apresentados os resultados obtidos utilizando o VIF.

5.3.1.2.1 VIF para falha de estator

Aplicando o método VIF para os ensaios saudável e com falha de estator obteve-se os atributos mostrados na Tabela 10 como sendo os melhores para a identificação deste tipo de falha. Na Figura 49 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 10 – Atributos selecionados a partir do VIF para falha de estator no motor de 1CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Moda
	Tempo	Moda Coeficiente de variação
Corrente A	Frequência	Moda
	Tempo	Moda
Corrente B	Frequência	Moda
		Média
	Tempo	Mediana
		Moda
		Variância Coeficiente de variação
Corrente C	Frequência	Moda
		Mediana
	Tempo	Moda
		Variância Coeficiente de variação
Tensão entre A e B	Frequência	Moda
	Tempo	Mediana
		Moda Coeficiente de variação
Tensão entre B e C	Frequência	Moda
	Tempo	Moda
Tensão entre C e A	Frequência	Moda
	Tempo	Moda
Vibração em X	Frequência	Moda
	Tempo	Mediana Moda
Vibração em Y	Frequência	Moda
	Tempo	Moda Variância
Vibração em Z	Frequência	Moda
	Tempo	Moda
Áudio 1	Frequência	Moda
	Tempo	Moda
Áudio 2	Frequência	Moda
	Tempo	Moda
Áudio 3	Frequência	Moda
		Média
	Tempo	Mediana
		Moda Coeficiente de variação
Áudio 4	Frequência	Moda
	Tempo	Moda
Áudio 5	Frequência	Moda


(continua)

Tabela 10 – Atributos selecionados a partir do VIF para falha de estator no motor de 1CV. (continuação)

Sensor	Domínio	Atributo	
		Tempo	Moda
		Coeficiente de variação	

Autoria própria.

Figura 49 – Correlação entre os atributos selecionados utilizando VIF para falha de estator no motor de 1CV.



Fonte: Autoria Própria.

Analisando-se os resultados apresentados pela seleção dos atributos utilizando VIF é possível observar que todos os 15 sensores possuem alguma informação que

não apresenta multicolinearidade com as demais. Dessa forma, essas variáveis não são dependentes entre si, o que garante que cada um dos sensores apresenta alguma característica que o diferencia das demais, ou seja, cada um dos sensores apresentam respostas distintas para a mesma condição de operação da máquina, permitindo que cada sensor possa contribuir para a identificação das falhas de estator.

Dos 46 atributos selecionados, os sensores que apresentaram maior número de atributos selecionados foram: i) Corrente B (6 atributos); ii) Corrente C (5 atributos), iii) Áudio 3 (5 atributos); iv) Tensão entre A e B (4 atributos).

Um fato observado com a utilização da seleção de atributos por meio do VIF em comparação com o uso da informação mútua é o aumento da quantidade de sensores selecionados pelo VIF. Além disso, considerando que o VIF elimina atributos que apresentam alta dependência com outro atributo, tem-se que a multicolinearidade entre os atributos selecionados pelo VIF é baixa.

5.3.1.2.2 VIF para falha de rotor

Aplicando o VIF para os ensaios saudável e com falha de rotor obteve-se os atributos mostrados na Tabela 11 como sendo os melhores para a identificação deste tipo de falha. Na Figura 50 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 11 – Atributos selecionados a partir do VIF para falha de rotor no motor de 1CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Moda
		Mediana
	Tempo	Moda
		Coeficiente de Variação
Corrente A	Frequência	Moda
	Tempo	Moda
Corrente B	Frequência	Moda
		Mediana
	Tempo	Moda
		Coeficiente de Variação
Corrente C	Frequência	Moda
		Mediana
	Tempo	Moda
		Coeficiente de Variação
Tensão entre A e B	Frequência	Moda
		Mediana
	Tempo	Moda
		Coeficiente de Variação
Tensão entre B e C	Frequência	Moda

(continua)

Tabela 11 – Atributos selecionados a partir do VIF para falha de rotor no motor de 1CV.

(continuação)		
Sensor	Domínio	Atributo
	Tempo	Moda
Tensão entre C e A	Frequência	Moda
	Tempo	Moda
Vibração em X	Frequência	Moda
	Tempo	Mediana
Vibração em Y	Frequência	Moda
	Tempo	Moda
Vibração em Z	Frequência	Moda
	Tempo	Moda
Áudio 1	Frequência	Moda
	Tempo	Moda
Áudio 2	Frequência	Moda
	Tempo	Moda
Áudio 3	Frequência	Moda
	Tempo	Média
		Moda
Áudio 4	Frequência	Moda
	Tempo	Moda
Áudio 5	Frequência	Moda
	Tempo	Moda
		Coeficiente de Variação

Autoria própria.

A seleção de atributos utilizando VIF para falha de rotor também apresentou atributos dos 15 sensores analisados. Este resultado confirma que estes sensores possuem alguma informação que não apresenta multicolinearidade com as demais, ou seja, que essas variáveis não são dependentes entre si.


Dos 42 atributos selecionados, os sensores que apresentaram maior número de atributos selecionados, com 4 atributos selecionado cada, foram: i) Fluxo; ii) Corrente B; iii) Corrente C; iv) Tensão entre A e B; v) Áudio 3.

Observa-se que a maioria dos atributos selecionados são atributos no domínio do tempo, sendo que o atributo no domínio da frequência se resume à moda.

5.3.1.2.3 VIF para falha de desgaste de rolamento

Aplicando o VIF para os ensaios saudável e com falha de rolamento obteve-se os atributos mostrados na Tabela 12 como sendo os melhores para a identificação deste tipo de falha. Na Figura 51 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Figura 50 – Correlação entre os atributos selecionados utilizando VIF para falha de rotor no motor de 1CV.



Fonte: Autoria Própria.

Tabela 12 – Atributos selecionados a partir do VIF para falha de desgaste de rolamento no motor de 1CV.

Sensor	Domínio	Atributo	
		Fluxo	Moda
Fluxo	Frequência	Mediana	
		Tempo	Moda
		Coeficiente de Variação	
Corrente A	Frequência	Moda	
	Tempo	Moda	
	Frequência	Moda	
Corrente B	Tempo	Mediana	

(continua)

Tabela 12 – Atributos selecionados a partir do VIF para falha de desgaste de rolamento no motor de 1CV.


(continuação)		
Sensor	Domínio	Atributo
		Moda
		Coeficiente de Variação
Corrente C	Frequência	Moda
	Tempo	Mediana
		Moda
		Coeficiente de Variação
Tensão entre A e B	Frequência	Moda
	Tempo	Mediana
		Moda
		Coeficiente de Variação
Tensão entre B e C	Frequência	Moda
	Tempo	Mediana
		Moda
Tensão entre C e A	Frequência	Moda
	Tempo	Moda
Vibração em X	Frequência	Moda
	Tempo	Mediana
		Moda
Vibração em Y	Frequência	Moda
	Tempo	Mediana
		Moda
		Variância
Vibração em Z	Frequência	Moda
	Tempo	Moda
Áudio 1	Frequência	Moda
	Tempo	Moda
Áudio 2	Frequência	Moda
	Tempo	Mediana
Áudio 3	Frequência	Moda
		Mediana
	Tempo	Moda
Áudio 4	Frequência	Moda
	Tempo	Moda
Áudio 5	Frequência	Moda
	Tempo	Moda
		Coeficiente de Variação

Autoria própria.

A exemplo da seleção de atributos utilizando VIF para falha de estator e rotor, a seleção de atributos utilizando VIF para falha de rolamento também apresentou atributos dos 15 sensores analisados. Assim, este resultado reforça o conceito de que esses sensores possuem alguma informação que não apresenta multicolinearidade com as demais, ou seja, que essas variáveis não são dependentes entre si.

Dos 45 atributos selecionados, os sensores que apresentaram maior número de atributos selecionados, com 4 atributos selecionado cada, foram: i) Fluxo; ii) Corrente B; iii) Corrente C e iv) Tensão entre A e B; v) Vibração em Y.

Figura 51 – Correlação entre os atributos selecionados utilizando VIF para falha de desgaste de rolamento no motor de 1CV.



Fonte: Autoria Própria.

A exemplo da seleção utilizando VIF para as outras duas falhas, pode-se observar que a maioria dos atributos selecionados são atributos no domínio do tempo. Este fato mostra que a utilização de atributos estatísticos no domínio na frequência tem pouca validade, uma vez que todos eles possuem alta correlação com os atributos no domínio do tempo selecionados, ou com os poucos atributos no domínio da frequência.

5.3.1.3 Seleção dos atributos utilizando *Random Forest*

Para a seleção dos melhores atributos utilizando o *Random Forest*, foi definido que inicialmente seria realizada a busca em grade para definição dos melhores parâmetros para a construção do *Random Forest*. Assim, a partir da busca em grade, os parâmetros do *Random Forest* foram definidos a partir da configuração que apresentasse a melhor acurácia na identificação da falha, considerando inicialmente que todos os atributos poderiam ser utilizados na construção das árvores. A partir dos parâmetros selecionados, procedeu-se com a seleção dos melhores atributos a partir da utilização do *Random Forest*.

Nas Subseção 5.3.1.3.1, Subseção 5.3.1.3.2 e Subseção 5.3.1.3.3 são apresentados os resultados obtidos utilizando o *Random Forest*.

5.3.1.3.1 *Random Forest* para falha de estator

Para falha de estator, a partir da busca em grade, obteve-se os seguintes parâmetros:

- Número de árvores de decisão: 150;
- Número de níveis de cada árvore de decisão: 4;
- Número máximo de atributos em cada árvore de decisão: 30;
- Acurácia: 100%;

Aplicando o *Random Forest* como seletor de atributos, configurado com os parâmetros apresentados anteriormente obteve-se os atributos mostrados na Tabela 13. Na Figura 52 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 13 – Atributos selecionados a partir do *Random Forest* para falha de estator no motor de 1CV.

Sensor	Domínio	Atributo
Corrente A	Tempo	Média
Corrente C	Tempo	Média
		Coeficiente de Variação
		Máximo
Tensão entre A e B	Frequência	Desvio Padrão
		Variância

(continua)


Tabela 13 – Atributos selecionados a partir do *Random Forest* para falha de estator no motor de 1CV.

(continuação)		
Sensor	Domínio	Atributo
Tensão entre B e C	Tempo	1º Quartil
		3º Quartil
Tensão entre C e A	Frequência	3º Quartil
	Frequência	1º Quartil
Vibração em X	Tempo	Média
		Valor Eficaz
		3º Quartil
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
		Média
Vibração em Y	Frequência	Mediana
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º Quartis
	Tempo	Média
		Mediana
		Valor Eficaz
Vibração em Z	Frequência	Máximo
		Desvio Padrão
		Variância
	Tempo	Mediana
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º Quartis
Áudio 1	Tempo	Máximo
Áudio 2	Frequência	Média Ponderada da Frequência
	Tempo	Valor Eficaz
Áudio 3	Frequência	Desvio Absoluto Médio
Áudio 4	Tempo	Média Ponderada da Frequência
Áudio 5	Frequência	Média
		Média Ponderada da Frequência

Autoria própria.

Analisando-se os resultados apresentados pela seleção dos atributos utilizando *Random Forest* é possível observar que, ao contrário dos atributos selecionados através da utilização da informação mútua e do VIF, os atributos selecionados pelo *Random Forest* são mais variados em termos de tipos de medidas estatísticas. Mais especificamente, possuem maior quantidade de atributos obtidos a partir dos dados no domínio da frequência.

Figura 52 – Correlação entre os atributos selecionados utilizando *Random Forest* para falha de estator no motor de 1CV.



Fonte: Autoria Própria.

Observando-se na Tabela 13 e na Figura 52 os atributos selecionados pelo *Random Forest* apresentam grande variabilidade tanto nos tipos de sensores selecionados, quanto no atributo estatísticos dos dados obtidos por esses sensores. Além disso, observa-se que a correlação entre os atributos selecionados é muito menor do que a correlação entre os atributos selecionados por meio da informação mútua, o que garante que os atributos selecionados por meio do *Random Forest* sejam variáveis, na sua maioria das vezes, independentes.

Dos 46 atributos selecionados, os únicos sensores que não possuíram atributos selecionados foram os sensores de Fluxo e de Corrente B. Ainda, dentre os sensores selecionados, o que apresentou maior quantidade de atributos foi o sensor de Vibração Y, com 16 atributos selecionados, seguido pelos sensores de Vibração em X e em Z, com 7 atributos selecionados cada.

5.3.1.3.2 *Random Forest para falha de rotor*

Para falha de estator, a partir da busca em grade, obteve-se os seguintes parâmetros:

- Número de árvores de decisão: 10;
- Número de níveis de cada árvore de decisão: 2;
- Número máximo de atributos em cada árvore de decisão: 15;
- Acurácia: 100%;

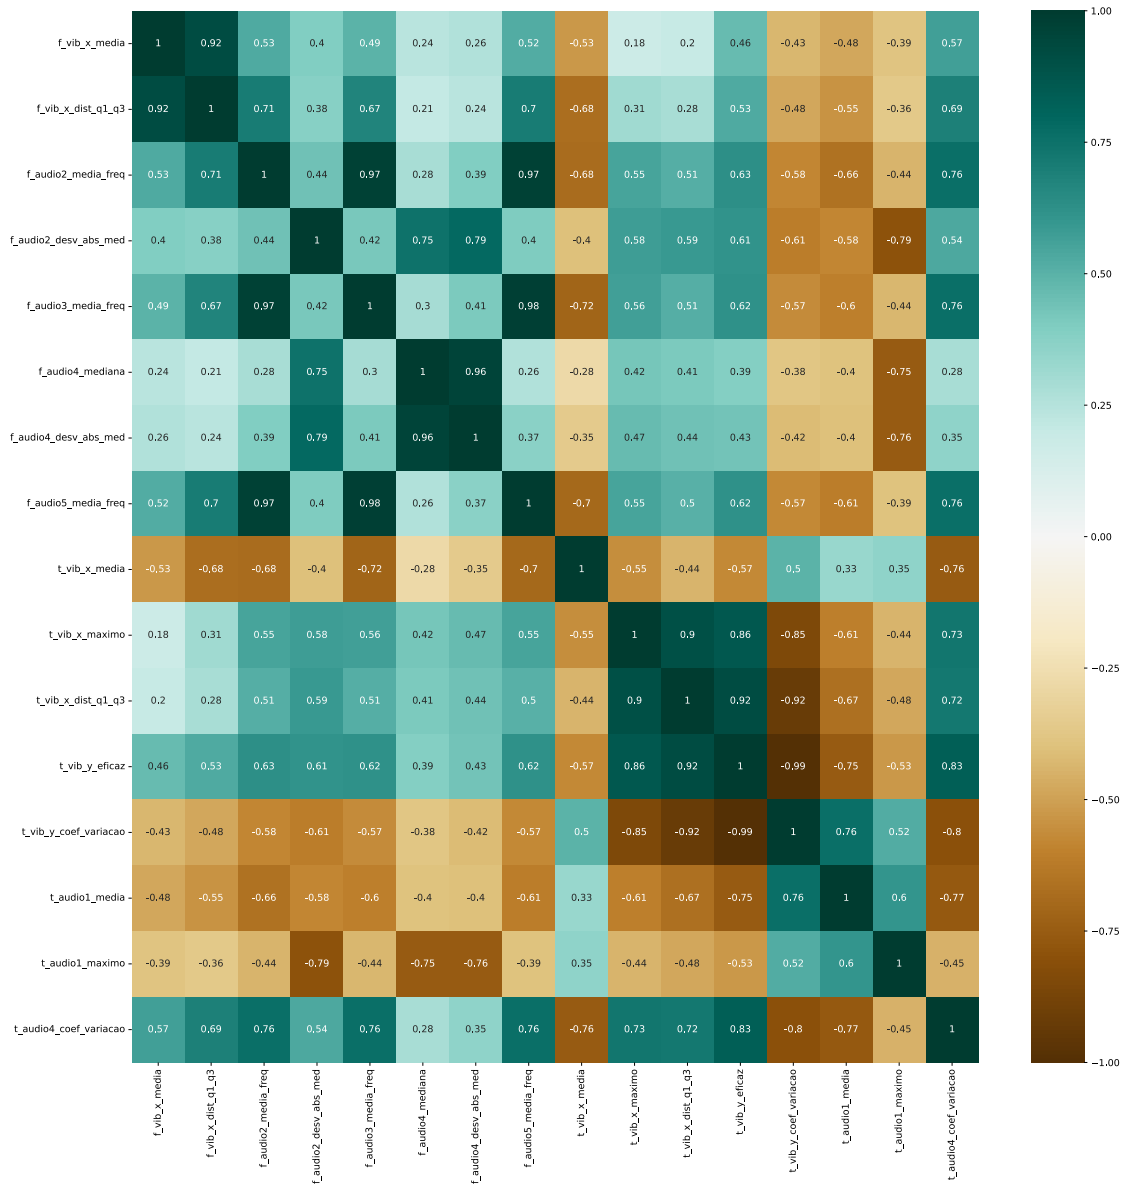
Aplicando o *Random Forest* como seletor de atributos e configurado com os parâmetros apresentados anteriormente, obteve-se os atributos mostrados na Tabela 14. A Figura 53, por sua vez, ilustra os coeficientes de correlação entre os atributos selecionados.

Tabela 14 – Atributos selecionados a partir do *Random Forest* para falha de rotor no motor de 1CV.

Sensor	Domínio	Atributo
Vibração em X	Frequência	Média
		Distância entre o 1º e o 3º Quartis
	Tempo	Média
		Máximo
Vibração em Y	Tempo	Distância entre o 1º e o 3º Quartis
		Valor Eficaz
		Coefficiente de Variação
Áudio 1	Tempo	Média
		Máximo
Áudio 2	Frequência	Média Ponderada da Frequência
Áudio 3	Frequência	Desvio Absoluto Médio
		Média Ponderada da Frequência
Áudio 4	Frequência	Mediana
		Desvio Absoluto Médio
	Tempo	Coefficiente de Variação
Áudio 5	Frequência	Média Ponderada da Frequência

Autoria própria.

Figura 53 – Correlação entre os atributos seleccionados utilizando *Random Forest* para falha de rotor no motor de 1CV.



Fonte: Autoria Própria.

Analisando-se os resultados para seleção dos atributos utilizando *Random Forest* para falha de rotor é possível observar que foram seleccionados apenas 16 atributos provenientes de apenas 7 sensores diferentes, são eles: i) Vibração em X (5 atributos); ii) Vibração em Y (2 atributos); iii) Áudio 1 (2 atributos); iv) Áudio 3 (1 atributo); Áudio 4 (3 atributos); Áudio 5 (1 atributo).

Observa-se que os atributos seleccionados são provenientes tanto do domínio do tempo quanto do domínio da frequência. Ainda, é possível verificar que para falhas de rotor, utilizando *Random Forest* como seletor de atributos, obteve-se uma redução

considerável na quantidade de atributos, o que pode refletir em um menor esforço computacional para a identificação e classificação dessa falha utilizando os atributos estatísticos selecionados.

5.3.1.3.3 *Random Forest para falha de desgaste de rolamento*

Para falha de desgaste de rolamento, a partir da busca em grade, obteve-se os seguintes parâmetros:

- Número de árvores de decisão: 40;
- Número de níveis de cada árvore de decisão: 2;
- Número máximo de atributos em cada árvore de decisão: 2;
- Acurácia: 100%;

Aplicando o *Random Forest* como seletor de atributos obtém-se aqueles mostrados na Tabela 15. Na Figura 54 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 15 – Atributos selecionados a partir do *Random Forest* para falha de desgaste de rolamento no motor de 1CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Média
		Desvio Padrão
Corrente A	Frequência	Variância
	Tempo	Média
Corrente B	Frequência	Variância
	Tempo	Média
Corrente C	Tempo	Coefficiente de Variação
Tensão entre A e B	Frequência	Média Ponderada da Frequência
	Tempo	Média
		3º Quartil
Tensão entre B e C	Frequência	Distância entre o 1º e 3º Quartis
	Tempo	Valor Eficaz
		Desvio Absoluto Médio
Tensão entre C e A	Frequência	Mediana
		Máximo
Vibração em X	Frequência	Distância entre o 1º e 3º Quartis
		Desvio Absoluto Médio
Vibração em Y	Tempo	Desvio Padrão
		Coefficiente de Variação
		Média Ponderada da Frequência
Vibração em Z	Frequência	Moda
		Coefficiente de Variação
		Moda
		Tempo

(continua)

Tabela 15 – Atributos selecionados a partir do *Random Forest* para falha de desgaste de rolamento no motor de 1CV.


(continuação)		
Sensor	Domínio	Atributo
Áudio 1		3º Quartil
		Distância entre o 1º e 3º Quartis
		Variância
		Coeficiente de Variação
	Frequência	Mediana
		Moda
		1º Quartil
		Coeficiente de Variação
	Tempo	1º Quartil
		3º Quartil
Distância entre o 1º e 3º Quartis		
Variância		
Áudio 2	Frequência	Média
		Média Ponderada da Frequência
		1º Quartil
		Distância entre o 1º e 3º Quartis
	Tempo	Desvio Absoluto Médio
		Mediana
		Valor Eficaz
		Máximo
		1º Quartil
		Desvio Padrão
Áudio 3	Frequência	Desvio Absoluto Médio
		Média Ponderada da Frequência
		Moda
	Tempo	3º Quartil
		Valor Eficaz
		Distância entre o 1º e 3º Quartis
Áudio 4	Frequência	1º Quartil
		3º Quartil
		Desvio Padrão
	Tempo	Mediana
		Valor Eficaz
		1º Quartil
Áudio 5	Frequência	Desvio Absoluto Médio
		Média Ponderada da Frequência
		Distância entre o 1º e 3º Quartis
	Tempo	Variância
		Média
		Valor Eficaz
		Desvio Absoluto Médio
		Coeficiente de Variação

Autoria própria.

Analisando-se a Tabela 15 a a Figura 54 do *Random Forest* para a seleção dos atributos associados a falha de rolamento, é possível observar que existem atributos selecionados de todos os 15 sensores analisados.

Os sensores que mais apresentam atributos selecionados dentre os 66 atributos

Figura 54 – Correlação entre os atributos selecionados utilizando *Random Forest* para falha de desgaste de rolamento no motor de 1CV.



Fonte: Autoria Própria.

selecionados no total, são: i) Vibração em Z (8 atributos); ii) Áudio 1 (8 atributos); iii) Áudio 2 (11 atributos); iv) Áudio 4 (7 atributos); v) Áudio 5 (7 atributos).

Observa-se também que há uma alta correlação com os atributos de áudio selecionados, assim como ocorreu com os atributos selecionados pela informação mútua para a falha de rolamento.

5.3.2 Seleção para o motor de 2CV

Neste seção serão mostrados os sensores e seus respectivos atributos selecionados para os ensaios realizados com o motor de 2CV.

5.3.2.1 Seleção dos atributos utilizando informação mútua

Para a seleção dos melhores atributos utilizando informação mútua, foram selecionados os 20 atributos que apresentassem o melhor ganho de informação com a variável alvo (falha ou não falha).

Nas Subseção 5.3.2.1.1, Subseção 5.3.2.1.2 e Subseção 5.3.2.1.3 são apresentados os resultados obtidos utilizando a informação mútua entre as variáveis.

5.3.2.1.1 Informação mútua para falha de estator

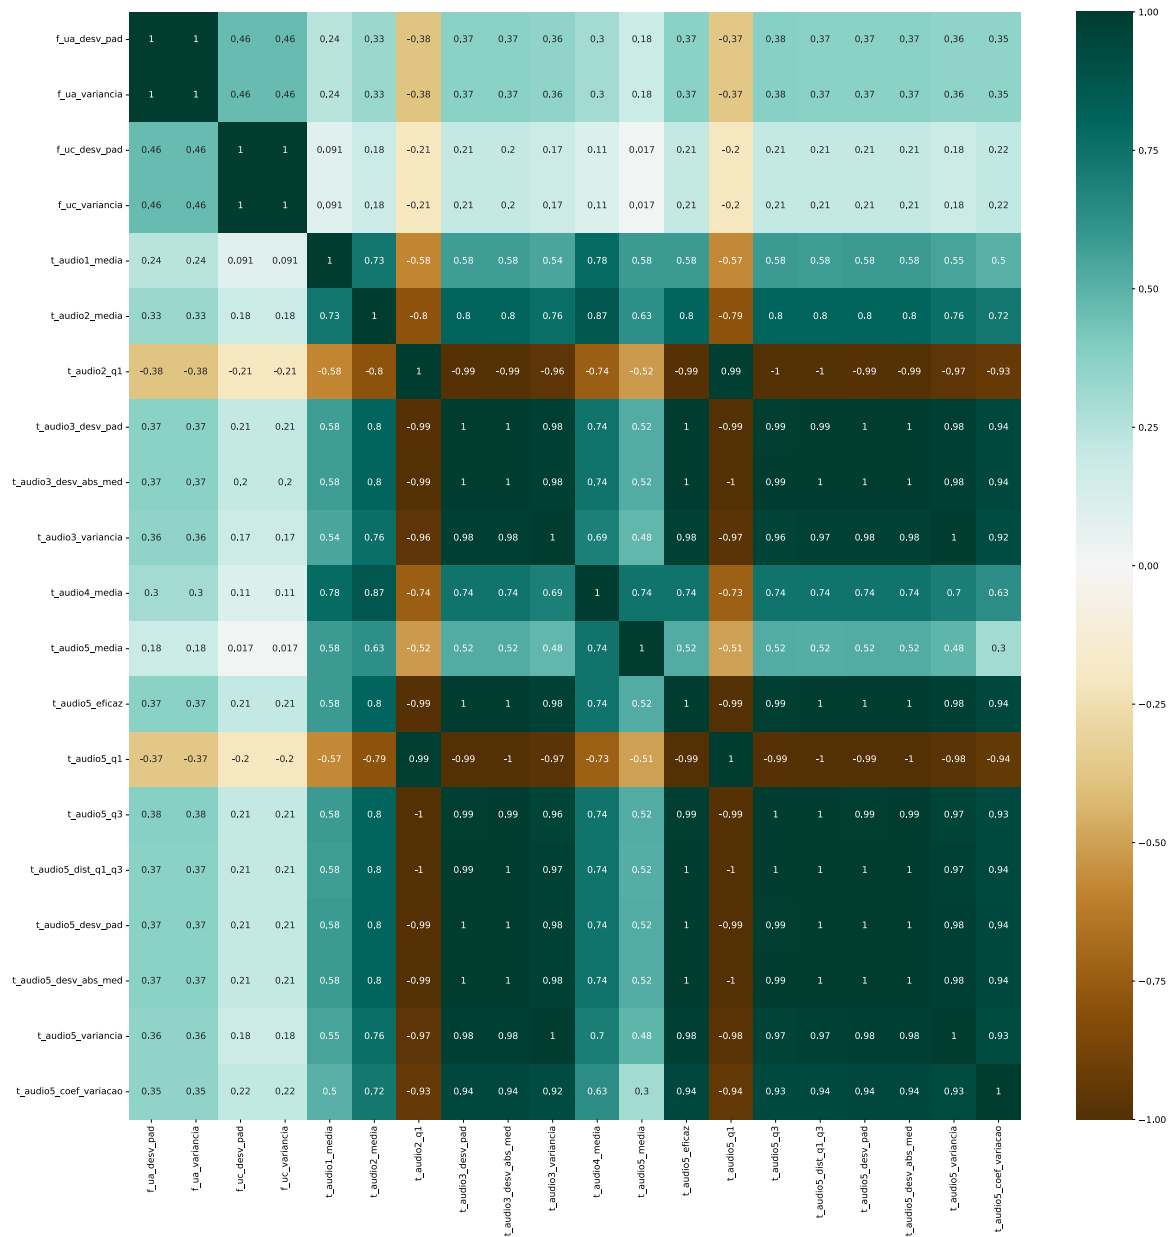
Aplicando a medida de informação mútua para os ensaios saudável e com falha de estator obteve-se os atributos mostrados na Tabela 16 como sendo os melhores para a identificação deste tipo de falha, enquanto na Figura 55 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 16 – Atributos selecionados a partir da informação mútua para falha de estator no motor de 2CV.

Sensor	Domínio	Atributo
Tensão entre A e B	Frequência	Desvio Padrão
		Variância
Tensão entre C e A	Frequência	Desvio Padrão
		Variância
Áudio 1	Tempo	Média
Áudio 2	Tempo	Média
		1º Quartil
Áudio 3	Tempo	Desvio Padrão
		Desvio Absoluto Médio
		Variância
Áudio 4	Tempo	Média
		Média
Áudio 5	Tempo	Valor eficaz
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
Coeficiente de Variação		

Autoria própria.

Figura 55 – Correlação entre os atributos selecionados utilizando informação mútua para falha de estator no motor de 2CV.



Fonte: Autoria Própria.

Analisando-se os resultados apresentados verifica-se os 20 atributos selecionados são provenientes de 7 sensores diferentes, a saber: i) Tensão entre A e B (2 atributos); ii) Tensão entre C e A (2 atributos); iii) Áudio 1 (1 atributo); iv) Áudio 2 (2 atributos); v) Áudio 3 (3 atributos); vi) Áudio 4 (1 atributo); vii) Áudio 5 (9 atributos).

Observando-se a Figura 55 verifica-se que, devido aos atributos selecionados serem majoritariamente provenientes de sensores de Áudio, e sabendo que todos os atributos dos sensores de áudio são do domínio do tempo, existe uma grande

correlação entre os atributos seleccionados, que deve, a exemplo do que aconteceu na Seção 5.3.1.1.1, ser considerado um ponto de atenção devido à multicolinearidade entre os atributos.

Observa-se ainda que todos os atributos seleccionados a partir de informação mútua para falha de estator no motor de 2CV são diferentes daqueles seleccionados para o motor de 1CV. Ainda, nenhum sensor seleccionado para o motor de 2CV foi seleccionado para o motor de 1CV. Considerando essa situação, é razoável afirmar que a utilização de informação mútua para seleção dos atributos estudados para falhas de estator não é uma opção tão interessante quando se deseja generalizar os resultados.

5.3.2.1.2 Informação mútua para falha de rotor

Aplicando a medida de informação mútua para os ensaios saudável e com falha de rotor obteve-se os atributos mostrados na Tabela 17 como sendo os melhores para a identificação deste tipo de falha. Já na Figura 56 são ilustrados os coeficientes de correlação entre os atributos seleccionados.

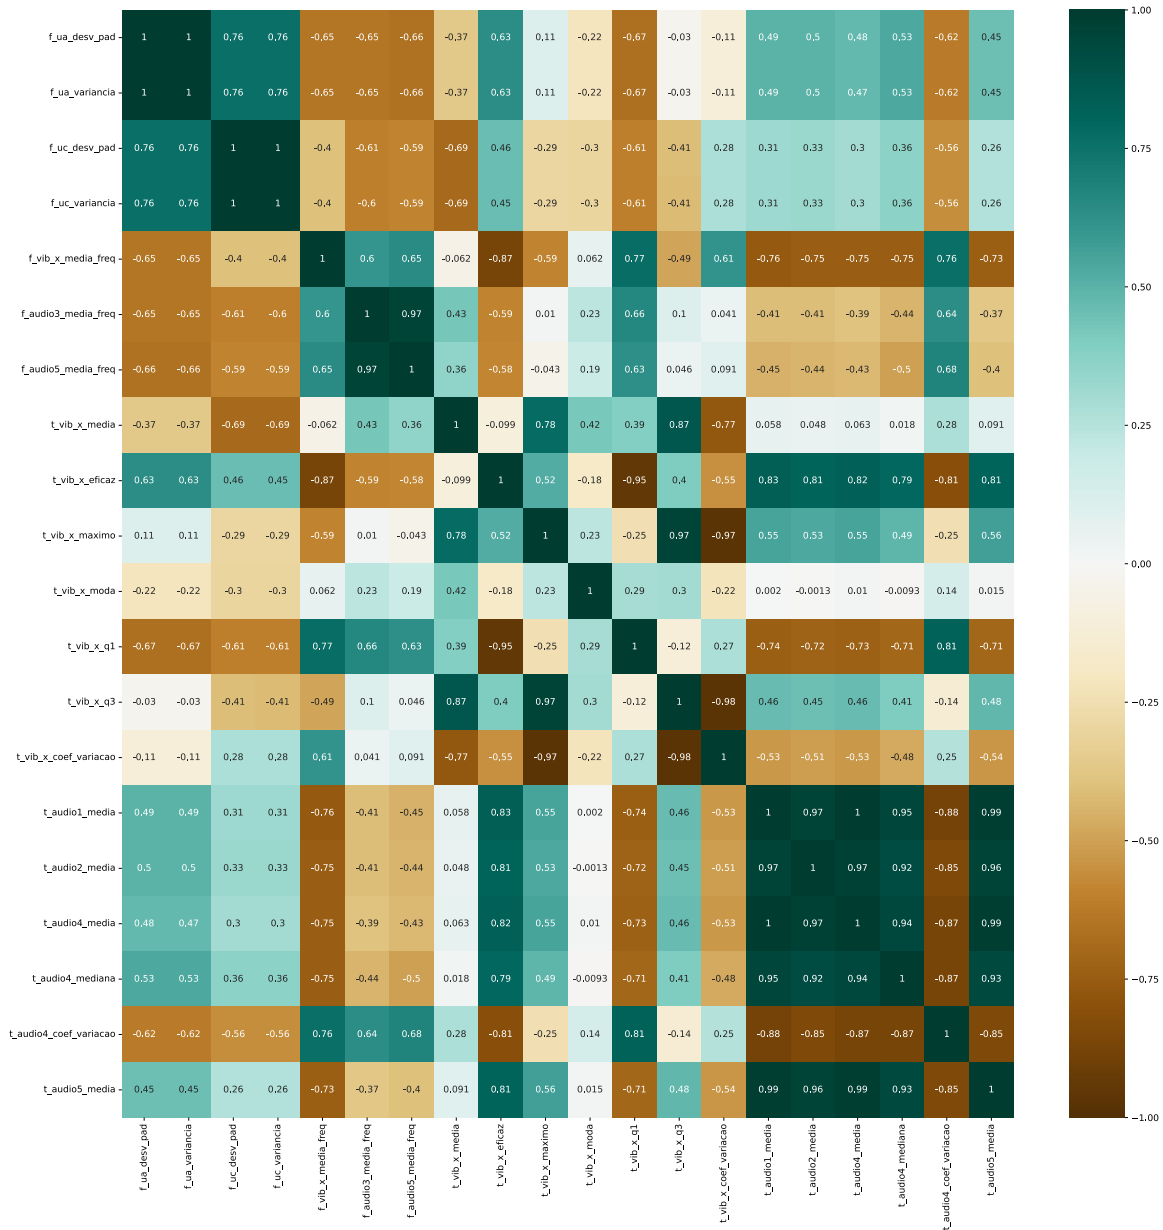
Tabela 17 – Atributos seleccionados a partir da informação mútua para falha de rotor no motor de 2CV.

Sensor	Domínio	Atributo
Tensão entre A e B	Frequência	Desvio Padrão
		Variância
Tensão entre C e A	Frequência	Desvio Padrão
		Variância
Vibração em X	Frequência	Média Ponderada da Frequência
		Média
	Tempo	Valor Eficaz
		Máximo
		Moda
		1º Quartil
		3º Quartil
		Coefficiente de Variação
Áudio 1	Tempo	Média
Áudio 2	Tempo	Média
Áudio 3	Frequência	Média Ponderada da Frequência
Áudio 4	Tempo	Média
		Mediana
		Coefficiente de Variação
Áudio 5	Frequência	Média Ponderada da Frequência
	Tempo	Média

Autoria própria.

Analisando-se os resultados apresentados verifica-se que para esse tipo de falha, os 20 atributos seleccionados através da informação mútua foram provenientes

Figura 56 – Correlação entre os atributos selecionados utilizando informação mútua para falha de rotor no motor de 2CV.



Fonte: Autoria Própria.

de 8 sensores, a saber: i) Tensão entre A e B (2 atributos); Tensão entre C e A (2 atributos); iii) Vibração em X (8 atributos); iv) Áudio 1 (1 atributo); v) Áudio 2 (1 atributo); vi) Áudio 3 (1 atributo); vii) Áudio 4 (3 atributos); viii) Áudio 5 (2 atributos).

Comparando os atributos selecionados para falha de rotor utilizando informação mútua para os motores de 1CV (Seção 5.3.1.1.2) e para os motores de 2CV pode-se observar que dos 20 atributos selecionados em cada grupo, 10 atributos são os mesmos. Além disso, os sensores selecionados para os dois motores fornecem informações das

mesmas medidas físicas (tensão, vibração e emissão acústica).

Diante disso, pode-se considerar que diferentemente da informação mútua para estator, a utilização da seleção dos atributos estudados a partir da informação mútua para falha de rotor pode ser considerada uma candidata para sua utilização em conjunto com um classificador.

5.3.2.1.3 Informação mútua para falha de desgaste de rolamento

Aplicando a medida de informação mútua para os ensaios saudável e com falha de rolamento obtém-se os atributos mostrados na Tabela 18. A Figura 57 ilustra os coeficientes de correlação entre os atributos selecionados.

Tabela 18 – Atributos selecionados a partir da informação mútua para falha de desgaste de rolamento no motor de 2CV.


Sensor	Domínio	Atributo
Áudio 3	Tempo	Coeficiente de Variação
		Média
		Valor Eficaz
		Máximo
		1º Quartil
Áudio 4	Tempo	3º Quartil
		Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
		Coeficiente de Variação
		Valor Eficaz
		Máximo
		1º Quartil
		3º Quartil
Áudio 5	Tempo	Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
		Coeficiente de Variação

Autoria própria.

Analisando-se os resultados apresentados verifica-se que para falha de rolamento, a exemplo do que ocorreu para o motor de 1CV, para o motor de 2CV os atributos de áudio são mais relevantes, sendo que os 20 atributos selecionados através da informação mútua foram provenientes de 3 sensores, a saber: i) Áudio 3 (1 atributo); ii) Áudio 4 (10 atributos); iii) Áudio 5 (9 atributos).

Comparando-se os atributos selecionados utilizando informação mútua para falha de rolamento no motor de 1CV (Seção 5.3.1.1.3) e no motor de 2CV observa-se

Figura 57 – Correlação entre os atributos selecionados utilizando informação mútua para falha de desgaste de rolamento no motor de 2CV.



Fonte: Autoria Própria.

que dos 20 atributos selecionados para cada motor, 15 deles são iguais. Tal fato, assim como para o caso de falha de rotor, torna a seleção de atributos a partir da informação mútua para casos de falhas de rolamento uma alternativa que deve ser levada em consideração.

Por fim, é possível observar que a seleção somente de atributos de sensores de áudio trouxe o problema da multicolinearidade conforme apresentado na Figura 57, assim como observado também no caso do motor de 1CV.

5.3.2.2 Seleção dos atributos utilizando VIF

Nesta seção são apresentados os melhores atributos utilizando VIF. Para isso, foi definido que seriam selecionados os atributos que apresentassem VIF menor que 5. Nas Subseção 5.3.2.2.1, Subseção 5.3.2.2.2 e Subseção 5.3.2.2.3 são apresentados os resultados obtidos utilizando o VIF.

5.3.2.2.1 VIF para falha de estator

Aplicando o método VIF para os ensaios saudável e com falha de estator obteve-se os atributos mostrados na Tabela 19 como sendo os melhores para a identificação deste tipo de falha. Na Figura 58 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 19 – Atributos selecionados a partir do VIF para falha de estator no motor de 2CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Moda
	Tempo	Moda
		Coeficiente de Variação
Corrente A	Frequência	Moda
	Tempo	Mediana
		Moda
Corrente B	Frequência	Moda
	Tempo	Mediana
		Moda
Corrente C	Frequência	Moda
	Tempo	Mediana
		Coeficiente de Variação
Tensão entre A e B	Frequência	Moda
	Tempo	Mediana
		Coeficiente de Variação
Tensão entre B e C	Frequência	Moda
	Tempo	Mediana
		Moda
Tensão entre C e A	Frequência	Moda
	Tempo	Mediana
		Moda
Vibração em X	Frequência	Moda
	Tempo	Mediana
		Variância
Vibração em Y	Frequência	Moda
	Tempo	Moda
Vibração em Z	Frequência	Moda
	Tempo	Moda

(continua)

Tabela 19 – Atributos selecionados a partir do VIF para falha de estator no motor de 2CV.

(continuação)		
Sensor	Domínio	Atributo
		Variância
Áudio 1	Frequência	Moda
	Tempo	Moda
Áudio 2	Frequência	Moda
	Tempo	Moda
Áudio 3	Frequência	Moda
		Mediana
	Tempo	Moda
		Coeficiente de Variação
Áudio 4	Frequência	Moda
		Mediana
	Tempo	Moda
Áudio 5	Frequência	Moda
	Tempo	Moda

Autoria própria.

Assim como observado para o caso do motor de 1CV (Seção 5.3.1.2.1), a seleção dos atributos utilizando VIF para falhas de estator no motor de 2CV selecionou atributos dos 15 sensores.

Dos 47 atributos selecionados, os sensores que apresentaram maior número de atributos selecionados (4 atributos para cada sensor) foram os sensores: i) Corrente B; ii) Corrente C, iii) Tensão entre A e B; iv) Vibração em X; v) Áudio 3; vi) Áudio 4.

Comparando-se os resultados obtidos para o motor de 2CV com os resultados para o motor de 1CV observa-se que 40 dos atributos selecionados utilizando VIF para falha de estator são comuns a ambos os motores.

5.3.2.2.2 VIF para falha de rotor

Aplicando o VIF para os ensaios saudável e com falha de rotor obteve-se os atributos mostrados na Tabela 20 como sendo os melhores para a identificação deste tipo de falha. Na Figura 59 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 20 – Atributos selecionados a partir do VIF para falha de rotor no motor de 2CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Moda
		Mediana
	Tempo	Moda
		Coeficiente de Variação
Corrente A	Frequência	Moda

(continua)

Tabela 20 – Atributos selecionados a partir do VIF para falha de rotor no motor de 2CV.

(continuação)		
Sensor	Domínio	Atributo
Corrente B	Tempo	Moda
	Frequência	Moda
	Tempo	Mediana
		Moda
		Coeficiente de Variação
Corrente C	Frequência	Moda
	Tempo	Mediana
		Moda
Tensão entre A e B	Frequência	Moda
	Tempo	Mediana
		Moda
Tensão entre B e C	Frequência	Moda
	Tempo	Mediana
		Moda
Tensão entre C e A	Frequência	Moda
	Tempo	Moda
Vibração em X	Frequência	Moda
	Tempo	Moda
		Variância
Vibração em Y	Frequência	Moda
	Tempo	Mediana
		Moda
Vibração em Z	Frequência	Moda
	Tempo	Moda
Áudio 1	Frequência	Moda
	Tempo	Moda
Áudio 2	Frequência	Moda
	Tempo	Moda
Áudio 3	Frequência	Moda
	Tempo	Mediana
Áudio 4	Frequência	Moda
	Tempo	Moda
Áudio 5	Frequência	Moda
	Tempo	Moda

Autoria própria.

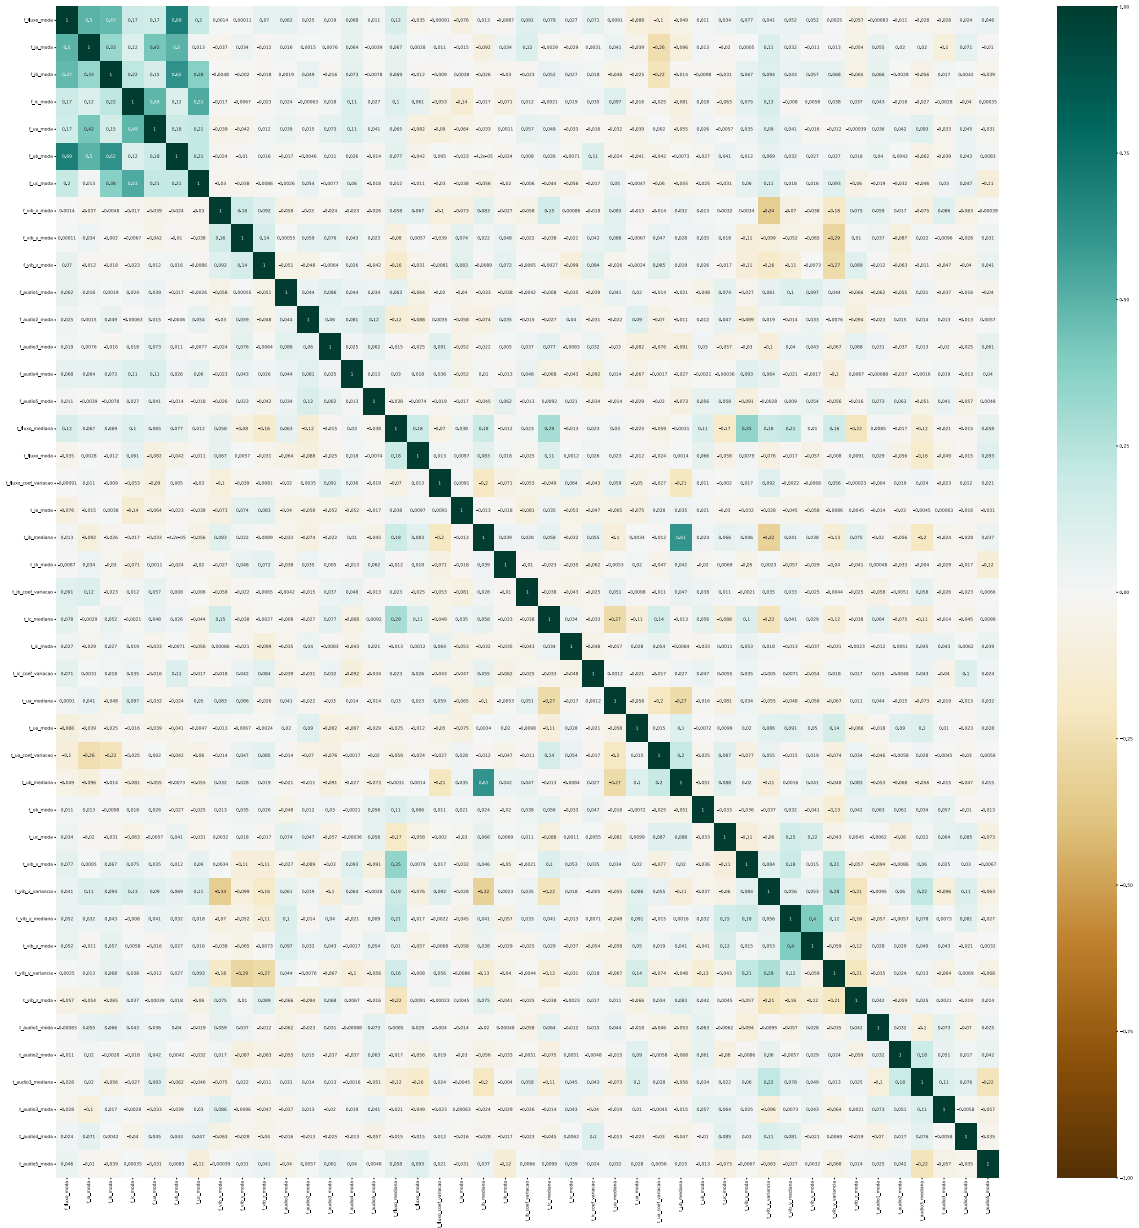
A seleção de atributos utilizando VIF para falha de rotor também apresentou atributos dos 15 sensores analisados.

Dos 43 atributos selecionados, os sensores que apresentaram maior número de atributos selecionados (4 atributos para cada sensor) foram: i) Fluxo; ii) Corrente B, iii) Corrente C; iv) Tensão entre A e B; v) Vibração em Y.

Observa-se que a maioria dos atributos selecionados são atributos no domínio do tempo, sendo que o atributo no domínio da frequência se resume à moda.

Comparando-se os resultados obtidos para o motor de 2CV com os resultados

Figura 59 – Correlação entre os atributos selecionados utilizando VIF para falha de rotor no motor de 2CV.



Fonte: Autoria Própria.

deste tipo de falha. Na Figura 60 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 21 – Atributos selecionados a partir do VIF para falha de desgaste de rolamento no motor de 2CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Moda
	Tempo	Moda
Corrente A	Frequência	Coefficiente de Variação
		Moda

(continua)

Tabela 21 – Atributos selecionados a partir do VIF para falha de desgaste de rolamento no motor de 2CV.

(continuação)		
Sensor	Domínio	Atributo
Corrente B	Tempo	Moda
	Frequência	Moda
		Média
	Tempo	Moda
		Coeficiente de Variação
Corrente C	Frequência	Moda
	Tempo	Mediana
		Moda
		Variância
		Coeficiente de Variação
Tensão entre A e B	Frequência	Moda
	Tempo	Mediana
		Moda
		Coeficiente de Variação
Tensão entre B e C	Frequência	Moda
	Tempo	Mediana
		Moda
Tensão entre C e A	Frequência	Moda
	Tempo	Moda
Vibração em X	Frequência	Moda
	Tempo	Mediana
		Moda
Vibração em Y	Frequência	Moda
	Tempo	Mediana
		Moda
Vibração em Z	Frequência	Moda
	Tempo	Moda
Áudio 1	Frequência	Moda
Áudio 2	Frequência	Moda
	Tempo	Moda
		Coeficiente de Variação
Áudio 3	Frequência	Moda
	Tempo	Média
		Coeficiente de Variação
Áudio 4	Frequência	Moda
Áudio 5	Frequência	Moda
	Tempo	Mediana
		Moda


Autoria própria.

A seleção de atributos utilizando VIF para falha de rolamento também apresentou atributos dos 15 sensores analisados.

Dos 42 atributos selecionados, os sensores que apresentaram maior número de atributos selecionados foram: i) Corrente B (4 atributos); ii) Corrente C (5 atributos); iii) Tensão entre A e B (4 atributos).

Assim como nas falhas de estator e de rotor, a maioria dos atributos selecionados utilizando VIF são atributos no domínio do tempo, sendo que o atributo no domínio

Figura 60 – Correlação entre os atributos selecionados utilizando VIF para falha de desgaste de rolamento no motor de 2CV.



Fonte: Autoria Própria.

da frequência se resume à moda.

Comparando-se os resultados obtidos para o motor de 2CV com os resultados para o motor de 1CV observa-se que 37 dos atributos selecionados utilizando VIF para falha de rolamento são comuns a ambos os motores.

5.3.2.3 Seleção dos atributos utilizando *Random Forest*

Para a seleção dos melhores atributos utilizando o *Random Forest*, foi definido que inicialmente seria realizada a busca em grade para definição dos melhores parâmetros para a construção do *Random Forest*. Assim, a partir da busca em grade, os parâmetros do *Random Forest* foram definidos a partir da configuração que apresentasse a melhor acurácia na identificação da falha, considerando inicialmente que todos os atributos poderiam ser utilizados na construção das árvores. A partir dos parâmetros selecionados, procedeu-se com a seleção dos melhores atributos a partir da utilização do *Random Forest*.

Nas Subseção 5.3.2.3.1, Subseção 5.3.2.3.2 e Subseção 5.3.2.3.3 são apresentados os resultados obtidos utilizando o *Random Forest*.

5.3.2.3.1 *Random Forest* para falha de estator

Para falha de estator, a partir da busca em grade, obteve-se os seguintes parâmetros:

- Número de árvores de decisão: 40;
- Número de níveis de cada árvore de decisão: 10;
- Número máximo de atributos em cada árvore de decisão: 30;
- Acurácia: 96,08%;

Aplicando o *Random Forest* como seletor de atributos, configurado com os parâmetros apresentados anteriormente obteve-se os atributos mostrados na Tabela 22. Na Figura 61 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 22 – Atributos selecionados a partir do *Random Forest* para falha de estator no motor de 2CV.

Sensor	Domínio	Atributo
Corrente A	Frequência	Mediana
		Média Ponderada da Frequência
Corrente B	Frequência	1º Quartil
		Mediana
		1º Quartil

(continua)

Tabela 22 – Atributos selecionados a partir do *Random Forest* para falha de estator no motor de 2CV.

(continuação)		
Sensor	Domínio	Atributo
Corrente C	Frequência	Mediana
		1º Quartil
Tensão entre A e B	Frequência	Máximo
		Desvio Padrão
	Tempo	Variância
		1º Quartil
Tensão entre B e C	Frequência	Desvio Padrão
		Valor eficaz
	Tempo	Máximo
		1º Quartil
		3º Quartil
		Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Desvio Absoluto Médio
Tensão entre C e A	Frequência	Variância
		Desvio Padrão
	Tempo	Moda
Vibração em X	Tempo	Média
		Máximo
		1º Quartil
		Desvio Padrão
Vibração em Y	Tempo	Mediana
		Coefficiente de Variação
Vibração em Z	Frequência	Mediana
	Tempo	1º Quartil
Áudio 1	Frequência	Mediana
		1º Quartil
		Média Ponderada da Frequência
	Tempo	Desvio Padrão
		Variância
		Média
		Máximo
		3º Quartil
Áudio 2	Frequência	Distância entre o 1º e o 3º Quartis
		Variância
		Mediana
		1º Quartil
	Tempo	3º Quartil
		Distância entre o 1º e o 3º Quartis
		Desvio Padrão
		Média
Áudio 3	Frequência	Valor eficaz
		1º Quartil
		Desvio Absoluto Médio
	Tempo	Variância
		Coefficiente de Variação
		Média Ponderada da Frequência
		1º Quartil
Áudio 3	Tempo	Média
		Mediana
		Desvio Padrão
		Variância
		Coefficiente de Variação

(continua)

Tabela 22 – Atributos selecionados a partir do *Random Forest* para falha de estator no motor de 2CV.

(continuação)		
Sensor	Domínio	Atributo
Áudio 4	Frequência	1º Quartil
		Média
	Tempo	3º Quartil
		Coeficiente de Variação
		Média Ponderada da Frequência
Áudio 5	Frequência	1º Quartil
		Coeficiente de Variação
		Média
	Tempo	Valor eficaz
		Máximo
		1º Quartil
		3º Quartil
		Desvio Padrão
		Desvio Absoluto Médio
		Variância
		Coeficiente de Variação

Autoria própria.

Observando-se na Tabela 22 e na Figura 61 os atributos selecionados pelo *Random Forest*, a exemplo do ocorreu com o motor de 1CV apresentam grande variabilidade tanto nos tipos de sensores selecionados, quanto no atributo estatísticos dos dados obtidos por esses sensores. Também é possível observar que a correlação entre os atributos selecionados é muito menor do que a correlação entre os atributos selecionados por meio da informação mútua, sendo que as maiores correlações acontecem entre os atributos dos sensores de áudio.

Dos 74 atributos selecionados, o único sensor que não possui atributos selecionados é o sensor de Fluxo. Ainda, dentre os sensores selecionados, o que apresentou maior quantidade de atributos foi o sensor de Áudio 5 (12 atributos), seguido pelos sensores de Áudio 2 (11 atributos) e Tensão entre B e C (9 atributos).

Considerando os atributos selecionados na Seção 5.3.1.3.1, que trata da seleção utilizando *Random Forest* para falha de estator no motor de 1CV, houve 18 atributos selecionados em comum entre os dois tipos de motores.

5.3.2.3.2 *Random Forest* para falha de rotor

Para falha de estator, a partir da busca em grade, obteve-se os seguintes parâmetros:

Aplicando o *Random Forest* como seletor de atributos e configurado com os parâmetros apresentados anteriormente, obteve-se os atributos mostrados na Tabela 23. A Figura 62, por sua vez, ilustra os coeficientes de correlação entre os atributos selecionados.


Tabela 23 – Atributos selecionados a partir do *Random Forest* para falha de rotor no motor de 2CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Variância
	Tempo	Mediana
Corrente B	Frequência	1º Quartil
Corrente C	Frequência	1º Quartil
		Máximo
Tensão entre A e B	Frequência	Desvio Padrão
	Tempo	Variância
Tensão entre B e C	Frequência	Máximo
	Tempo	Desvio Padrão
Tensão entre C e A	Frequência	Variância
		Moda
Vibração em X	Frequência	Desvio Padrão
		Variância
		Média Ponderada da Frequência
		Máximo
	Tempo	Desvio Padrão
		Variância
		Média
		Mediana
Vibração em Z	Tempo	Valor Eficaz
		Moda
		Variância
		Desvio Padrão
Áudio 1	Tempo	Média
		Mediana
		Variância
		Coefficiente de Variação
Áudio 2	Frequência	Média Ponderada da Frequência
	Tempo	1º Quartil
Áudio 3	Frequência	Média
		Mediana
Áudio 4	Tempo	Valor Eficaz
		Distância entre o 1º e o 3º Quartis
		Variância
		Coefficiente de Variação
Áudio 5	Frequência	Média Ponderada da Frequência
		Máximo
	Tempo	Desvio Padrão
		Média

Autoria própria.

Analisando-se os resultados é possível observar que os atributos selecionados

Figura 62 – Correlação entre os atributos selecionados utilizando *Random Forest* para falha de rotor no motor de 2CV.



Fonte: Autoria Própria.

utilizando *Random Forest* para falha de rotor no motor de 2CV são provenientes de 13 tipos de sensores diferentes. Os únicos sensores que não tiveram atributos selecionados são os sensores Corrente A e Vibração em Y. Tais resultados destoam do obtido a partir do motor de 1CV.

Dos 43 atributos selecionados, o sensor que apresentou maior quantidade de atributos foi o sensor de Vibração em X (10 atributos), seguido pelo sensor de Áudio 4 (6 atributos).

Considerando os atributos selecionados na Seção 5.3.1.3.2, que trata da seleção utilizando *Random Forest* para falha de rotor no motor de 1CV, houve 6 atributos selecionados em comum entre os dois tipos de motores. Em um primeiro momento esse número pode parecer muito baixo considerando que para o motor de 2CV foram selecionados 43 atributos, no entanto, vale lembrar que para o motor de 1CV para a situação de falha de rotor e seleção por *Random Forest* foram selecionados 16 atributos.

5.3.2.3.3 *Random Forest para falha de desgaste de rolamento*

Para falha de desgaste de rolamento, a partir da busca em grade, obteve-se os seguintes parâmetros:

- Número de árvores de decisão: 120;
- Número de níveis de cada árvore de decisão: 2;
- Número máximo de atributos em cada árvore de decisão: 1;
- Acurácia: 100%;

Aplicando o *Random Forest* como seletor de atributos obtem-se aqueles mostrados na Tabela 24. Na Figura 63 são ilustrados os coeficientes de correlação entre os atributos selecionados.

Tabela 24 – Atributos selecionados a partir do *Random Forest* para falha de desgaste de rolamento no motor de 2CV.

Sensor	Domínio	Atributo
Fluxo	Frequência	Média
		Média Ponderada da Frequência
		3º Quartil
		Distância entre o 1º e 3º Quartis
	Desvio Padrão	
Corrente A	Tempo	Média
		Desvio Absoluto Médio
Corrente B	Frequência	Desvio Padrão
		1º Quartil
		3º Quartil
	Tempo	Desvio Absoluto Médio
		Média
Corrente C	Frequência	Moda
		Moda
		1º Quartil
		Distância entre o 1º e 3º Quartis

(continua)

Tabela 24 – Atributos selecionados a partir do *Random Forest* para falha de desgaste de rolamento no motor de 2CV.

(continuação)		
Sensor	Domínio	Atributo
	Tempo	Mediana
		3º Quartil
Tensão entre A e B	Frequência	Média Ponderada da Frequência
		Máximo
		Distância entre o 1º e 3º Quartis
	Tempo	Variância
		Média
		Mediana
Tensão entre B e C	Tempo	Moda
		Distância entre o 1º e 3º Quartis
		Mediana
		Valor Eficaz
Tensão entre C e A	Frequência	Moda
		3º Quartil
		Variância
	Tempo	Média
		Média Ponderada da Frequência
		Desvio Padrão
Vibração em X	Frequência	Variância
		Média
		Máximo
	Tempo	Moda
		3º Quartil
		Distância entre o 1º e 3º Quartis
Vibração em Y	Frequência	Média
		Média Ponderada da Frequência
		Máximo
	Tempo	3º Quartil
		Mediana
		Moda
		3º Quartil
		Distância entre o 1º e 3º Quartis
		Desvio Padrão
Vibração em Z	Frequência	Desvio Absoluto Médio
		Coefficiente de Variação
		Média
	Tempo	3º Quartil
		Distância entre o 1º e 3º Quartis
		Coefficiente de Variação
	Frequência	Valor Eficaz
		1º Quartil
		Distância entre o 1º e 3º Quartis
	Tempo	Desvio Absoluto Médio
		Variância
		1º Quartil
	Frequência	Variância

(continua)


Tabela 24 – Atributos selecionados a partir do *Random Forest* para falha de desgaste de rolamento no motor de 2CV.

(continuação)			
Sensor	Domínio	Atributo	
	Tempo	Média	
		Moda	
		1º Quartil	
		3º Quartil	
		Desvio Padrão	
	Áudio 2	Frequência	Mediana
			Máximo
			Moda
			1º Quartil
			Distância entre o 1º e 3º Quartis
Tempo		Desvio Padrão	
		Desvio Absoluto Médio	
		Variância	
		Média	
		Valor Eficaz	
Áudio 3	Frequência	Máximo	
		Moda	
		1º Quartil	
		3º Quartil	
		Coeficiente de Variação	
	Tempo	Média	
		Mediana	
		Média Ponderada da Frequência	
		Desvio Absoluto Médio	
		Variância	
Áudio 4	Frequência	Mediana	
		Máximo	
		1º Quartil	
		3º Quartil	
		Distância entre o 1º e 3º Quartis	
	Tempo	Média	
		Mediana	
		Máximo	
		1º Quartil	
		Distância entre o 1º e 3º Quartis	
Áudio 5	Frequência	Média Ponderada da Frequência	
		Máximo	
		Distância entre o 1º e 3º Quartis	
		Variância	
		Média	
	Tempo	Máximo	
		1º Quartil	
		Distância entre o 1º e 3º Quartis	

Autoria própria.

Analisando-se a Tabela 24 a a Figura 63 do *Random Forest* para a seleção dos atributos associados a falha de rolamento, é possível observar que existem atributos

Figura 63 – Correlação entre os atributos selecionados utilizando *Random Forest* para falha de desgaste de rolamento no motor de 2CV.



Fonte: Autoria Própria.

selecionados de todos os sensores, a exemplo do que ocorre para a mesma situação no motor de 1CV.

Os sensores que mais apresentam atributos selecionados dentre os 116 atributos selecionados no total, são: i) Vibração em X (13 atributos); ii) Vibração em Y (14 atributos); iii) Áudio 2 (18 atributos); iv) Áudio 3 (13 atributos).

Considerando os atributos selecionados na Seção 5.3.1.3.3, que trata da seleção utilizando *Random Forest* para falha de rolamento no motor de 1CV, houve 32

atributos selecionados em comum entre os dois tipos de motores.

5.3.2.4 Resumo da Seleção dos Atributos

De maneira resumida, os resultados obtidos para a seleção de atributos são os são mostrados nas Tabela 25, Tabela 26 e Tabela 27.

Tabela 25 – Resumo da seleção dos atributos para o motor de 1CV.

Falha	Método de Seleção	Total de Sensores	Total de Atributos
Estator	Informação Mútua	6	20
	VIF	15	46
	<i>Random Forest</i>	13	46
Rotor	Informação Mútua	10	20
	VIF	15	42
	<i>Random Forest</i>	7	16
Desgaste de Rolamento	Informação Mútua	3	20
	VIF	15	45
	<i>Random Forest</i>	15	66

Fonte: Autoria Própria.

Tabela 26 – Resumo da seleção dos atributos para o motor de 2CV.

Falha	Método de Seleção	Total de Sensores	Total de Atributos
Estator	Informação Mútua	7	20
	VIF	15	47
	<i>Random Forest</i>	14	74
Rotor	Informação Mútua	8	20
	VIF	15	43
	<i>Random Forest</i>	13	43
Desgaste de Rolamento	Informação Mútua	3	20
	VIF	15	42
	<i>Random Forest</i>	15	116

Fonte: Autoria Própria.

Tabela 27 – Resumo dos atributos selecionados em comum entre os motores de 1CV e 2CV.

Falha	Método de Seleção	Atributos em comum
Estator	Informação Mútua	0
	VIF	40
	<i>Random Forest</i>	18
Rotor	Informação Mútua	10
	VIF	38
	<i>Random Forest</i>	6
Desgaste de Rolamento	Informação Mútua	15
	VIF	37
	<i>Random Forest</i>	32

Fonte: Autoria Própria.

5.4 CONCLUSÃO DO CAPÍTULO

Neste capítulo foram apresentados os resultados obtidos com a realização deste trabalho. Inicialmente foram apresentados os resultados obtidos com o sensoriamento da evolução do desgaste dos rolamentos. Com os resultados do desgaste, pode-se afirmar que os rolamentos utilizados apresentaram desgaste condizente com o tempo em que os mesmos estiveram sujeitos ao funcionamento com a pasta abrasiva no lugar do lubrificante. Observou-se também que a evolução do desgaste dos rolamentos não ocorre de forma linear, e que mesmo com os rolamentos possuindo a mesma especificação e mesmo fabricante a evolução do desgaste não ocorreu ao mesmo tempo para todos os rolamentos.

Também foram apresentados as informações finais sobre o banco de dados de falha criado. Tal banco de dados possui uma quantidade significativa de dados de ensaios, além de apresentar informações de 19 sensores diferentes, contendo informações de corrente e tensão de alimentação, vibração, emissão acústica, fluxo de dispersão, torque e velocidade do motor. Outro banco de dados criado foi o banco de evolução do desgaste dos rolamentos, o qual possui uma quantidade significativa de dados.

Foram apresentados os resultados obtidos a partir da aplicação de técnicas de seleção de atributos. Os resultados apresentados mostram os atributos selecionados por 3 técnicas a saber: i) Informação mútua; ii) *Variance Inflation Factor* (VIF) e iii) *Random Forest*. Os atributos selecionados por cada técnica indicam que o banco de dados criado tem grande potencial para a utilização nas pesquisas de falhas em máquinas elétricas, uma vez que foram selecionados atributos de todos os sensores em algum método ou tipo de falha analisada.

Por fim, comparando-se os atributos selecionados a partir dos dados dos motores de 1CV e 2CV, pode-se observar que o método de seleção de atributos que mostra o maior potencial para permitir a generalização dos resultados de uma classificação é o método VIF.

6 CONCLUSÃO

Neste trabalho foi apresentado um estudo sobre a utilização do multissensoriamento para a detecção de falhas em motores de indução trifásicos. A utilização de diversos tipos de sensores para o sensoriamento de um motor de indução trifásico vem sendo amplamente abordada na comunidade acadêmica e também em aplicações industriais.

A utilização de sensores de vibração, áudio, corrente, tensão, fluxo disperso, entre outros, especialmente quando utilizados em conjunto, aumenta confiabilidade do resultado de identificação e classificação de padrões. Atualmente a análise das correntes que alimentam um motor de indução ainda é uma técnica utilizada nos meios científicos e de produção. No entanto, o uso isolado deste sensor pode ser substituído por outros sensores, ou a partir da incorporação de novos sensores na análise dos dados. Aplicações industriais, por exemplo, estão optando por utilizar sensores de vibração para a realização de análises, devido à facilidade de instalação dos mesmos no motor a ser analisado.

Antes da realização deste trabalho, o Laboratório de Sistemas Inteligentes (LSI) da UTFPR – Campus Cornélio Procópio possuía banco de dados que continham apenas informações de corrente, tensão, torque e velocidade do motor de indução. Tal banco de dados foi amplamente utilizado nos diversos trabalhos realizados no LSI. No entanto, observou-se que existia uma lacuna em termos de dados que poderiam ser analisados no monitoramento das condições de um motor de indução trifásico. Diante disso, este trabalho foi realizado com o principal objetivo de eliminar essa lacuna, agregando dados de outros tipos de sensores, sendo eles: áudio, vibração e fluxo de dispersão.

Com a criação do banco de dados desse trabalho espera-se que seja possível melhorar a acurácia da classificação das condições das motores de indução, além de permitir que sejam aplicadas outras técnicas de identificação e classificação de falhas. Com esse banco de dados também espera-se que seja possível aproximar ainda mais os estudos realizados no LSI com as demandas o sistema produtivo no que tange ao monitoramento das condições dos motores de indução.

A criação do bando de dados desse trabalho a partir de sensores de relativo

baixo custo pode levantar dúvidas sobre a qualidade e usabilidade dos dados obtidos. Para dirimir essas dúvidas foi realizada a análise dos dados coletados a partir de métodos de seleção de atributos. Observou-se que os todos os sensores foram selecionados por um ou mais métodos de seleção de atributos como sendo importantes para a identificação da condição de operação da máquina. Além disso, observou-se que com a utilização do método de seleção de atributos correta, pode-se obter atributos e sensores em comum independentemente das características do motor utilizado

Por fim, pode-se considerar que os objetivos deste trabalho foram atingidos, e espera-se que o banco de dados criado possa ser útil nos trabalhos futuros do Laboratório de Sistemas Inteligentes (LSI) da UTFPR – Campus Cornélio Procópio.

6.1 TRABALHOS FUTUROS

Este trabalho é o ponto inicial para a realização de diversos outros trabalhos, uma vez que o banco de dados criado pode ser utilizado em vários tipos de análise. Alguns dos trabalhos futuros que podem ser realizados a partir desse trabalho são:

- a) Expansão do banco de dados a partir da realização de ensaios com alimentação por meio de inversor de frequência;
- b) Expansão do banco de dados a partir da realização de ensaios com falhas pontuais de rolamento (falha nas esferas, nas pistas externa e interna);
- c) Aplicação de métodos de processamento de sinais e utilização de sistemas inteligentes para a identificação da posição do curto-circuito na falha de estator;
- d) Realização da identificação e classificação de falha a partir dos dados dos sensores de vibração, áudio e fluxo de dispersão;
- e) Realização da identificação e classificação de falha a partir da utilização conjunta de dois ou mais tipos de sensores;
- f) Comparativo entre o desempenho da classificação de padrões utilizando cada sensor individualmente e o multissensoriamento;
- g) Implementar o multissensoriamento utilizando sensores com saídas digitais e comparar o desempenho com os sensores utilizados neste trabalho.

REFERÊNCIAS

ABNT. **NBR 17094-1: Máquinas elétricas girantes - Parte 1: Motores de indução trifásicos — Requisitos**, Rio de Janeiro, 2018.

ALI, Mohammad Zawad; SHABBIR, Md Nasmus Sakib Khan; LIANG, Xiaodong; ZHANG, Yu; HU, Ting. Machine learning-based fault diagnosis for single- and multi-faults in induction motors using measured stator currents and vibration signals. **IEEE Transactions on Industry Applications**, IEEE, v. 55, n. 3, p. 2378–2391, 2019. ISSN 19399367.

ALIN, Aylin. Multicollinearity. **Wiley Interdisciplinary Reviews: Computational Statistics**, Wiley Online Library, v. 2, n. 3, p. 370–374, 2010.

ALSAEDI, Malik Abadulrazzaq. Fault Diagnosis of Three-Phase Induction Motor: A Review. **Optics**, v. 4, n. 1, p. 1, 2015. ISSN 2328-7780.

ANEEL. **RESOLUÇÃO NORMATIVA ANEEL Nº 956**, 2021.

ANG, Wei Tech; KHOSLA, Pradeep K; RIVIERE, Cameron N. Nonlinear regression model of a low-*g* mems accelerometer. **IEEE Sensors Journal**, IEEE, v. 7, n. 1, p. 81–88, 2006.

BARUSU, Madhusudhana Reddy; DEIVASIGAMANI, Meganathan. Non-Invasive Vibration Measurement for Diagnosis of Bearing Faults in 3-Phase Squirrel Cage Induction Motor Using Microwave Sensor. **IEEE Sensors Journal**, v. 21, n. 2, p. 1026–1039, 2021. ISSN 15581748.

BAZAN, Gustavo Henrique. **Identificação Inteligente de Falhas em Máquinas Elétricas Utilizando Informação Mútua**. 2020. 155 p. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2020.

BAZAN, Gustavo Henrique; GOEDEL, Alessandro; SCALASSARA, Paulo Rogério; ENDO, Wagner; NUNES, Erick Araujo; TAKASE, Victor Takeo Ferreira; GUEDES, Jacqueline Jordan; GENTIL, Murillo Garcia. An Embedded System for Stator Short-Circuit Diagnosis in Three-Phase Induction Motors Using Information Theory and Artificial Neural Networks. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 05, n. 10, p. 1–11, 2022. ISSN 21682232.

BAZAN, Gustavo Henrique; SCALASSARA, Paulo Rogério; ENDO, Wagner; GOEDEL, Alessandro; GODOY, Wagner Fontes; PALÁCIOS, Rodrigo Henrique Cunha. Stator

fault analysis of three-phase induction motors using information measures and artificial neural networks. **Electric Power Systems Research**, Elsevier B.V., v. 143, p. 347–356, 2017. ISSN 03787796. Disponível em: <http://dx.doi.org/10.1016/j.epsr.2016.09.031>.

BAZAN, Gustavo Henrique; SCALASSARA, Paulo Rogério; ENDO, Wagner; GOEDEL, Alessandro. Information theoretical measurements from induction motors under several load and voltage conditions for bearing faults classification. **IEEE Transactions on Industrial Informatics**, IEEE, v. 16, n. 6, p. 3640–3650, 2019.

BAZAN, Gustavo Henrique; SCALASSARA, Paulo Rogério; ENDO, Wagner; GOEDEL, Alessandro; PALACIOS, Rodrigo Henrique Cunha; GODOY, Wagner Fontes. Stator Short-Circuit Diagnosis in Induction Motors Using Mutual Information and Intelligent Systems. **IEEE Transactions on Industrial Electronics**, v. 66, n. 4, p. 3237–3246, 2019. ISSN 02780046.

BEEBY, Stephen. **MEMS mechanical sensors**. Norwood: Artech House, 2004.

BELLINI, Alberto; FILIPPETTI, Fiorenzo; TASSONI, Carla; CAPOLINO, Gérard-André. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, IEEE, v. 55, n. 12, p. 4109–4126, 2008.

BLODT, Martin; GRANJON, Pierre; RAISON, Bertrand; ROSTAING, Gilles. Models for bearing damage detection in induction motors using stator current monitoring. **IEEE Transactions on Industrial Electronics**, v. 55, n. 4, p. 1813–1822, 2008. ISSN 02780046.

CHENG, Jiehong; SUN, Jun; YAO, Kunshan; XU, Min; CAO, Yan. A variable selection method based on mutual information and variance inflation factor. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, Elsevier, v. 268, p. 120652, 2022.

CHOUDHARY, Anurag; GOYAL, Deepam; LETHA, Shimi Sudha. Infrared Thermography-Based Fault Diagnosis of Induction Motor Bearings Using Machine Learning. **IEEE Sensors Journal**, v. 21, n. 2, p. 1727–1734, 2021. ISSN 15581748.

De Pelegrin, Jesse; DREYER, Uilian Jose; MARTELLI, Cicero; Da Silva, Jean Carlos Cardozo. Optical Fiber Sensor Encapsulated in Carbon Fiber Reinforced Polymer for Fault Detection in Rotating Electrical Machines. **IEEE Sensors Journal**, v. 20, n. 19, p. 11364–11371, 2020. ISSN 15581748.

DIAS, Cleber Gustavo; PEREIRA, Fabio Henrique. Broken Rotor Bars Detection in Induction Motors Running at Very Low Slip Using a Hall Effect Sensor. **IEEE Sensors Journal**, IEEE, v. 18, n. 11, p. 4602–4613, 2018. ISSN 1530437X.

DINEVA, Adrienn; MOSAVI, Amir; GYIMESI, Mate; VAJDA, Istvan; NABIPOUR, Narjes; RABCZUK, Timon. Fault diagnosis of rotating electrical machines using multi-label classification. **Applied Sciences (Switzerland)**, v. 9, n. 23, 2019. ISSN 20763417.

DORRELL, David G.; FROSINI, Lucia; BOTTANI, Marcello; GALBIATI, Giacomo; MIN-FU-HSIEH. Analysis of axial voltages and inter-bar currents in cast copper cage rotors during DC current injection as an aid to identify casting faults. *In: IECON Proceedings (Industrial Electronics Conference)*. Porto: IEEE, 2009. p. 3431–3436.

DUQUE-PEREZ, Oscar; POZO-GALLEGO, Carlos Del; MORINIGO-SOTELO, Daniel; GODOY, Wagner Fontes. Condition monitoring of bearing faults using the stator current and shrinkage methods. **Energies**, v. 12, n. 17, p. 1–13, 2019. ISSN 19961073.

EPE. Atlas da Eficiência Energética. p. 149, 2020. Disponível em: <http://www.epe.gov.br>.

ESFAHANI, Ehsan Tarkesh; WANG, Shaocheng; SUNDARARAJAN, V. Multisensor wireless system for eccentricity and bearing fault detection in induction motors. **IEEE/ASME Transactions on Mechatronics**, IEEE, v. 19, n. 3, p. 818–826, 2014. ISSN 10834435.

ESTÉVEZ, Pablo A; TESMER, Michel; PEREZ, Claudio A; ZURADA, Jacek M. Normalized mutual information feature selection. **IEEE Transactions on neural networks**, IEEE, v. 20, n. 2, p. 189–201, 2009.

FILHO, Paulo C.M.Lamim; SANTOS, Deivity C.; BATISTA, Fabiano B.; BACCARINI, Lane M.R. Axial Stray Flux Sensor Proposal for Three-Phase Induction Motor Fault Monitoring by Means of Orbital Analysis. **IEEE Sensors Journal**, v. 20, n. 20, p. 12317–12325, 2020. ISSN 15581748.

FILIPPETTI, Fiorenzo; FRANCESCHINI, Giovanni; TASSONI, Caria; VAS, Peter. AI techniques in induction machines diagnosis including the speed ripple effect. **IEEE Transactions on Industry Applications**, v. 34, n. 1, p. 98–108, 1998. ISSN 00939994.

FREESCALE, SEMICONDUCTOR INC. Xtrinsic fxln83xxq 3-axis lowpower analog-output accelerometer. **Datasheet**, v. 2.0, 2014.

FROSINI, Lucia. Monitoring and diagnostics of electrical machines and drives: A state of the art. *In: 2019 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*. Athens: IEEE, 2019. p. 169–176.

GANGSAR, Purushottam; TIWARI, Rajiv. Comparative investigation of vibration and current monitoring for prediction of mechanical and electrical faults in induction motor based on multiclass-support vector machine algorithms. **Mechanical Systems and**

Signal Processing, Elsevier Ltd, v. 94, p. 464–481, 2017. ISSN 10961216. Disponível em: <http://dx.doi.org/10.1016/j.ymssp.2017.03.016>.

GANGSAR, Purushottam; TIWARI, Rajiv. Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. **Mechanical Systems and Signal Processing**, Elsevier Ltd, v. 144, p. 106908, 2020. ISSN 10961216. Disponível em: <https://doi.org/10.1016/j.ymssp.2020.106908>.

GARCIA-ESCUADERO, Luis Angel; DUQUE-PEREZ, Oscar; FERNANDEZ-TEMPRANO, Miguel; MORINIGO-SOTELO, Daniel. Robust Detection of Incipient Faults in VSI-Fed Induction Motors Using Quality Control Charts. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 3076–3085, 2017. ISSN 00939994.

GLOWACZ, Adam. Acoustic based fault diagnosis of three-phase induction motor. **Applied Acoustics**, Elsevier, v. 137, n. March, p. 82–89, 2018. ISSN 1872910X. Disponível em: <https://doi.org/10.1016/j.apacoust.2018.03.010>.

GNACINSKI, Piotr; PEPLINSKI, Marcin; MURAWSKI, Lech; SZELEZINSKI, Adam. Vibration of induction machine supplied with voltage containing subharmonics and interharmonics. **IEEE Transactions on Energy Conversion**, IEEE, v. 34, n. 4, p. 1928–1937, 2019. ISSN 15580059.

GODOY, Wagner Fontes; Da Silva, Ivan Nunes; GOEDEL, Alessandro; Cunha Palácios, Rodrigo Henrique. Evaluation of stator winding faults severity in inverter-fed induction motors. **Applied Soft Computing Journal**, Elsevier B.V., v. 32, p. 420–431, 2015. ISSN 15684946. Disponível em: <http://dx.doi.org/10.1016/j.asoc.2015.03.053>.

GODOY, Wagner Fontes; MORINIGO-SOTELO, Daniel; DUQUE-PEREZ, Oscar; Da Silva, Ivan Nunes; GOEDEL, Alessandro; PALÁCIOS, Rodrigo Henrique Cunha. Estimation of bearing fault severity in line-connected and inverter-fed three-phase induction motors. **Energies**, v. 13, n. 13, 2020. ISSN 19961073.

GODOY, Wagner Fontes; SILVA, Ivan Nunes da; GOEDEL, Alessandro; PALÁCIOS, Rodrigo Henrique Cunha; LOPES, Tiago Drummond. Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter. **IET Electric Power Applications**, v. 10, n. 5, p. 430–439, 2016. ISSN 17518679.

GONGORA, W. S.; GOEDEL, A.; Da Silva, S. A.O.; GRACIOLA, C. L. Neural Approach to Fault Detection in Three-phase Induction Motors. **IEEE Latin America Transactions**, v. 14, n. 3, p. 1279–1288, 2016. ISSN 15480992.

GYFTAKIS, Konstantinos N.; ANTONINO-DAVIU, Jose A.; GARCIA-HERNANDEZ, Raul; MCCULLOCH, Malcolm D.; HOWEY, David A.; CARDOSO, Antonio J. Marques.

Comparative Experimental Investigation of Broken Bar Fault Detectability in Induction Motors. **IEEE Transactions on Industry Applications**, IEEE, v. 52, n. 2, p. 1452–1459, 2016. ISSN 00939994.

HAROUN, Smail; SEGHIR, Amirouche Nait; TOUATI, Said. Multiple features extraction and selection for detection and classification of stator winding faults. **IET Electric Power Applications**, v. 12, n. 3, p. 339–346, 2018. ISSN 1751-8660.

HEGDE, Vishwanath; RAO, Maruthi Gujjar Sathyannarayana. Detection of Stator Winding Inter-Turn Short Circuit Fault in Induction Motor Using Vibration Signals by MEMS Accelerometer. **Electric Power Components and Systems**, Taylor & Francis, v. 45, n. 13, p. 1463–1473, 2017. ISSN 15325016. Disponível em: <https://doi.org/10.1080/15325008.2017.1358777>.

HENAO, Humberto; CAPOLINO, Gerard Andre; FERNANDEZ-CABANAS, Manes; FILIPPETTI, Fiorenzo; BRUZZESE, Claudio; STRANGAS, Elias; PUSCA, Remus; ESTIMA, Jorge; RIERA-GUASP, Martin; HEDAYATI-KIA, Shahin. Trends in fault diagnosis for electrical machines: A review of diagnostic techniques. **IEEE Industrial Electronics Magazine**, v. 8, n. 2, p. 31–42, 2014. ISSN 19324529.

HONZÍK, P; GUIANVARC'H, C; BRUNEAU, M. Modeling of capacitive mems microphone with square membrane or plate using integral method. **Procedia Engineering**, Elsevier, v. 120, p. 418–421, 2015.

HUANG, Zexian; CHEN, Daqi. A breast cancer diagnosis method based on vim feature selection and hierarchical clustering random forest algorithm. **IEEE Access**, IEEE, v. 10, p. 3284–3293, 2021.

IRHOUMAH, Miftah; PUSCA, Remus; LEFEVRE, Eric; MERCIER, David; ROMARY, Raphael. Detection of the Stator Winding Inter-Turn Faults in Asynchronous and Synchronous Machines Through the Correlation between Harmonics of the Voltage of Two Magnetic Flux Sensors. **IEEE Transactions on Industry Applications**, IEEE, v. 55, n. 3, p. 2682–2689, 2019. ISSN 19399367.

ISAVAND, Javad; KASAEI, Afshar; PELOW, Andrew; AFZALI, Babak; SHIRZADI, Ebrahim. Comparison of vibration and acoustic responses in a rotary machine balancing process. **Applied Acoustics**, Elsevier Ltd, v. 164, p. 107258, 2020. ISSN 1872910X. Disponível em: <https://doi.org/10.1016/j.apacoust.2020.107258>.

KANNAN, Akila. **Design and modeling of a MEMS-based accelerometer with pull in analysis**. 2008. Tese (Doutorado) — University of British Columbia, 2008.

- KATRUTSA, Alexandr; STRIJOV, Vadim. Comprehensive study of feature selection methods to solve multicollinearity problem according to evaluation criteria. **Expert Systems with Applications**, Elsevier, v. 76, p. 1–11, 2017.
- KINGSLEY, Charles; UMANS, Stephen D; FITZGERALD, Arthur E. **Máquinas Elétricas-: Com Introdução à Eletrônica de Potência**. Porto Alegre: Bookman, 2006.
- LAYTON, Richard A; ADAMS, Thomas M. **Introductory MEMS: Fabrication and Applications**. New York: Springer, 2010.
- LEI, Yaguo; HE, Zhengjia; ZI, Yanyang. A new approach to intelligent fault diagnosis of rotating machinery. **Expert Systems with applications**, Elsevier, v. 35, n. 4, p. 1593–1600, 2008.
- LEWIS, Jerad. Analog and digital mems microphone design considerations. **Invensense Inc**, 2013.
- LI, Bo; CHOW, Mo Yuen; TIPSUWAN, Yodyium; HUNG, James C. Neural-network-based motor rolling bearing fault diagnosis. **IEEE Transactions on Industrial Electronics**, v. 47, n. 5, p. 1060–1069, 2000. ISSN 02780046.
- LIU, Huawen; SUN, Jigui; LIU, Lei; ZHANG, Huijie. Feature selection with dynamic mutual information. **Pattern Recognition**, Elsevier, v. 42, n. 7, p. 1330–1339, 2009.
- LOPES, Tiago Drummond; GOEDEL, Alessandro; PALÁCIOS, Rodrigo Henrique Cunha; GODOY, Wagner Fontes; SOUZA, Roberto Molina de. Bearing fault identification of three-phase induction motors bases on two current sensor strategy. **Soft Computing**, Springer Berlin Heidelberg, v. 21, n. 22, p. 6673–6685, 2017. ISSN 14337479.
- LOUZADA, Ailton de Oliveira; SOUZA, Wesley Angelino de; CASTOLDI, Marcelo Favoretto; GOEDEL, Alessandro. Diagnóstico de curto-circuito entre espiras de estator de motores de indução usando fluxo de dispersão e dados estatísticos. *In: ANAIS DO XXIV CONGRESSO BRASILEIRO DE AUTOMÁTICA – CBA 2022*. Fortaleza: SBA, 2022.
- LUCAS, Guilherme Beraldi; De Castro, Bruno Albuquerque; ROCHA, Marco Aurelio; ANDREOLI, Andre Luiz. A New Acoustic Emission-Based Approach for Supply Disturbances Evaluation in Three-Phase Induction Motors. **IEEE Transactions on Instrumentation and Measurement**, v. 70, 2021. ISSN 15579662.
- LYU, Ming; ZHAO, Jian; KACEM, Najib; TANG, Bin; LIU, Pengbo; SONG, Jiahao; ZHONG, Heng; HUANG, Yu. Design and modeling of a mems accelerometer based

on coupled mode-localized nonlinear resonators under electrostatic actuation. **Communications in Nonlinear Science and Numerical Simulation**, Elsevier, v. 103, p. 105960, 2021.

MARTINEZ, Javier; BELAHCEN, Anouar; MUETZE, Annette. Analysis of the Vibration Magnitude of an Induction Motor with Different Numbers of Broken Bars. **IEEE Transactions on Industry Applications**, IEEE, v. 53, n. 3, p. 2711–2720, 2017. ISSN 00939994.

MARUTHI, G. S.; HEGDE, Vishwanath. Application of MEMS Accelerometer for Detection and Diagnosis of Multiple Faults in the Roller Element Bearings of Three Phase Induction Motor. **IEEE Sensors Journal**, IEEE, v. 16, n. 1, p. 145–152, 2016. ISSN 1530437X.

MIRZAEVA, Galina; SAAD, Khalid Imtiaz. Advanced Diagnosis of Rotor Faults and Eccentricity in Induction Motors Based on Internal Flux Measurement. **IEEE Transactions on Industry Applications**, IEEE, v. 54, n. 4, p. 3961–3970, 2018. ISSN 00939994.

MIRZAEVA, Galina; SAAD, Khalid Imtiaz. Advanced Diagnosis of Stator Turn-to-Turn Faults and Static Eccentricity in Induction Motors Based on Internal Flux Measurement. **IEEE Transactions on Industry Applications**, IEEE, v. 54, n. 4, p. 3961–3970, 2018. ISSN 00939994.

MOHAMMED, Anees; DJUROVIC, Sinisa. Electric Machine Bearing Health Monitoring and Ball Fault Detection by Simultaneous Thermo-Mechanical Fibre Optic Sensing. **IEEE Transactions on Energy Conversion**, v. 36, n. 1, p. 71–80, 2021. ISSN 15580059.

MONITRAN. Mtn/8066. **Datasheet**, 2023.

NANDI, Subhasis; TOLIYAT, Hamid A; LI, Xiaodong. Condition monitoring and fault diagnosis of electrical motors—a review. **IEEE transactions on energy conversion**, IEEE, v. 20, n. 4, p. 719–729, 2005.

OZDOGAN, Mehmet; TOWFIGHIAN, Shahrzad; MILES, Ronald N. Modeling and characterization of a pull-in free mems microphone. **IEEE Sensors Journal**, IEEE, v. 20, n. 12, p. 6314–6323, 2020.

PALÁCIOS, Rodrigo Henrique Cunha; GOEDEL, Alessandro; GODOY, Wagner Fontes; FABRI, José Augusto. Fault Identification in the Stator Winding of Induction Motors Using PCA with Artificial Neural Networks. **Journal of Control, Automation and Electrical Systems**, Springer US, v. 27, n. 4, p. 406–418, 2016. ISSN 21953899.

PALÁCIOS, Rodrigo H Cunha; SILVA, Ivan Nunes Da; GOEDEL, Alessandro; GODOY, Wagner F. A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. **Electric Power Systems Research**, Elsevier, v. 127, p. 249–258, 2015.

PALÁCIOS, Rodrigo Henrique Cunha; Da Silva, Ivan Nunes; GOEDEL, Alessandro; GODOY, Wagner Fontes; LOPES, Tiago Drummond. Diagnosis of Stator Faults Severity in Induction Motors Using Two Intelligent Approaches. **IEEE Transactions on Industrial Informatics**, v. 13, n. 4, p. 1681–1691, 2017. ISSN 15513203.

PARK, Minha; GAO, Yang. Error analysis and stochastic modeling of low-cost mems accelerometer. **Journal of Intelligent and Robotic Systems**, Springer, v. 46, p. 27–41, 2006.

PARK, Yonghyun; CHOI, Hanchun; LEE, Sang Bin; GYFTAKIS, Konstantinos N. Search Coil-Based Detection of Nonadjacent Rotor Bar Damage in Squirrel Cage Induction Motors. **IEEE Transactions on Industry Applications**, v. 56, n. 5, p. 4748–4757, 2020. ISSN 19399367.

PEDOTTI, Luciane Agnoletti dos; ZAGO, Ricardo Mazza; FRUETT, Fabiano. Fault Diagnostics in Rotary Machines through Spectral Vibration Analysis Title Using Low-Cost MEMS Devices. **IEEE Instrumentation & Measurement Magazine**, n. December, p. 39–44, 2017.

PEÑA-GARCÍA, Néstor N; AGUILERA-CORTÉS, Luz A; GONZÁLEZ-PALACIOS, Max A; RASKIN, Jean-Pierre; HERRERA-MAY, Agustín L. Design and modeling of a mems dual-backplate capacitive microphone with spring-supported diaphragm for mobile device applications. **Sensors**, MDPI, v. 18, n. 10, p. 3545, 2018.

PENMAN, J.; SEDDING, H.G; . Detection and Location of Interturn Short Circuits. **IEEE Transactions on Energy Conversion**, v. 9, n. 4, p. 652–658, 1994.

PHD, sensors. Acelerômetro baixa rotação, 500 mv/g, saída topo. **Datasheet**, 2023.

RAD, Nastaran Mohammadian. **Deep Learning for Abnormal Movement Detection using Wearable Sensors: Case Studies on Stereotypical Motor Movements in Autism and Freezing of Gait in Parkinson's Disease**. 2019. Tese (Doutorado) — University of Trento, 2019.

RIERA-GUASP, Martin; ANTONINO-DAVIU, Jose A.; CAPOLINO, Gerard Andre. Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State of the art. **IEEE Transactions on Industrial Electronics**, v. 62, n. 3, p. 1746–1759, 2015. ISSN 02780046.

RZESZUCINSKI, Pawel; ORMAN, Maciej; PINTO, Cajetan T.; TKACZYK, Agnieszka; SULOWICZ, Maciej. Bearing Health Diagnosed with a Mobile Phone. **IEEE Industry Applications Magazine**, IEEE, n. April 2018, p. 17–23, 2018.

SANGEETHA, Parvathi B.; HEMAMALINI, S. Rational-dilation wavelet transform based torque estimation from acoustic signals for fault diagnosis in a three-phase induction motor. **IEEE Transactions on Industrial Informatics**, IEEE, v. 15, n. 6, p. 3492–3501, 2019. ISSN 15513203.

SANTOS, Herman Lucas dos *et al.* **Processamento de emissões acústicas aplicado a detecção de falhas em máquinas elétricas**. 2019. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2019.

SCHOEN, Randy R; HABETLER, Thomas G; KAMRAN, Farrukh; BARTFIELD, RG. Motor bearing damage detection using stator current monitoring. **IEEE Transactions on Industry Applications**, IEEE, v. 31, n. 6, p. 1274–1279, 1995.

SEERA, Manjeevan; LIM, Chee Peng; ISHAK, Dahaman; SINGH, Harapajan. Offline and online fault detection and diagnosis of induction motors using a hybrid soft computing model. **Applied Soft Computing Journal**, Elsevier B.V., v. 13, n. 12, p. 4493–4507, 2013. ISSN 15684946. Disponível em: <http://dx.doi.org/10.1016/j.asoc.2013.08.002>.

SIZOV, Gennadi Y.; SAYED-AHMED, Ahmed; YEH, Chia Chou; DEMERDASH, Nabeel A.O. Analysis and diagnostics of adjacent and nonadjacent broken-rotor-bar faults in squirrel-cage induction machines. **IEEE Transactions on Industrial Electronics**, IEEE, v. 56, n. 11, p. 4627–4641, 2009. ISSN 02780046.

SON, Jong Duk; AHN, Byung Hyun; HA, Jeong Min; CHOI, Byeong Keun. An availability of MEMS-based accelerometers and current sensors in machinery fault diagnosis. **Measurement: Journal of the International Measurement Confederation**, Elsevier Ltd, v. 94, p. 680–691, 2016. ISSN 02632241. Disponível em: <http://dx.doi.org/10.1016/j.measurement.2016.08.035>.

SOUZA, Ruhan Pontes Policarpo de; AGULHARI, Cristiano Marcos; GOEDEL, Alessandro; CASTOLDI, Marcelo Favoretto. Inter-turn short-circuit fault diagnosis using robust adaptive parameter estimation. **International Journal of Electrical Power and Energy Systems**, Elsevier Ltd, v. 139, n. January, p. 107999, 2022. ISSN 01420615. Disponível em: <https://doi.org/10.1016/j.ijepes.2022.107999>.

ST. Ann4426 – tutorial for mems microphone. **Application note**, v. 2, 2017.

TDK. Clamp type ac current sensors. **Datasheet**, 2016.

VAIMANN, Toomas; SOBRA, Jan; BELAHCEN, Anouar; RASSÖLKIN, Anton; ROLAK, Michal; KALLASTE, Ants. Induction machine fault detection using smartphone recorded audible noise. **IET Science, Measurement and Technology**, v. 12, n. 4, p. 554–560, 2018. ISSN 17518822.

VERAS, Frank Cesar; LIMA, Thyago L.V.; SOUZA, Jefferson S.; RAMOS, Jorge G.G.S.; Lima Filho, Abel C.; BRITO, Alisson V. Eccentricity failure detection of brushless DC motors from sound signals based on density of maxima. **IEEE Access**, IEEE, v. 7, p. 150318–150326, 2019. ISSN 21693536.

VERGARA, Jorge R; ESTÉVEZ, Pablo A. A review of feature selection methods based on mutual information. **Neural Computing and Applications**, Springer, v. 24, p. 175–186, 2014.

VU, Dao Hoang; MUTTAQI, Kashem M; AGALGAONKAR, Ashish P. A variance inflation factor and backward elimination based robust regression model for forecasting monthly electricity demand using climatic variables. **Applied Energy**, Elsevier, v. 140, p. 385–394, 2015.

WANG, Daichao; LI, Yibin; JIA, Lei; SONG, Yan; LIU, Yanjun. Novel Three-Stage Feature Fusion Method of Multimodal Data for Bearing Fault Diagnosis. **IEEE Transactions on Instrumentation and Measurement**, v. 70, 2021. ISSN 15579662.

WEG. Electric motors. **Specification Guide**, v. 7, 2020.

WEG. Motor trifásico W22. v. 6, mar 2021.

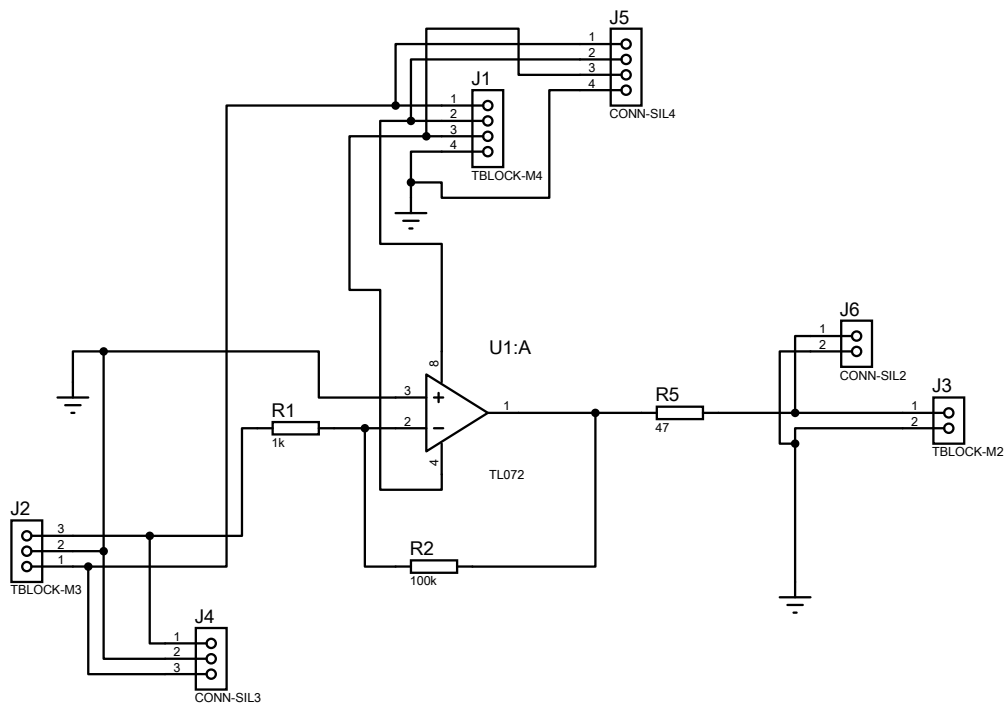
XUAN, Yi; SI, Weiguo; ZHU, Jiong; SUN, Zhiqing; ZHAO, Jian; XU, Mingjie; XU, Shouliang. Multi-model fusion short-term load forecasting based on random forest feature selection and hybrid neural network. **IEEE Access**, IEEE, v. 9, p. 69002–69009, 2021.

YAMAN, Orhan. An automated faults classification method based on binary pattern and neighborhood component analysis using induction motor. **Measurement: Journal of the International Measurement Confederation**, Elsevier Ltd, v. 168, n. July 2020, p. 108323, 2021. ISSN 02632241. Disponível em: <https://doi.org/10.1016/j.measurement.2020.108323>.

ZUBAIR, Iqbal Muhammad; KIM, Byunghoon. A group feature ranking and selection method based on dimension reduction technique in high-dimensional data. **IEEE Access**, IEEE, v. 10, p. 125136–125147, 2022.

APÊNDICE A – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE ÁUDIO DESENVOLVIDA

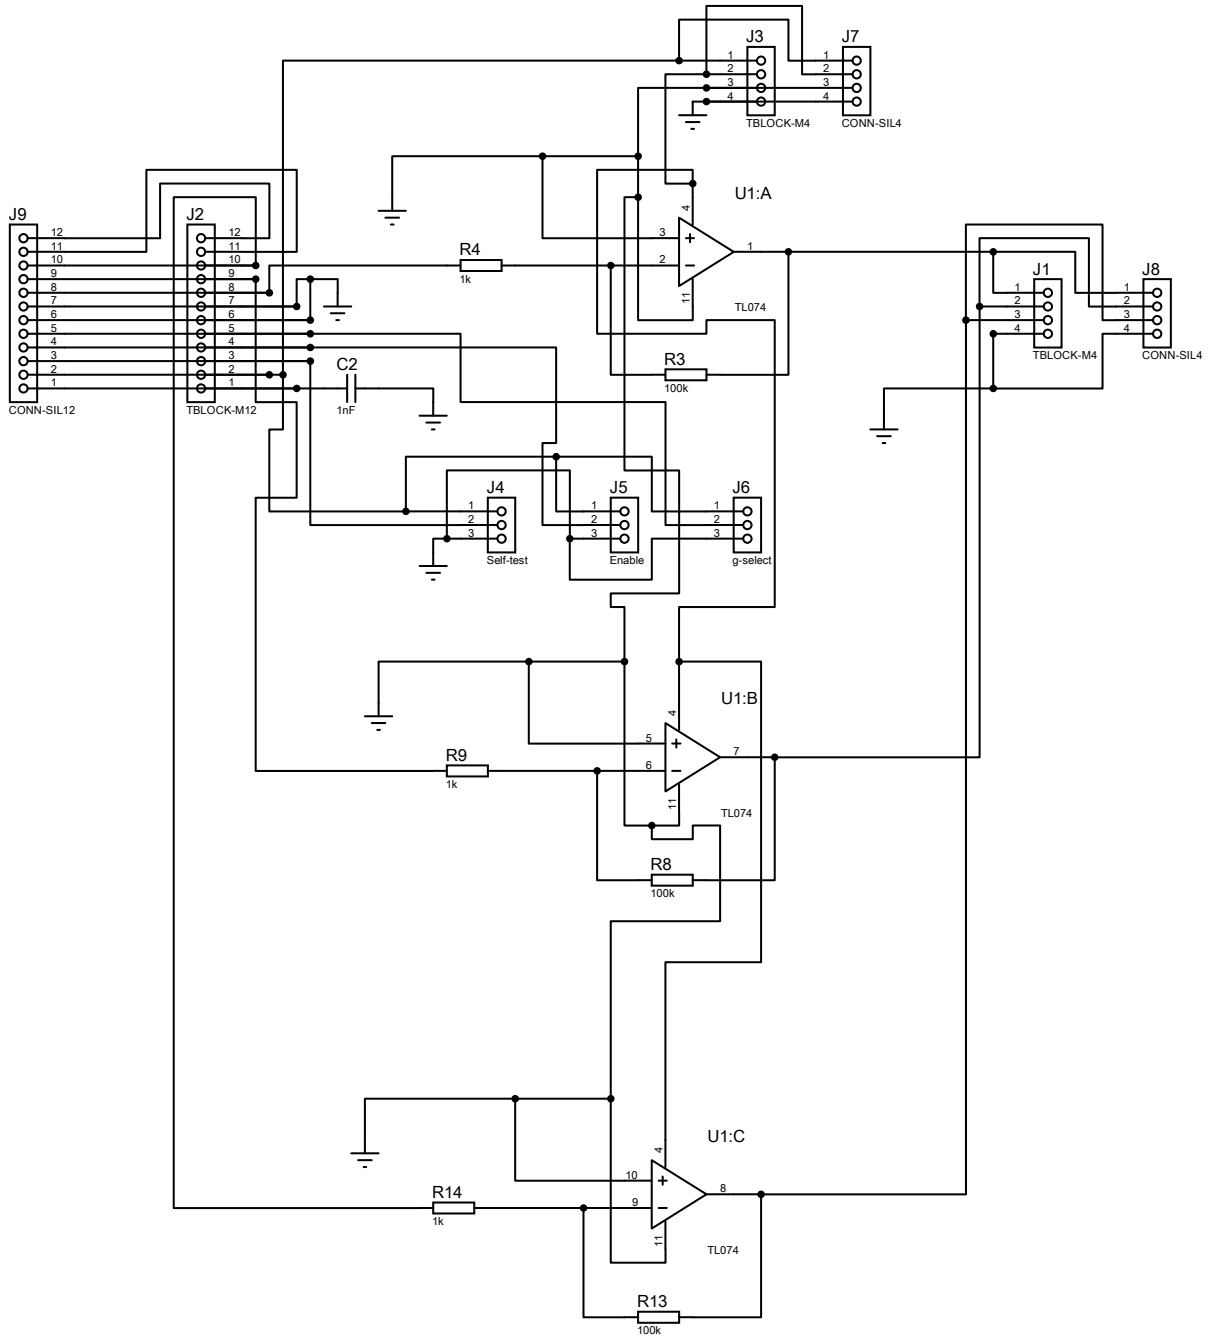
Figura 64 – Esquemático da placa de condicionamento dos sinais de áudio desenvolvida.



Fonte: Autoria Própria.

APÊNDICE B – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE VIBRAÇÃO DESENVOLVIDA

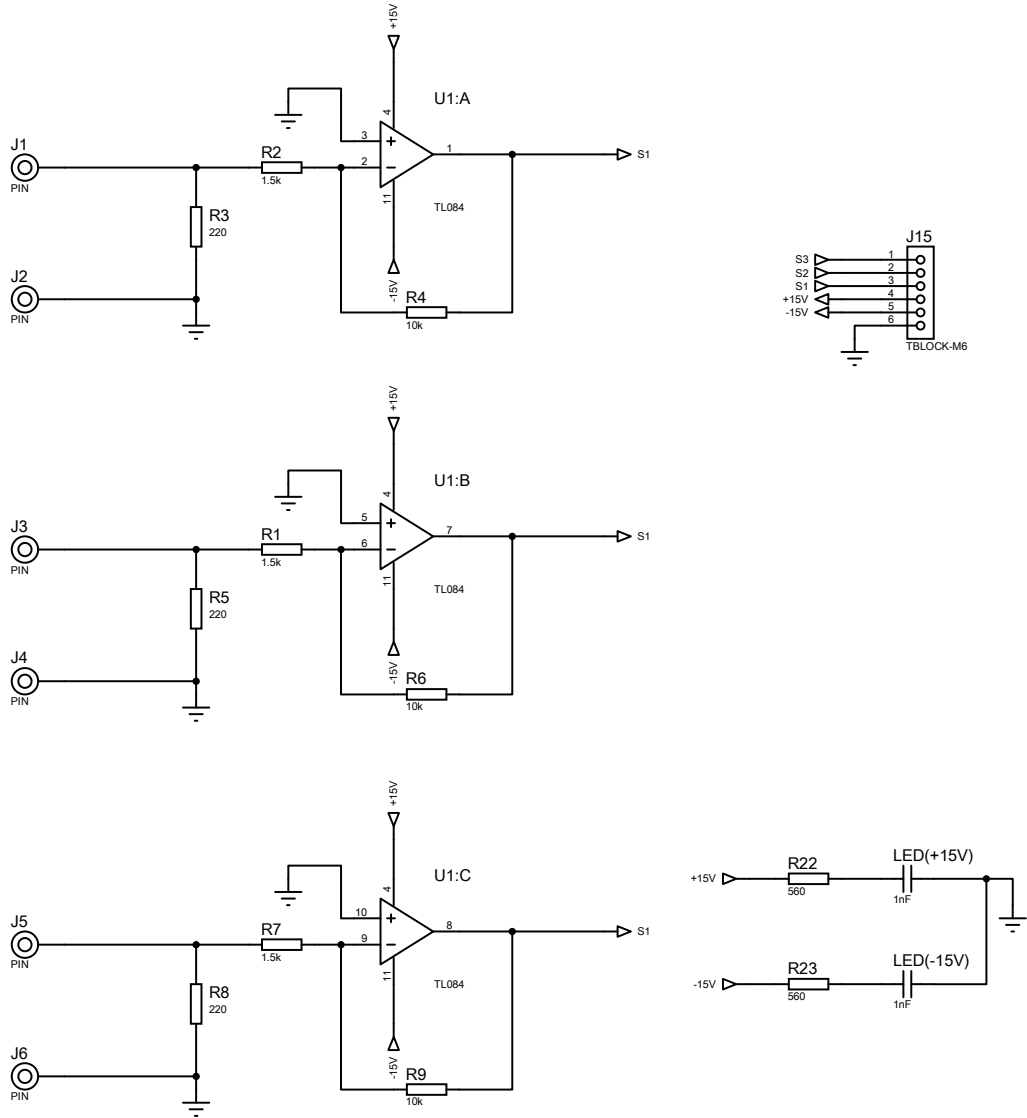
Figura 65 – Esquemático da placa de condicionamento dos sinais de vibração desenvolvida.



Fonte: Autoria Própria.

APÊNDICE C – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE CORRENTE DESENVOLVIDA

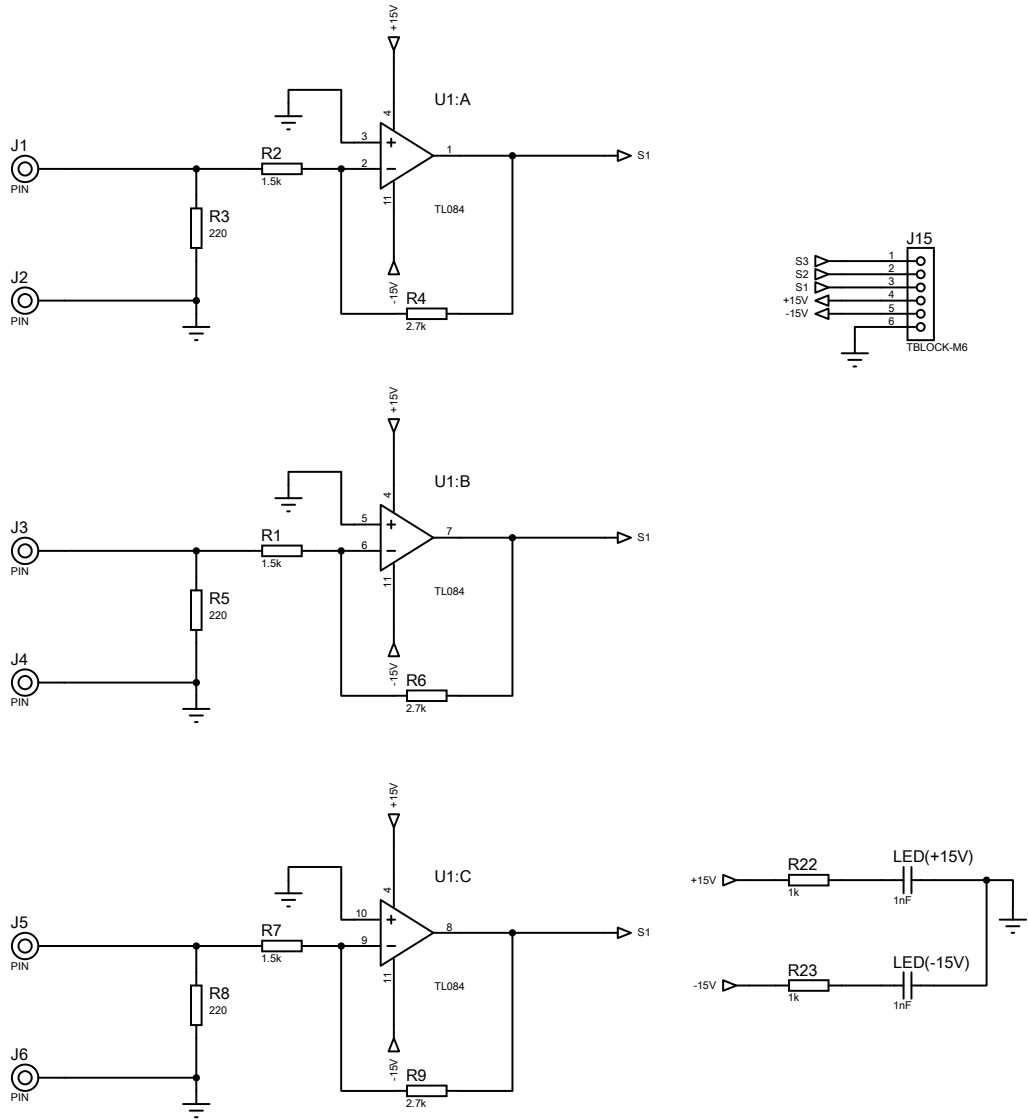
Figura 66 – Esquemático da placa de condicionamento dos sinais de corrente desenvolvida.



Fonte: Autoria Própria.

APÊNDICE D – ESQUEMÁTICO DA PLACA DE CONDICIONAMENTO DE SINAIS DE TENSÃO DESENVOLVIDA

Figura 67 – Esquemático da placa de condicionamento dos sinais de tensão desenvolvida.



Fonte: Autoria Própria.