

UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CAMPUS FLORIANÓPOLIS - CENTRO TECNOLÓGICO  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E ELETRÔNICA  
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Fabricio Fontoura

**SISTEMAS DE DETECÇÃO DE FALHAS EM MOTORES ELÉTRICOS BASEADOS  
EM ANÁLISES DE VIBRAÇÃO:  
ESTUDO DE UM MOTOR DE INDUÇÃO TRIFÁSICO.**

Florianópolis

2023



Fabricao Fontoura

**SISTEMAS DE DETECÇÃO DE FALHAS EM MOTORES ELÉTRICOS BASEADOS  
EM ANÁLISES DE VIBRAÇÃO:  
ESTUDO DE UM MOTOR DE INDUÇÃO TRIFÁSICO.**

Trabalho de Conclusão de Curso submetido ao curso de Engenharia Elétrica do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Renato Lucas Pacheco, Dr.

Florianópolis

2023

Fontoura, Fabricio

SISTEMAS DE DETECÇÃO DE FALHAS EM MOTORES ELÉTRICOS BASEADOS EM ANÁLISES DE VIBRAÇÃO : ESTUDO DE UM MOTOR DE INDUÇÃO TRIFÁSICO / Fabricio Fontoura ; orientador, Renato Lucas Pacheco, 2023.  
93 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Engenharia Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Elétrica. 2. Motor Elétrico de Indução. 3. Detecção de Falhas. 4. Aprendizagem de Máquina. 5. Inteligência Artificial. I. Pacheco, Renato Lucas. II. Universidade Federal de Santa Catarina. Graduação em Engenharia Elétrica. III. Título.

Fabricio Fontoura

**Título: SISTEMAS DE DETECÇÃO DE FALHAS EM MOTORES ELÉTRICOS  
BASEADOS EM ANÁLISES DE VIBRAÇÃO: ESTUDO DE UM MOTOR DE  
INDUÇÃO TRIFÁSICO**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia Elétrica” e aceito, em sua forma final, pelo Curso de Graduação em Engenharia Elétrica.

Florianópolis, 28 de julho de 2023.



Documento assinado digitalmente  
**Miguel Moreto**  
Data: 28/07/2023 16:34:37-0300  
CPF: \*\*\*.850.100-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

---

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

**Banca Examinadora:**



Documento assinado digitalmente  
**Renato Lucas Pacheco**  
Data: 28/07/2023 14:33:01-0300  
CPF: \*\*\*.751.489-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

---

**Prof. Renato Lucas Pacheco, Dr.**  
Orientador  
Universidade Federal de Santa Catarina



Documento assinado digitalmente  
**Jean Viane Leite**  
Data: 31/07/2023 14:17:26-0300  
CPF: \*\*\*.474.909-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

---

**Prof. Jean Viane Leite, Dr.**  
Universidade Federal de Santa Catarina



Documento assinado digitalmente  
**CRISTIAN FRANZOI MAZZOLA**  
Data: 29/07/2023 12:48:56-0300  
CPF: \*\*\*.191.289-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

---

**Eng. Eletric. Cristian Franzoi Mazzola**  
Universidade Federal de Santa Catarina



Este trabalho é dedicado aos meus pais, pois é graças ao seu esforço e dedicação incessante, que hoje posso concluir meu curso.





## AGRADECIMENTOS

Este trabalho é fruto de um intenso processo que uniu esforço, dedicação e persistência, compartilhado com diversas pessoas que marcaram a minha trajetória acadêmica na Universidade Federal de Santa Catarina (UFSC) e fora dela. A todas essas pessoas, manifesto minha sincera gratidão. No entanto, algumas merecem uma menção especial.

Aos meus pais, Alice e Ozi, que sempre acreditaram no estudo de qualidade e jamais mediram forças para que essa graduação fosse uma ótima experiência. Sou grato pelos ensinamentos e dedicação, por sempre se fazerem presentes, e, pelo seu esforço conjunto para me oferecerem uma vida repleta de oportunidades.

À minha namorada, Beatriz, que me acompanhou durante grande parte desta trajetória. Expresso minha gratidão pelas inúmeras contribuições, pelos aprendizados diários, e, pelo seu companheirismo que foi o estímulo principal para seguir em frente.

Aos meus sogros, Louisa e Fabio, pela compreensão e incentivo constante durante este caminho.

À Capitu e ao Sebastião, pelo amor intrínseco em seus comportamentos.

Aos amigos da UFSC, que enfrentaram comigo os inúmeros desafios impostos pela vida acadêmica. Obrigado por tornar esse período ainda mais prazeroso e divertido.

Por fim, agradeço especialmente ao professor Renato Lucas Pacheco que foi o coordenador do curso durante grande parte de minha graduação e nunca mediu esforços para ajudar o corpo discente. Obrigado por ter aceitado ser meu orientador, pelo incentivo e dedicação de seu valioso tempo ao meu trabalho.



“Porque cada um, independente das habilitações que tenha, ao menos uma vez na vida fez ou disse coisas muito acima da sua natureza e condição, e se a essas pessoas pudéssemos retirar do cotidiano pardo em que vão perdendo os contornos, ou elas a si próprias se retirassem de malhas e prisões, quantas mais maravilhas seriam capazes de obrar, que pedaços de conhecimento profundo poderiam comunicar, porque cada um de nós sabe infinitamente mais do que julga e cada um dos outros infinitamente mais do que neles aceitamos reconhecer”.

José Saramago



## RESUMO

Com notável destaque na indústria, os motores elétricos de indução são comumente utilizados devido a sua alta robustez e diversidade de atuação. No entanto, estas máquinas estão sujeitas à esforços indesejados podendo diminuir a vida útil de determinados componentes mais suscetíveis a falhas. Neste contexto, o presente projeto tem como objetivo criar um sistema de detecção e diagnóstico de falhas em motores elétricos, baseado em análises de vibração. São usados algoritmos de aprendizagem de máquina capazes de prever as falhas em indústrias e assim mitigar custos e restrições operacionais. A metodologia aplicada consiste na utilização da transformada de *Fourier* para os sinais de vibração disponíveis em base pública e posterior elaboração de modelos classificadores como *Support Vector Machine* (SVM) e *K-nearest neighbors* (k-NN). Por fim, os resultados são comparados via métricas de avaliação de modelos de inteligência artificial tais como acurácia, sensibilidade e curvas AUC/ROC (Area Under the Curve/ Receiver Operating Characteristic).

**Palavras-chave:** Motor elétrico de indução; Falhas; Detecção; Diagnóstico; Inteligência Artificial; Aprendizagem de Máquina.



## ABSTRACT

With a notable prominence in the industry, induction motors are commonly used due to their high robustness and diversity of operation. However, these machines are subjected to unwanted efforts, which can reduce the useful life of certain components that are more susceptible to failures. In this context, the present project aims to create a fault detection and diagnosis system in electric motors, based on vibration analysis. Machine learning algorithms are used to predict failures in industries and thus mitigate costs and operational constraints. The applied methodology consists in using the Fourier transform for the vibration signals available in a public database and subsequent modeling of classifier models such as Support Vector Machine (SVM) and K-nearest neighbors (k-NN). Finally, the results are compared via artificial intelligence model evaluation metrics such as accuracy, sensitivity and AUC/ROC (Area Under the Curve/ Receiver Operating Characteristic) curves.

**Keywords:** Induction motor; Faults; Detection; Diagnosis; Artificial intelligence; Machine learning.





## LISTA DE FIGURAS

Figura 1 - Diferentes tipos de máquinas de corrente contínua e corrente alternada.	27
Figura 2 – Motor de indução trifásico com visão explodida .....	29
Figura 3 – Princípio de funcionamento do motor de indução trifásico .....	34
Figura 4 - Circuito elétrico equivalente do motor de indução .....	36
Figura 5 - Circuito elétrico equivalente por fase do motor de indução.....	37
Figura 6 – Rolamento esférico detalhado.....	43
Figura 7 - Fluxograma de identificação de falhas.....	45
Figura 8 - Processo de Aprendizagem Supervisionada .....	51
Figura 9 - Exemplo de Aprendizagem Não Supervisionada.....	52
Figura 10 – Curva ROC e exemplos de classificadores .....	55
Figura 11 - MFS da SpectraQuest Inc.....	58
Figura 12 - Vibração axial do rolamento no tempo para o funcionamento normal ....	61
Figura 13 - Vibração radial do rolamento no tempo para o funcionamento normal ...	62
Figura 14 - Vibração tangencial do rolamento no tempo para o funcionamento normal .....	62
Figura 15 - Vibração axial do rolamento para uma falha de desbalanceamento com carga de 35 g .....	63
Figura 16 - Vibração radial do rolamento para uma falha de desbalanceamento com carga de 35 g .....	63
Figura 17 - Vibração tangencial do rolamento para uma falha de desbalanceamento com carga de 35 g.....	64
Figura 18 – Sinais de vibração no domínio da frequência para o funcionamento normal .....	65
Figura 19 - Sinais de vibração no domínio da frequência para de desbalanceamento com carga de 35 g.....	65
Figura 20 - Comparativos de sinais de falhas de desbalanceamento, sendo o primeiro um funcionamento normal.....	66
Figura 21 - Classificação SVM de dois rótulos .....	67
Figura 22 – Classificação k-NN de dois rótulos.....	68
Figura 23 - Curva ROC para desbalanceamento de carga – SVM.....	70
Figura 24 - Curva ROC para desbalanceamento de carga – k-NN .....	70

Figura 25 – Curva ROC para desalinhamento horizontal – SVM.....	72
Figura 26 – Curva ROC para desalinhamento horizontal – k-NN.....	72
Figura 27 – Curva ROC para desalinhamento vertical – SVM.....	74
Figura 28 – Curva ROC para desalinhamento vertical – k-NN.....	74
Figura 29 – Curva ROC para para desalinhamento angular negativo com falha no anel externo – SVM.....	76
Figura 30 – Curva ROC para para desalinhamento angular negativo com falha no anel externo – k-NN.....	76
Figura 31 – Curva ROC para para desalinhamento angular negativo com falha nas esferas – SVM.....	78
Figura 32 – Curva ROC para desalinhamento angular negativo com falha nas esferas – k-NN.....	78
Figura 33 – Curva ROC para para desalinhamento angular negativo com falha no separador esferas – SVM.....	80
Figura 34 – Curva ROC para desalinhamento angular negativo com falha no separador esferas – k-NN.....	80
Figura 35 – Curva ROC para para desalinhamento angular positivo com falha no anel externo – SVM.....	82
Figura 36 – Curva ROC para para desalinhamento angular positivo com falha no anel externo – k-NN.....	82
Figura 37 – Curva ROC para desalinhamento angular positivo com falha nas esferas – SVM.....	84
Figura 38 – Curva ROC para desalinhamento angular positivo com falha nas esferas – k-NN.....	84
Figura 39 – Curva ROC para desalinhamento angular positivo com falha no separador esferas – SVM.....	86
Figura 40 – Curva ROC para desalinhamento angular positivo com falha no separador esferas – k-NN.....	86

## LISTA DE TABELAS

Tabela 1 - Percentual de falha de componentes do motor .....	40
Tabela 2 - Matriz de confusão para modelos estatísticos .....	53
Tabela 3 - Parâmetros de avaliação dos modelos .....	54
Tabela 4 – Interpretação do indicador AUC .....	55
Tabela 5 – Sequência de falhas simuladas .....	58
Tabela 6 – Variações de medidas para a falha de desalinhamento .....	59
Tabela 7 - Variações de carga para a falha de desbalanceamento .....	59
Tabela 8 - Variações de carga para a falha de desalinhamento angular de rolamento .....	60
Tabela 9 – Métricas de avaliação para desbalanceamento de carga.....	69
Tabela 10 – AUC para desbalanceamento de carga.....	71
Tabela 11 – Métricas de avaliação para desalinhamento horizontal .....	71
Tabela 12 – AUC para desalinhamento horizontal .....	73
Tabela 13 – Métricas de avaliação para desalinhamento vertical .....	73
Tabela 14 – AUC para desalinhamento vertical .....	75
Tabela 15 – Métricas de avaliação para desalinhamento angular negativo com falha no anel externo.....	75
Tabela 16 – AUC para desalinhamento angular negativo com falha no anel externo .....	77
Tabela 17 – Métricas de avaliação para desalinhamento angular negativo com falha nas esferas.....	77
Tabela 18 – AUC para desalinhamento angular negativo com falha nas esferas .....	79
Tabela 19 – Métricas de avaliação para desalinhamento angular negativo com falha no separador de esferas .....	79
Tabela 20 – AUC para desalinhamento angular negativo com falha no separador esferas .....	81
Tabela 21 – Métricas de avaliação para desalinhamento angular positivo com falha no anel externo.....	81
Tabela 22 – AUC para desalinhamento angular positivo com falha no anel externo .....	83
Tabela 23 – Métricas de avaliação para desalinhamento angular negativo com falha nas esferas.....	83
Tabela 24 – AUC para desalinhamento angular negativo com falha nas esferas .....	85

Tabela 25 – Métricas de avaliação para desalinhamento angular positivo com falha no separador de esferas .....	85
Tabela 26 – AUC para desalinhamento angular positivo com falha no separador esferas .....	87

## LISTA DE ABREVIATURAS E SIGLAS

ACC - Acurácia

AUC - Area Under the Curve

CSV - Comma-Separated Values

DFT - Transformada Discreta de Fourier

EPE - Empresa de Pesquisa Energética do Governo Federal

EPRI - Electric Power Research Institute

FFT - Transformada Rápida de Fourier

FN - Falso Negativo

FP - Falso Positivo

FT - Transformada de Fourier

F1 - F-score

HT - Transformada de Hilbert

IA - Inteligência Artificial

IEEE - Institute of Electrical and Electronics Engineers

KNN - K-nearest neighbors

MFS - Machinery Fault Simulator

MIT - Motor elétrico de Indução Trifásico

ML - Machine Learning

P - Precisão

PC - Personal Computer

RAM - Random Access Memory

RL - Reinforcement Learning

ROC - Receiver Operating Characteristic

S - Sensibilidade

SVM - Support Vector Machine

VN - Verdadeiro Negativo

VP - Verdadeiro Positivo

WT - Transformada de Wavelet



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>25</b>
1.1	OBJETIVOS .....	26
1.1.1	<b>Objetivo Geral</b> .....	<b>26</b>
1.1.2	<b>Objetivos Específicos</b> .....	<b>26</b>
<b>2</b>	<b>MOTORES ELÉTRICOS DE INDUÇÃO</b> .....	<b>27</b>
2.1	TIPOS DE MOTORES ELÉTRICOS .....	27
2.2	MOTORES ELÉTRICOS DE INDUÇÃO .....	28
2.3	MOTORES DE INDUÇÃO TRIFÁSICOS .....	29
2.3.1	<b>Princípio de funcionamento do motor de indução trifásico</b> .....	<b>31</b>
2.3.2	<b>Modelos do motor de indução</b> .....	<b>35</b>
<b>3</b>	<b>FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS</b> .....	<b>39</b>
3.1	FALHAS NO ROTOR.....	40
3.2	FALHAS NO ESTATOR.....	41
3.3	FALHAS NOS ROLAMENTOS .....	42
<b>4</b>	<b>DETECÇÃO E DIAGNÓSTICO DE FALHAS</b> .....	<b>45</b>
4.1	TÉCNICAS E FERRAMENTAS.....	45
4.1.1	<b>Sensoriamento dos motores</b> .....	<b>45</b>
4.1.2	<b>Transformada de <i>Fourier</i></b> .....	<b>46</b>
4.1.2.1	<i>Transformada Rápida de Fourier</i> .....	47
4.1.3	<b>Transformada de <i>Hilbert</i></b> .....	<b>48</b>
4.1.4	<b>Transformada de <i>Wavelet</i></b> .....	<b>49</b>
4.1.5	<b>Aprendizagem de Máquina</b> .....	<b>50</b>
4.1.5.1	<i>Aprendizagem Supervisionada</i> .....	50
4.1.5.2	<i>Aprendizagem Não Supervisionada</i> .....	51
4.1.5.3	<i>Aprendizagem por reforço</i> .....	52
4.1.6	<b>Métricas de Avaliação de Desempenho</b> .....	<b>53</b>
<b>5</b>	<b>DESENVOLVIMENTO DO MÉTODO DE DETECÇÃO</b> .....	<b>57</b>
5.1	BASE DE DADOS.....	57
5.2	MÉTODOS UTILIZADOS.....	60
5.2.1	<b>Transformada Rápida de Fourier FFT</b> .....	<b>64</b>
5.2.2	<b>Modelos Classificadores</b> .....	<b>66</b>
5.2.2.1	<i>Classificador SVM</i> .....	66

5.2.2.2	<i>Classificador k-NN</i> .....	67
<b>6</b>	<b>RESULTADOS OBTIDOS</b> .....	<b>69</b>
6.1	DESBALANCEAMENTO DE CARGA .....	69
6.2	DESALINHAMENTO HORIZONTAL .....	71
6.3	DESALINHAMENTO VERTICAL .....	73
6.4	DESALINHAMENTO ANGULAR NEGATIVO .....	75
<b>6.4.1</b>	<b>Falha no Anel Externo</b> .....	<b>75</b>
<b>6.4.2</b>	<b>Falha nas Esferas</b> .....	<b>77</b>
<b>6.4.3</b>	<b>Falha no Separador de Esferas</b> .....	<b>79</b>
6.5	DESALINHAMENTO ANGULAR POSITIVO.....	81
<b>6.5.1</b>	<b>Falha no Anel Externo</b> .....	<b>81</b>
<b>6.5.2</b>	<b>Falha nas Esferas</b> .....	<b>83</b>
<b>6.5.3</b>	<b>Falha no Separador de Esferas</b> .....	<b>85</b>
<b>7</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	<b>89</b>
	<b>REFERÊNCIAS</b> .....	<b>91</b>



## 1 INTRODUÇÃO

Os motores elétricos de indução possuem um destaque especial dentre os tipos de máquinas elétricas mais utilizadas pela indústria, devido às suas principais características, como construção simples, robustez, confiabilidade e custo-benefício. Tais motores são empregados em diversas áreas, por exemplo: fábricas de cerâmica, mineração, siderúrgica, fabricação de eletrodomésticos, entre outras. São utilizados em acionamentos de bombas, ventiladores, exaustores, misturadores, esteiras e demais utilidades (GUEDES, 1994).

No Brasil, estudos realizados pela Empresa de Pesquisa Energética do Governo Federal (EPE), em março de 2022, revelam que o consumo de energia elétrica por parte da indústria equivale a 32% do montante total. Deste consumo, estima-se que 50% da energia seja demandada dos motores elétricos industriais (SUETAKE, 2012).

Embora os motores de indução sejam lembrados por sua robustez, o ambiente industrial os deixa sujeitos a esforços indesejados, que desgastam e diminuem a vida útil dos componentes. Pesquisadores estudaram diversas falhas em variados elementos das máquinas elétricas, chegando a um consenso sobre a necessidade do monitoramento constante de algumas métricas intrínsecas ao funcionamento do motor, como: corrente, tensão, vibração, ruídos, entre outros. Este monitoramento tem por objetivo a detecção, análise e correção das falhas antes que elas aconteçam, reduzindo danos, custos e paradas não programadas (SIDDIQUE et al., 2005).

Além disso, as tecnologias de monitoramento do comportamento físico e dos parâmetros dos motores elétricos estão em constante evolução e são as principais aliadas na agenda mundial de eficiência energética e controle de custos. Nesse contexto, a inteligência artificial ganha cada vez mais notoriedade no mercado e a pauta de indústria 4.0 está em efervescência no Brasil. Muitos trabalhos mostram que é possível aliar a aquisição de dados de corrente, tensão, vibração e ruídos dos motores com a detecção de falhas por meio de inteligência artificial ou redes neurais (JANDREICE, 2019).

## 1.1 OBJETIVOS

### 1.1.1 Objetivo Geral

Desenvolver e testar um sistema de detecção e diagnóstico de falhas para um motor de indução baseado em análise de dados de vibração e aprendizagem de máquina, que identifique e classifique corretamente o elemento e a causa da falha ocorrida.

### 1.1.2 Objetivos Específicos

Definido o objetivo geral, pode-se destacar os seguintes objetivos específicos:

1. Estudar o comportamento do motor elétrico de indução;
2. Estudar as variadas falhas do motor elétrico de indução;
3. Tratar e organizar os dados de vibração de um motor de indução trifásicos selecionados para o projeto;
4. Utilizar a Transformada Rápida de *Fourier* (FFT) para o processamento dos sinais de vibração;
5. Implementar técnicas de aprendizagem de máquina nos dados tratados e processados;
6. Avaliar a acurácia das técnicas implementadas.


## 2 MOTORES ELÉTRICOS DE INDUÇÃO

### 2.1 TIPOS DE MOTORES ELÉTRICOS

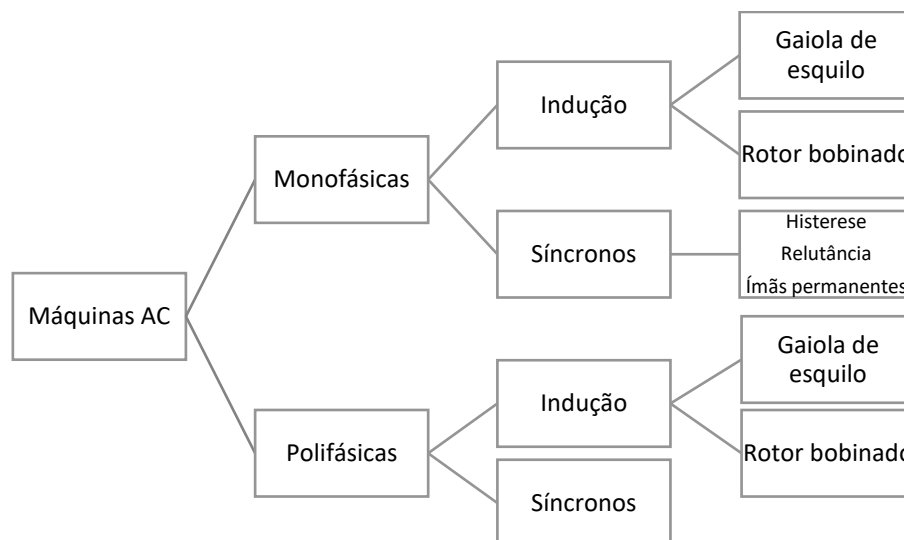
A Figura 1 mostra os diferentes tipos de máquinas elétricas que, genericamente, podem ser divididas em máquinas de corrente contínua (Figura 1.a) e máquinas de corrente alternada (Figura 1.b). As máquinas de corrente contínua são subdivididas pelo tipo de construção e pela forma de ligação dos enrolamentos com a alimentação elétrica. Em corrente alternada, existem as máquinas síncronas, que giram com velocidade constante, independente da carga, e as máquinas assíncronas, nas quais a velocidade depende da carga. As máquinas de corrente alternada podem também ser classificadas com base na quantidade de fases de sua alimentação elétrica e nas características de construção.

Figura 1 - Diferentes tipos de máquinas de corrente contínua e corrente alternada.

#### a) Máquinas de corrente contínua



#### b) Máquinas de corrente alternada



Fonte: adaptado de Guedes (1994, p.02)

Cada motor apresenta uma aplicação distinta, devido às suas diferentes características construtivas e particularidades como, por exemplo, característica torque versus velocidade, o sistema de acionamento disponível, necessidades e características da carga mecânica, entre outros (GUEDES, 1994).

O foco deste trabalho são os motores elétricos de indução, também chamados de motores assíncronos.

## 2.2 MOTORES ELÉTRICOS DE INDUÇÃO

Apesar de relativamente antigos em teoria e concepção, devido à sua versatilidade e às preocupações ambientais da sociedade moderna, têm se tornado alvo de pesquisas e melhoramentos e estão cada vez mais eficientes e tecnológicos. A aplicação de alta tecnologia na produção deste tipo de motor torna-o cada vez mais eficaz em termos de custo de produção, densidade de potência e robustez, o que o leva a uma baixa necessidade de manutenção, combinada a um baixo custo e a uma gama diversificada de aplicação e atuação.

Os motores elétricos de indução ou motores assíncronos, e apresentam como características principais (GUEDES, 1994):

- alto rendimento na transformação energia elétrica em energia mecânica;
- índice de proteção adequado a diversos ambientes;
- robustez;
- baixo custo;
- versatilidade para vários tipos de acionamentos e cargas.


Tais características são os responsáveis pela grande difusão dos motores elétricos na indústria (GUEDES, 1994).

## 2.3 MOTORES DE INDUÇÃO TRIFÁSICOS

O motor elétrico de indução, cuja patente original é de Nikola Tesla (1888), é o foco deste trabalho, mais especificamente, o motor de indução trifásico. Estes motores são muito utilizados notadamente na indústria, principalmente pelo seu baixo custo, pela sua simplicidade de manutenção e pela sua robustez (GUEDES, 1994).

O motor elétrico de indução trifásico (MIT), de forma simples, é composto por: um **estator** (parte fixa), onde normalmente está o enrolamento de armadura, um **rotor** (parte girante), onde normalmente está o induzido, e **estrutura mecânica** que agrega todos os componentes e permite a fixação do equipamento. A figura 2 apresenta as partes componentes de um motor de indução trifásico com rotor gaiola de esquilo.

Figura 2 – Motor de indução trifásico com visão explodida



Fonte: (WEG,2013)

O estator, na grande maioria dos motores de indução, é responsável por acomodar os enrolamentos de armadura, ou seja, os enrolamentos que recebem a alimentação a partir da rede de energia elétrica, e onde é formado o campo girante. O

circuito elétrico de armadura, no MIT, é formado por três bobinas fabricadas com condutores isolados, que são desfasadas espacialmente  $120^\circ$  entre si. Essas bobinas são alimentadas por cada uma das fases do sistema trifásico, produzindo um campo magnético girante no entreferro do motor (espaço vazio entre o ferro do estator e o ferro do rotor). A velocidade desse campo depende da frequência da rede elétrica e do número de polos do motor.

O estator é formado por um empacotamento de chapas de material ferro magnético, com baixa densidade de perdas magnéticas, que forma o circuito magnético estatórico. As chapas são eletricamente isoladas entre si para minimizar as correntes induzidas no estator. Entre os conjuntos de chapas magnéticas podem existir canais de ventilação, que servirão para a refrigeração da estrutura (GUEDES, 1994).

No rotor está o componente do motor chamado de induzido, que interage com o campo magnético girante experimentando a indução de um torque. O rotor tem como característica o movimento rotatório em torno do seu próprio eixo, movimentando a carga mecânica acoplada ao motor.

Os enrolamentos de rotor podem ser constituídos de bobinas ou barras de um material condutor (comumente cobre ou alumínio). Esta última é a construção mais comum, muito robusta e é conhecida como *Rotor Gaiola de Esquilo*, uma vez que o seu formato final, considerando apenas os condutores engastados no ferro, se assemelha a uma gaiola.

Essa gaiola consiste em um conjunto de barras de cobre, alumínio ou ligas condutoras instalados nas ranhuras do núcleo de ferro, conectadas nas duas extremidades por um anel condutor, de forma que suas extremidades são curto-circuitadas em cada lado do rotor. Essas barras condutoras são normalmente fundidas nas ranhuras do rotor, implicando em um rotor de grande resistência mecânica. Nesse formato, as barras de alumínio estão em contato direto com as lâminas de aço. Todavia, como consequência da diferença de condutividade entre os dois materiais, aliado ao fato de as lâminas que compõe o rotor serem isoladas entre si, a maior parte da corrente do rotor flui através das barras de alumínio e não através das lâminas do

A Estrutura Mecânica fornece o suporte para a fixação das diversas partes do motor, para que ele possa funcionar de forma consistente, além de servir à fixação do próprio equipamento em seu ponto de trabalho. Adicionalmente, a estrutura mecânica exerce o papel de proteção do motor às agressões ambientais (GUEDES, 1994).

### 2.3.1 Princípio de funcionamento do motor de indução trifásico

O MIT é também denominado como motor assíncrono, pois existe uma diferença entre a velocidade do campo magnético girante e a velocidade de rotação do rotor. Essa diferença é definida como escorregamento ( $s$ ) do motor e pode ser calculado conforme (1) e (2) (CHAPMAN, 2013).

$$n_{esc} = n_{sinc} - n_{motor} \quad (1)$$

$$s = \frac{n_{sinc} - n_{motor}}{n_{sinc}} \times (100) \quad (2)$$

onde:

- $n_{esc}$  – velocidade de escorregamento;
- $n_{sinc}$  – velocidade síncrona (velocidade do campo girante);
- $n_{motor}$  – velocidade mecânica (velocidade do eixo).

O princípio de funcionamento do motor de indução trifásico, é encontrado em vasta bibliografia e é resumido a seguir.

Em um sistema trifásico equilibrado com sequência de fases a, b e c, a armadura do MIT é alimentada por tensões trifásicas equilibradas, fazendo circular correntes trifásicas equilibradas em seus enrolamentos da seguinte forma:

$$i_a(t) = I_m \cdot \cos(\omega \cdot t) \quad (3)$$

$$i_b(t) = I_m \cdot \cos(\omega \cdot t - 120^\circ) \quad (4)$$

$$i_c(t) = I_m \cdot \cos(\omega \cdot t + 120^\circ) \quad (5)$$

$$\omega = 2. \pi. f \quad (6)$$

onde:

$\omega$  – frequência angular [rd/s];

$t$  – tempo decorrido [s];

$f$  – frequência da rede elétrica [Hz];

$i_i(t)$  – corrente elétrica na fase  $i$  [A];

$I_m$  – valor de pico da corrente elétrica [A] (considera-se um sistema equilibrado).

As forças magnetomotrizes geradas em cada fase, supondo três bobinas de  $N$  espiras defasadas espacialmente de  $120^\circ$ , são mostradas em (7), (8) e (9).

$$\mathfrak{F}_a(t) = N. i_a(t) = N. I_m. \cos(\omega. t) = F_m. \cos(\omega. t) \quad (7)$$

$$\mathfrak{F}_b(t) = N. i_b(t) = N. I_m. \cos(\omega. t - 120^\circ) = F_m. \cos(\omega. t - 120^\circ) \quad (8)$$

$$\mathfrak{F}_c(t) = N. i_c(t) = N. I_m. \cos(\omega. t + 120^\circ) = F_m. \cos(\omega. t + 120^\circ) \quad (9)$$

onde:

$\mathfrak{F}_i(t)$  – força magnetomotriz gerada na fase  $i$  [Ampere.espira];

$N$  – número de espiras de cada bobina;

$F_m$  – valor eficaz da força magnetomotriz [Ampere.espira].

A distribuição espacial das forças magnetomotrizes, para cada fase, considerando o defasamento mecânico de  $120^\circ$  entre as bobinas, é dada por (10), (11) e (12).

$$\mathfrak{F}_{a-espacial}(\theta, t) = \mathfrak{F}_a(t). \cos(\theta) = F_m. \cos(\theta). \cos(\omega. t) \quad (10)$$

$$\mathfrak{F}_{b-espacial}(\theta, t) = \mathfrak{F}_b(t). \cos(\theta - 120^\circ) = F_m. \cos(\theta - 120^\circ). \cos(\omega. t - 120^\circ) \quad (11)$$

$$\mathfrak{F}_{c-espacial}(\theta, t) = \mathfrak{F}_c(t). \cos(\theta + 120^\circ) = F_m. \cos(\theta + 120^\circ). \cos(\omega. t + 120^\circ) \quad (12)$$

onde:



$\mathfrak{F}_{i-espacial}(\theta, t)$  – distribuição espacial da força magnetomotriz gerada na fase  $i$ ;  
 $\theta$  – ângulo espacial medido no sentido anti-horário ao partir do eixo da fase  $a$  [graus];

Demonstra-se que a soma dessas três ondas espaciais resulta em um campo girante espacial cuja amplitude depende da corrente de armadura e do número de espiras de cada bobina e cuja velocidade depende diretamente da frequência da rede elétrica e do número de polos do motor. O resultado do somatório pode ser visto em (13).

$$\mathfrak{F}_{ESPACIAL}(\theta, t) = 1,5. F_m. \cos(\theta - \omega. t) \quad (13)$$

onde:

$\mathfrak{F}_{ESPACIAL}(\theta, t)$  – distribuição espacial resultante da interação entre as forças magnetomotrizes geradas em cada fase do enrolamento da armadura [Ampere.espira].

Essa equação descreve uma força magnetomotriz resultante girando no entreferro com velocidade angular  $\omega$ , no sentido anti-horário.

Assim sendo, o funcionamento do motor de indução trifásico pode ser explicado da seguinte forma:

O campo girante descrito, ao atravessar as barras do rotor, induz correntes que circulam em seu interior. Conforme a Lei de Lenz, essas correntes produzem um campo magnético, que se opõe ao campo girante. Devido à natureza indutiva da máquina, o campo magnético induzido está atrasado em relação ao campo original, formando-se atrás dele e sendo puxado por ele. Por ação desse binário eletromagnético, o rotor tende girar no sentido do campo girante. Como já mencionado anteriormente, a velocidade do rotor nunca irá alcançar a velocidade do campo girante, mesmo sem carga em seu eixo, devido às perdas por atrito e ventilação e pela diminuição do torque induzido devido à redução da diferença entre as velocidades do rotor e o campo girante.




### 2.3.2 Modelos do motor de indução

Os motores de indução podem ser modelados através do seu circuito elétrico equivalente. Segundo Barbi (1985, p.26), para esta modelagem, é necessário assumir as seguintes hipóteses:

- Os três enrolamentos estatóricos são iguais entre si;
- No caso de um motor de rotor bobinado, os três enrolamentos rotóricos são iguais entre si;
- Os ângulos elétricos entre os enrolamentos são iguais, tanto no rotor quanto no estator;
- O entreferro é considerado constante;
- O circuito magnético é considerado ideal, ou seja, não ocorre a saturação magnética;
- A distribuição da densidade de fluxo magnético no entreferro é radial e senoidal;
- Não são consideradas as perdas magnéticas.

A partir dessas considerações pode-se montar o circuito elétrico equivalente do motor de indução. Esse modelo deve incluir as perdas *Joule* e o fluxo disperso nos enrolamentos de armadura e no induzido, as perdas magnéticas no rotor e no estator e, também, considerar a magnetização do núcleo responsável pelo campo girante. Tensões e correntes, internas e externas, são indicadas no modelo conforme mostra a figura 4 (CHAPMAN, 2013).

Figura 4 - Circuito elétrico equivalente do motor de indução



Fonte: adaptado de (Chapman, 2013)

No modelo apresentado, os parâmetros mostrados significam:

$V_p$  – tensão terminal aplicada;

$E_1$  – força contraeletromotriz gerada (induzida) pelo fluxo resultante de entreferro, no estator;

$I_1$  – corrente no estator;

$I_M$  – corrente de excitação, responsável pelo fluxo de entreferro e pelas perdas no ferro;

$I_2$  – corrente e carga (parcela transferida ao rotor:  $I_2 = I_1 - I_M$ );

$R_1$  – resistência elétrica efetiva do enrolamento de armadura, representando as perdas estatóricas;

$X_1$  – reatância de dispersão do estator, representando as perdas por fluxo disperso na armadura;

$R_C$  – resistência de perdas no ferro, representando as perdas magnéticas;

$X_M$  – reatância de magnetização, representando a magnetização do ferro;

$a_{ef}$  – relação de transformação efetiva;

$E_R$  – força contraeletromotriz gerada (induzida) pelo fluxo resultante de entreferro, no rotor;


$I_R$  – corrente no rotor;

$R_R$  – resistência elétrica efetiva do rotor, representando as perdas *Joule* no rotor mais o efeito da carga mecânica no eixo do motor;

$X_R$  – reatância de dispersão do rotor, na frequência do estator, representando o fluxo disperso.

É importante observar que a frequência estatórica é a frequência da rede elétrica de alimentação, porém a frequência rotórica depende do escorregamento. É interessante referir todo o circuito para o lado da armadura e trabalhar com a frequência da rede. A Figura 5 mostra o circuito referido.

Figura 5 - Circuito elétrico equivalente por fase do motor de indução



Fonte: adaptado de (Chapman, 2013)

Os parâmetros mostrados já foram apresentados, com exceção de:

$R_2$  – resistência elétrica efetiva do rotor, representando as perdas *Joule* mais o efeito da carga mecânica no eixo do motor, referida ao estator;

$X_2$  – reatância de dispersão do rotor, representando o fluxo disperso, referida ao estator.

$s$  – escorregamento.



### 3 FALHAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

As falhas a serem consideradas em motores elétricos de indução trifásicos, podem ser quaisquer alterações em uma parte ou componente da máquina que a incapacita de desempenhar as suas funções de forma integral e satisfatória. De forma ampla, as falhas em motores elétricos estão relacionadas tanto a aspectos mecânicos quanto elétricos (Hattangadi, 2005).

Segundo Nandi *et al.* (2005), as falhas, de forma isolada ou combinadas, podem gerar os seguintes sintomas: tensões e correntes de linha desbalanceadas; aumento de vibrações e ruídos; queda do torque médio; aumento das perdas e redução do rendimento; aquecimento excessivo, entre outros. As falhas foram classificadas em sete categorias, conforme a lista a seguir:

1. Falhas estatóricas, resultando na abertura ou curto-circuito de um ou mais enrolamentos de fase do estator;
2. Erros nas conexões dos enrolamentos do estator;
3. Quebra de barras ou rachaduras nos anéis terminais e/ou escovas do rotor;
4. Folgas irregulares estáticas e/ou dinâmicas no entreferro;
5. Eixo desalinhado, o que pode resultar em atrito entre o estator e o rotor;
6. Curto-circuito na bobina do rotor;
7. Falhas de engrenagens ou nos rolamentos.

A Tabela 1 apresenta valores percentuais de falhas baseados em dois estudos estatísticos obtidos do *Institute of Electrical and Electronics Engineers – IEEE* e do *Electric Power Research Institute - EPRI* (SIDDIQUE *et al.*, 2005).

Tabela 1 - Percentual de falha de componentes do motor

Instituto de Pesquisa	Falhas no rotor	Falhas no estator	Falhas nos rolamentos	Outras falhas
EPRI	10%	38%	40%	12%
IEEE	8%	28%	42%	22%

Fonte: adaptado de (REIS, 2010)

### 3.1 FALHAS NO ROTOR

Conforme os resultados dos estudos apresentados na tabela 1, as falhas no rotor demonstram menor relevância estatística em comparação com as demais. A maioria das falhas que ocorrem nos rotores são resultados de uma agregação de esforços em que são submetidos (BONNETT, 1988). Esses esforços podem ser classificados em cinco grupos: esforços magnéticos; térmicos; mecânicos; dinâmicos; ambientais.

Os esforços magnéticos são oriundos de quatro principais causas: sobre tração do rotor, tração magnética desnivelada (irregular), saturação da laminação e correntes parasitas. Em sua maioria, são problemas causados pelo processo de fabricação do rotor (BONNETT, 1988).

Os esforços térmicos, por revelarem pontos quentes visíveis nas extremidades do rotor, são normalmente fáceis de identificar. As possíveis causas são: sobrecarga térmica, desbalanço térmico, pontos quentes, sentido incorreto de rotação ou rotor bloqueado (PINHEIRO, 2011).

As falhas mecânicas necessitam de uma avaliação mais complexa para o completo entendimento de sua causa. As causas mais encontradas são: variações da carcaça; laminação e/ou barras com folgas; incorreto ajuste eixo-núcleo; fadiga ou ruptura de peças, geometria do estator e do rotor inapropriadas; desvios de materiais; montagem prática e/ou ressonância do eixo impróprias; e fabricação ou projeto inadequados (BONNETT, 1988).



Os esforços dinâmicos são comumente originados por forças externas, tais como: vibrações, barras do rotor folgadas, fricção do rotor, torque transitório, sobre velocidade e esforços cíclicos.

As falhas ambientais, por sua vez, podem acontecer por motivos de mau uso da máquina ou por manutenções incorretas. As possíveis causas são: contaminação; materiais abrasivos; poeiras e partículas estranhas; defeito de ventilação; alta temperatura ambiente; outras forças externas incomuns (PINHEIRO, 2011).

### 3.2 FALHAS NO ESTATOR

Segundo Siddique *et al.* (2005), assim como o rotor, o estator também é submetido a vários esforços, como térmicos, elétricos, mecânicos e ambientais, que resultam em uma condição de falha.

Os esforços térmicos são comumente associados ao envelhecimento dos enrolamentos e à sobre-elevação de temperatura.

Os esforços elétricos podem ser decompostos em efeito corona e tensões transitórias. O efeito corona é caracterizado pela descarga proveniente da ionização de gases, resultado de uma alta tensão e pode comprometer a isolação das bobinas. Tensões transitórias são resultantes de diversas situações como curto-circuito fase-fase e/ou fase-terra, curto-circuito multifases-terra, manobras de disjuntores, variações de frequência, entre outros e podem assumir valores elevados. Essas tensões acabam por diminuir a capacidade do isolamento e assim, a vida útil do enrolamento (PINHEIRO, 2011).

Os esforços mecânicos acontecem principalmente por movimentos de bobina e descargas elétricas entre rotor e estator. O primeiro caso é provocado pela força magnética sobre as bobinas e pode resultar em danos à isolação pelo movimento mecânico do material bobinado. O segundo caso, é razão de atrito entre a parte girante e a parte fixa do MIT. Esse atrito pode ocorrer por inúmeras razões, como defeito nos rolamentos, deflexão de eixo, desalinhamento entre rotor e estator, batidas durante a partida, entre outros (SIDDIQUE *et al.*, 2005).

Por fim, as falhas ambientais, da mesma maneira que no rotor, podem ser resultado da presença de materiais inapropriados causando efeitos destrutivos como a redução na dissipação de calor, falhas prematuras nos enrolamentos, corrosões e defeitos na isolação (PINHEIRO, 2011).

### 3.3 FALHAS NOS ROLAMENTOS


Constatado por Siddique *et al.* (2005), as falhas no rolamento são aquelas de maior valor estatístico, concentrando quase metade das falhas visualizadas nos estudos de IEEE e EPRI. Por outro lado, são falhas que permitem maior facilidade maior de detecção por monitoramento das informações de vibração e acústica.

Rolamentos esféricos, como aquele mostrado na Figura 6, ou deslizantes (mancais) são usados em larga escala e em uma variedade grande de máquinas. Apesar de serem projetados para funcionar durante toda a vida útil do motor, defeitos de funcionamento não são raros. Os materiais utilizados nos rolamentos são submetidos aos maiores níveis de esforços, já que toda a transmissão de força mecânica se dá através deles. Pode-se dizer que a causa mais comum para a falta é a fadiga do metal utilizado na fabricação (HATTANGADI, 2005).

Outras condições determinantes para as faltas no rolamento são (IEEE, 2007):

- sobrecargas térmicas;
- lubrificação excessiva, inadequada ou ausente;
- contaminação do lubrificante por poeira, umidade e gases corrosivos;
- carga excessiva no eixo;
- excesso de vibração;
- desalinhamento dos eixos do motor e da carga que está sendo acionada;
- correntes de falta do eixo para terra, gerando corrosão eletrolítica;
- montagem incorreta, aplicação incorreta, danos de transporte ou armazenamento.

Figura 6 – Rolamento esférico detalhado



Fonte: adaptado de (GORDO et al., 1997)

Podem ser citadas também como causas de falhas no rolamento as correntes elétricas que circulam pelo elemento em função da carga eletrostática induzida no eixo do motor quando acionado por inversores (ARAÚJO, 2011).



## 4 DETECÇÃO E DIAGNÓSTICO DE FALHAS

A detecção e o diagnóstico de falhas em motores de indução é importante pauta de estudos pelos pesquisadores e acadêmicos do universo da engenharia. Dentro deste campo de pesquisa, podem-se encontrar inúmeros métodos para diferentes falhas em diversos estágios de condição da máquina. Esses métodos utilizam sinais como corrente, tensão, temperatura, vibração, ruído, entre outros, para reconhecer padrões que possam revelar indícios de anormalidades nos motores de indução industriais (AMANUEL et al., 2021).

### 4.1 TÉCNICAS E FERRAMENTAS

A metodologia de identificação de falhas é composta por três etapas, mostradas na Figura 7: Aquisição de dados; Processamento dos sinais; Detecção e diagnóstico da falha (JANDREICE, 2019). O presente projeto aborda os recursos que podem ser empregados em cada uma das etapas da metodologia proposta, conforme é apresentado a seguir.

Figura 7 - Fluxograma de identificação de falhas



Fonte: adaptado de (JANDREICE, 2019)

#### 4.1.1 Sensoriamento dos motores

A aquisição das informações dos sinais a serem processados, e posteriormente estudados, a fim de entender as faltas associadas, pode ser feita de diversas maneiras. O pesquisador pode usar a estratégia de multissensoriamento com

a finalidade de encontrar múltiplas grandezas como corrente, tensão, vibração e ruídos ou, com essa mesma estratégia, focar em apenas uma grandeza, porém vista em âmbitos diferentes. Além disso, para o estudo que foca em uma grandeza específica, os sinais podem trazer informações sobre as peças do motor de forma indireta. Um exemplo são as falhas no rolamento, que podem ser detectadas tanto na assinatura da corrente, quanto na frequência de vibração, sabendo que a vibração do componente pode variar o torque do motor e, então, refletir no comportamento das correntes do estator (BÓRNEA, 2022).

#### 4.1.2 Transformada de *Fourier*

A análise de *Fourier* surgiu com o matemático Jean Baptiste Joseph Fourier (1768-1830) com o propósito de solucionar uma equação de distribuição de temperaturas. Sua função é gerar um espectro de frequências e informações que geralmente não estão disponíveis no domínio do tempo. A transformada de *Fourier* (FT) é uma variação da análise para os sinais contínuos e não periódicos. E, para sinais discretos e periódicos finitos, utiliza-se a Transformada Discreta de *Fourier* (DFT) (JESUS, 2019).

Para uma função  $x = x(t)$ , a FT é definida por (14):

$$X(\omega) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j \cdot \omega \cdot t} \cdot dt \quad (14)$$

onde:

$x(t)$  – sinal a ser transformado;

$X(\omega)$  – sinal  $x(t)$  representado no domínio da frequência ( $\omega$ );

A função que representa a DFT é mostrada em (15):

$$X(m) = \sum_{n=0}^{Na-1} x(n) \cdot e^{-j \cdot \left(\frac{2 \cdot \pi}{Na}\right) \cdot m \cdot n} \quad (15)$$

onde:

- $n$  – número inteiro entre  $[0... Na]$ , que representa o índice do vetor discreto do sinal  $x(n)$  no domínio do tempo;
- $m$  – número inteiro entre  $[0... Na]$ , que representa o índice do vetor discreto do sinal  $x(n)$  no domínio da frequência;
- $Na$  – quantidade total de amostras.

O cálculo de uma DTF é equivalente ao cálculo da FT em  $Na$  amostragens de frequência, com espaçamento conforme (16):

$$\omega_m = \frac{2 \cdot \pi \cdot m}{Na} \quad (16)$$

onde:

$\omega_m$  – amostragem de frequência.

#### 4.1.2.1 Transformada Rápida de Fourier

A Transformada Rápida de Fourier (FFT) é comprovadamente o método mais eficaz para realizar a transformação de frequências. Ela necessita de uma menor performance computacional, pois reduz o número de operações ao executar a premissa de não utilizar cálculos matriciais (JESUS, 2019).

Segundo Smith (2013), a FFT funciona conforme os três passos a seguir, assim resumidos:

1. Decomposição entrelaçada, que consiste em decompor o sinal original de duas em duas partes, inicialmente divididos em par e ímpar. O algoritmo colhe sempre o primeiro e o terceiro ponto de cada parte do vetor que foi dividido, em primeiro instante, o vetor com os pontos pares e com os pontos ímpares. Por exemplo, um sinal com oito pontos é dividido, tornando-se dois sinais com quatro pontos que, por sua vez, transforma-se em quatro sinais com dois pontos e assim sucessivamente, até que se transforma em oito sinais com um ponto cada.

2. Encontro do espectro de frequência em cada ponto, ou seja, o sinal que foi multiplicado, transformando-se em vários sinais com um ponto apenas (espectro de frequência) que já está no domínio da frequência.
3. Combinação desses vários pontos com N espectros de frequência em um sinal apenas. Em outras palavras, é feito o reverso do que foi feito no primeiro passo, isto é, os pontos são sintetizados até que são transformados em um espectro de frequência (chamado de diagrama borboleta) com oito pontos, que é a saída do FFT.

Conforme citado no passo número 1, para decompor o sinal de duas em duas partes, é necessário que o valor de  $Na$  de (2) e (3) seja representado em potência de dois, como mostrado em (17):

$$Na = 2^v \quad (17)$$

onde:

$v$  – número inteiro e positivo.

#### 4.1.3 Transformada de *Hilbert*

A Transformada de *Hilbert* foi criada pelo matemático alemão David Hilbert, nascido na Alemanha em 23-01-1862 e falecido em 14-02-1943. Resumidamente, enquanto a transformada de *Fourier* transforma o domínio da função, por exemplo, passando do domínio tempo para o domínio frequência, ou vice-versa, a transformada *Hilbert* mapeia uma função em outra no mesmo domínio, considerando as fases das componentes discretas do sinal original, o que é interessante em algumas aplicações (JESUS, 2019).

A definição da transformada de *Hilbert* (HT) está na convolução entre um sinal real no domínio do tempo. Ela adianta a fase do sinal em  $90^\circ$ , conforme (18), e não altera a amplitude nem o domínio do sinal dois, como mostrado em (10):

$$H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(t - \tau)}{\tau} d\tau \quad (18)$$



onde:

$H$  – Transformada de *Hilbert*;

$x(t)$  – sinal variante no tempo (sinal real);

$\tau$  – variável de integração.

A HT possui diversas aplicações, tanto no campo da engenharia, quanto no da medicina e sismologia. A seguir são listados alguns exemplos de utilização desta transformada:

- Análise de vibração em motores e rolamentos;
- Diagnósticos de falhas em rotores de motores de indução;
- Modulação e demodulação de sinais em sistemas de comunicação;
- Processamento e codificação de imagens;
- Eletromedicina;
- Análises de sinais sismológicos.

#### 4.1.4 Transformada de *Wavelet*

A transformada de *Wavelet* (WT) foi desenvolvida no campo acadêmico com o objetivo de suprir algumas desvantagens intrínsecas da transformada de *Fourier*, que não consegue identificar eventos característicos do domínio do tempo. *Wavelet*, cuja tradução literal seria “ondaleta” ou “onda pequena” ou “ondinha” ou ainda “leve ondulação”, utiliza um método de segmentação de regiões que variam no tempo e pode ajudar no reconhecimento de atributos específicos na análise dos sinais coletados (BÓRNEA, 2022) (JANDREICE, 2019).

A maneira em que a transformada de *Wavelet* de tempo contínuo é calculada é mostrada em (19).

$$CWT(a, b) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{a}} \Psi \left( \frac{t - b}{a} \right) dt \quad (19)$$

onde:

$CWT$  – Transformada de *Wavelet*;

$x(t)$  – sinal a ser decomposto;

$a$  – parâmetro de escala (contração/dilatação);

$b$  – parâmetro de deslocamento;

$\Psi$  – wavelet-mãe.

#### 4.1.5 Aprendizagem de Máquina

A aprendizagem de máquina, do inglês *Machine Learning* (ML), é um dos pilares da inteligência artificial (IA), que tem como base executar funções de modo autônomo, como por exemplo, diagnosticar falhas nos motores de indução trifásicos (JESUS, 2019).


Diversos tipos de problemas do mundo real podem ser solucionados pelo ML. Um método de solução pode ser descrito como uma sobreposição de específicas variedades de algoritmos a fim de resolver um tipo particular de problema. Fundamentalmente, os três métodos mais populares de ML são: aprendizagem *supervisionada*, *não supervisionada* e *por reforço* (CHINNAMGARI, 2019).

##### 4.1.5.1 Aprendizagem Supervisionada

A aprendizagem supervisionada, cujo processo é mostrado na Figura 8, é aplicada em modelagens com resultados claros de um problema proposto. No entanto, essa modelagem não tem embasamento para explicar como os dados afetam o resultado que está ali colocado (CHINNAMGARI, 2019).

Para que uma questão seja solucionada via aprendizagem supervisionada, é necessária a utilização de dados devidamente rotulados e com respostas pré-definidas para a correta interpretação. Enquanto isso, divide-se o sistema de dados em conjunto de treino e conjunto de testes, de modo que o algoritmo aprenda com os dados de treinamento a fim de gerar um modelo final que deverá prever as soluções do conjunto de testes (CHINNAMGARI, 2019).

Figura 8 - Processo de Aprendizagem Supervisionada



Fonte: adaptado de (CHINNAMGARI, 2019)

#### 4.1.5.2 Aprendizagem Não Supervisionada

A modelagem supervisionada citada no item anterior é factível por diversos motivos, porém a rotulação dos resultados é essencial para que se possa utilizar modelos classificadores ou de regressão.

Quando um problema exposto não tem a disponibilidade de respostas, o que é uma prática muito comum por ser relativamente mais barato no quesito de aquisição de dados, adotam-se algoritmos denominados de modelos não supervisionados. São exemplos de aprendizagem não supervisionada: segmentação de dados (*clustering*), associação e redução de dimensionalidade (CHINNAMGARI, 2019).

A Figura 9 apresenta uma segmentação de dados de um modelo não supervisionado, em que se utiliza o reconhecimento de padrões e características semelhantes entre as amostras. Dessa forma, a inteligência artificial consegue reconhecer três grupos distintos como ilustrado.

Figura 9 - Exemplo de Aprendizagem Não Supervisionada



Fonte: adaptado de (CHINNAMGARI, 2019)

#### 4.1.5.3 Aprendizagem por reforço

A aprendizagem por reforço, do inglês *reinforcement learning* (RL), não se encaixa em nenhum dos tipos de ML já citados no presente projeto. Nesse método, cria-se um agente que aprenderá os melhores resultados com base no meio-ambiente previamente dimensionado. O agente receberá recompensas à medida que as tentativas de solução ocorrerem (CHINNAMGARI, 2019).

Por este motivo, não se pode caracterizar o algoritmo como supervisionado, já que não existem rótulos na base de dados. De outro lado, não será possível denominá-lo não supervisionado, pois o sistema deve ser alimentado com um guia de recompensas para que o agente evolua conforme suas ações sejam tomadas (CHINNAMGARI, 2019).

São exemplos de problemas solucionados por aprendizagem por reforço: jogos diversos como jogo da velha, jogos eletrônicos, xadrez, labirintos, entre outros.

#### 4.1.6 Métricas de Avaliação de Desempenho

Na presente seção, serão apresentados os parâmetros escolhidos para avaliar o desempenho dos modelos classificadores de aprendizagem supervisionada. Para o modelo de classificação escolhido, só existem quatro possibilidades de resultados comparativos no conjunto de testes (CHINNAMGARI, 2019), conforme mostra a Tabela 2.

As possibilidades são:

VP - verdadeiro positivo;

FP - falso positivo;

FN - falso negativo;

VN - verdadeiro negativo.

Tabela 2 - Matriz de confusão para modelos estatísticos

Matriz de Confusão		Conjunto de Testes	
		Falha	Não Falha
Resultado do Modelo	Falha	<b>VP</b>	<b>FP</b>
	Não Falha	<b>FN</b>	<b>VN</b>

Fonte: adaptado de (JESUS, 2019)

Dados os indicadores citados na Tabela 2, podem ser aferidas diversas métricas a fim de analisar parâmetros dos modelos aplicados. A seguir, constam as medidas que serão utilizadas ao final do processo de modelagem e que são mostradas na Tabela 3.

1. Acurácia (ACC) avalia o percentual de acertos do modelo;
2. Sensibilidade (S) demonstra a capacidade de detecção de resultados positivos;
3. Precisão (P) avalia a quantidade de VP dentre todos os resultados positivos;
4. F-score (F1) métrica comparativa que utiliza a precisão e a sensibilidade como base.

Tabela 3 - Parâmetros de avaliação dos modelos


Parâmetros		
	Métrica	Equação
1	Acurácia (ACC)	$\frac{VP + VN}{VP + FP + VN + FN}$
2	Sensibilidade (S)	$\frac{VP}{VP + FN}$
3	Precisão (P)	$\frac{VP}{VP + FP}$
4	F-score (F1)	$2 \cdot \frac{P \cdot S}{P + S}$

Fonte: adaptado de (JESUS, 2019)

Outro importante indicador na avaliação de modelos de classificação é a curva ROC (*Receiver Operating Characteristic*), que é definida por um plano cartesiano em que o eixo Y representa a taxa de verdadeiros positivos no modelo e o eixo X representa a taxa de falsos positivos. Pode-se também retirar o valor de AUC (*Area Under the Curve*) da curva gerada para cada modelo. Assim, é possível discriminar e comparar os modelos gerados para o presente projeto. (JESUS, 2019).

Na Figura 10 é possível compreender de que forma se dá o comparativo mencionado e, com a ajuda da Tabela 4, classificar o modelo como excelente, bom, fraco, ruim ou aleatório. Quanto mais próximo de A for a curva de um classificador, melhor é a sua previsão, obtendo um valor máximo de AUC igual a 1,0.

Figura 10 – Curva ROC e exemplos de classificadores



Fonte: adaptado de (PARK *et. al.*, 2004)

Tabela 4 – Interpretação do indicador AUC

AUC	Interpretação do Modelo
0,9 a 1,0	Excelente
0,8 a 0,9	Bom
0,7 a 0,8	Regular
0,5 a 0,7	Ruim
0 a 0,5	Aleatório

Fonte: adaptado de (JESUS, 2019)





## 5 DESENVOLVIMENTO DO MÉTODO DE DETECÇÃO

Como citado nos capítulos anteriores, as falhas no MIT são majoritariamente oriundas de falhas nos rolamentos. Estes motores são amplamente utilizados na indústria como consequência de sua simplicidade e produtividade. Todavia, mesmo com sua robustez, é um componente suscetível a danificações naturais do ambiente fabril. Então, a fim de uma análise acadêmica das falhas causadas pelas condições de operação, é necessária uma bateria de testes em laboratório que possam simular acontecimentos industriais (JANDRICE, 2019).

Além disso, para a elaboração de um sistema de detecção de falhas baseado em um modelo de aprendizagem de máquina eficaz, é necessária a utilização de um conjunto de dados robusto e confiável. Então, para o presente trabalho, utilizou-se a base de dados de Ribeiro (2021), que focou seu estudo na simulação de falhas oriundas dos rolamentos.

### 5.1 BASE DE DADOS

Ribeiro (2021) realizou um trabalho experimental em que capturou as informações de rotação de um motor, posição angular, radial e tangencial dos rolamentos, além de sinais de ruído para as seguintes falhas mecânicas: Desalinhamento vertical e horizontal; Desbalanceamento; Falhas de rolamento na gaiola, esfera e anel externo.

A base de dados é composta por 1951 séries temporais adquiridas por sensores em um simulador de falhas chamado MFS (*Machinery Fault Simulator*) da empresa *SpectraQuest*, ilustrado na Figura 11.

Figura 11 - MFS da SpectraQuest Inc



Fonte: adaptado de (SPECTRAQUEST)

Dadas as 1951 séries adquiridas pelo sistema apresentado anteriormente, o projeto realizado capturou diversas amostras de cargas dentro das falhas sugeridas pelo acadêmico responsável. A Tabela 5 apresenta os testes que foram efetuados, bem como, a quantidade de experimentações para cada modelo que resultaram nas séries levantadas. Nessa tabela, os termos “Desalinhamento Angular Negativo” e “Desalinhamento Angular Positivo” significam a situação em que o sistema de acoplamento está exercendo uma força angular sobre o rolamento, negativa ou positiva.

Tabela 5 – Sequência de falhas simuladas

Sequência		Testes / Séries Adquiridas
Normal		49
Desalinhamento Horizontal		197
Desalinhamento Vertical		301
Desbalanceamento		333
Desalinhamento Angular Negativo	Separador	188
	Anel Externo	184
	Esferas	186
Desalinhamento Angular Positivo	Separador	188
	Anel Externo	188
	Esferas	137
Total		1951

Fonte: adaptado de (RIBEIRO, 2021)

As tabelas a seguir contém as variações de cargas a fim de entender a oscilação dos resultados para as falhas apresentadas na Tabela 5, totalizando o valor de 1951 séries. A Tabela 6 mostra as variações de medidas para a falha de desalinhamento, a Tabela 7, as variações de carga para a falha de desbalanceamento e, finalmente, a Tabela 8, as variações de carga para a falha de desalinhamento angular de rolamento.

Tabela 6 – Variações de medidas para a falha de desalinhamento

Tipo de Falha	Desalinhamento (mm)	Testes / Séries Adquiridas
Desalinhamento Vertical	0,51	51
	0,63	50
	1,27	50
	1,40	50
	1,78	50
	1,90	50
Desalinhamento Horizontal	0,50	50
	1,00	49
	1,50	49
	2,00	49
<b>Total</b>		<b>498</b>

Fonte: adaptado de (RIBEIRO, 2021)

Tabela 7 - Variações de carga para a falha de desbalanceamento

Tipo de Falha	Peso (g)	Testes / Séries Adquiridas
Desbalanceamento	6	49
	10	48
	15	48
	20	49
	25	47
	30	47
	35	45
<b>Total</b>		<b>333</b>

Fonte: adaptado de (RIBEIRO, 2021)

Tabela 8 - Variações de carga para a falha de desalinhamento angular de rolamento

Tipo de Falha	Peso(g)	Testes / Séries Adquiridas		
		Separador	Anel Externo	Esferas
Desalinhamento Angular Negativo	0	49	49	50
	6	48	49	49
	20	49	49	49
	35	42	37	38
Desalinhamento Angular Positivo	0	49	49	49
	6	49	49	43
	20	49	49	25
	35	41	41	20
<b>Total</b>		<b>376</b>	<b>372</b>	<b>323</b>

Fonte: adaptado de (RIBEIRO, 2021)

## 5.2 MÉTODOS UTILIZADOS

Para cada série do banco de dados disponibilizado, foi gerado um *dataframe* de oito colunas. Cada coluna corresponde a um sensor do MFS utilizado, como discriminado a seguir: Tacômetro para medição da velocidade de rotação; Posições axial, radial e tangencial do rolamento, tanto para o desalinhamento angular positivo, quanto negativa; Microfone para captação de áudio. Os dados foram armazenados em arquivos CSV (do inglês *Comma-Separated Values*).

Para a leitura e processamento dos dados, foi necessária a implementação de um ambiente de codificação em linguagem de programação *Python*, no caso, em um PC Intel *core i5*, com frequência de processamento de 2,5 GHz e 16 GB de memória RAM.

A primeira etapa constituiu na implementação da técnica de diminuição amostral, a fim de otimizar a performance do modelo, diminuir o custo do processamento e avaliar a eficiência das abordagens propostas.


Na segunda etapa preocupou-se em analisar os valores de sinal no tempo contínuo para os testes de sequência normal, em que não houve falhas. Estes dados serão importantes para o seguimento do processo, já que serão utilizados modelos

classificadores, ou seja, que necessitam da rotulação de resultados para um entendimento completo do problema.

A Figura 12 mostra o resultado da coleta de dados de vibração axial do rolamento, a Figura 13 mostra a vibração radial do rolamento e, finalmente, a Figura 14 mostra a vibração tangencial do rolamento, os três casos para o funcionamento normal do equipamento. Nas abscissas está representada a quantidade de amostras observadas após a técnica de diminuição amostral e nas ordenadas a amplitude em milímetros da vibração verificada pelos sensores.


Na etapa seguinte, foram analisadas as vibrações no domínio do tempo para falhas mais robustas a fim de entender se existe alguma alteração perceptível nos gráficos. A Figura 15 apresenta a vibração axial do rolamento, a Figura 16, a vibração radial do rolamento e, por sua vez, a Figura 17 mostra a vibração tangencial do rolamento, nos três casos para uma falha de desbalanceamento com carga de 35 g, onde 35 g indica a aplicação carga de 35 gramas a fim de gerar o desbalanceamento. Nesses gráficos, as abscissas representam a quantidade de amostras observadas após a técnica de diminuição amostral e as ordenadas a amplitude em milímetros da vibração verificada pelos sensores.

Figura 12 - Vibração axial do rolamento no tempo para o funcionamento normal




Fonte: Autoria própria

Figura 13 - Vibração radial do rolamento no tempo para o funcionamento normal



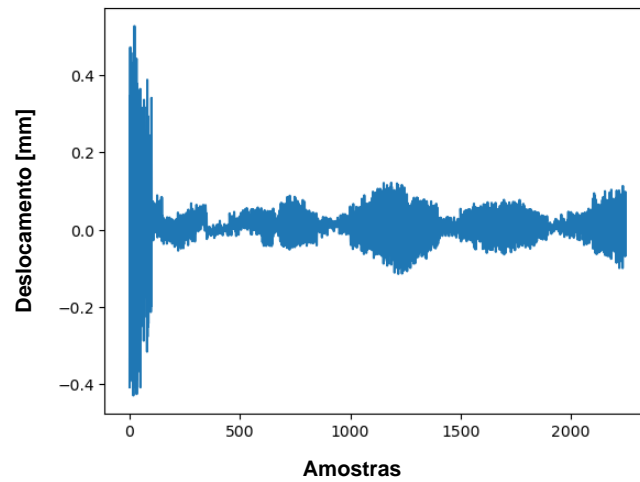
Fonte: Autoria própria

Figura 14 - Vibração tangencial do rolamento no tempo para o funcionamento normal



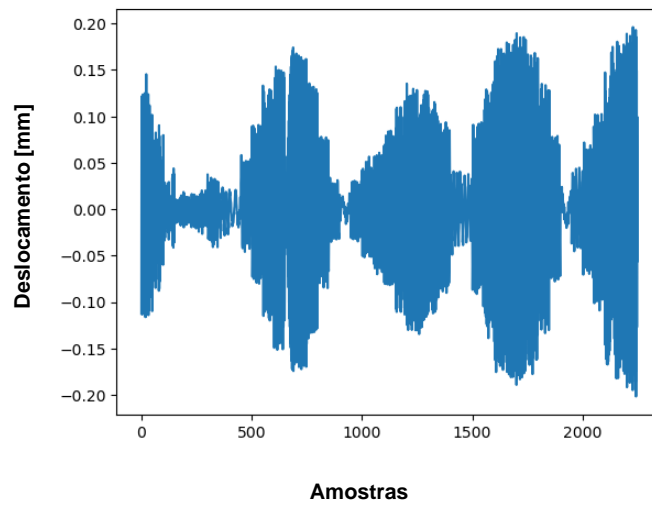
Fonte: Autoria própria

Figura 15 - Vibração axial do rolamento para uma falha de desbalanceamento com carga de 35 g



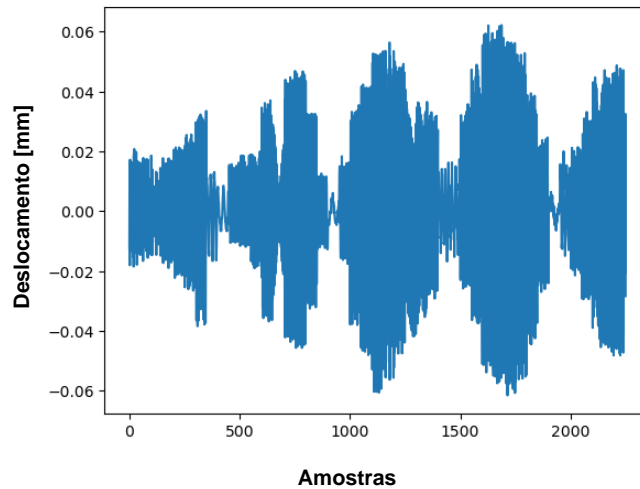
Fonte: Autoria própria

Figura 16 - Vibração radial do rolamento para uma falha de desbalanceamento com carga de 35 g



Fonte: Autoria própria

Figura 17 - Vibração tangencial do rolamento para uma falha de desbalanceamento com carga de 35 g



Fonte: Autoria própria

### 5.2.1 Transformada Rápida de Fourier FFT

Seguindo com a metodologia de processamento de dados apresentada no capítulo 4, foi aplicada a Transformada Rápida de Fourier (FFT) para todas as 1951 séries adquiridas pelo sistema. Utilizou-se uma biblioteca para a linguagem *Python* chamada *scipy*, que foi criada para matemáticos, cientistas e engenheiros quando for necessária a manipulação científica de dados.


A partir disso, pode-se comparar melhor os gráficos de sequência normal e de falhas no domínio da frequência. A Figura 18 mostra os sinais de vibração no domínio da frequência para o funcionamento normal, com pico de deslocamento em 450 mm, na Figura 19, os sinais de vibração no domínio da frequência para desbalanceamento com carga de 35 g, com picos de deslocamento em 600 mm e 260mm negativos, e a Figura 20 mostra o comparativo de sinais de falhas de desbalanceamento, sendo o primeiro para um funcionamento normal. Nos três gráficos, as abscissas representam a quantidade de amostras e as ordenadas a amplitude de vibração no domínio da frequência.

Para interpretar o gráfico mostrado na Figura 20, deve-se considerar o conjunto de falhas de desbalanceamento citados na tabela 7. As transformadas foram




colocadas em sequência (de 6 g a 35 g) a fim de ilustrar o comparativo das falhas nas curvas do domínio da frequência com o funcionamento normal de um motor.

Figura 18 – Sinais de vibração no domínio da frequência para o funcionamento normal



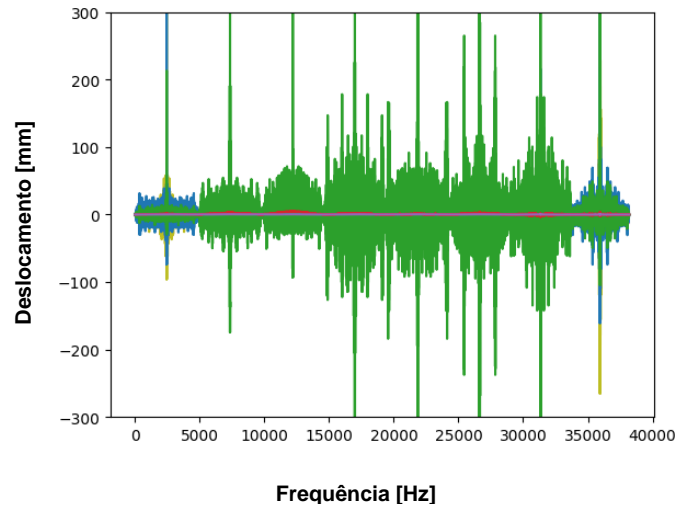
Fonte: Autoria própria

Figura 19 - Sinais de vibração no domínio da frequência para de desbalanceamento com carga de 35 g



Fonte: Autoria própria

Figura 20 - Comparativos de sinais de falhas de desbalanceamento, sendo o primeiro um funcionamento normal



Fonte: Autoria própria

## 5.2.2 Modelos Classificadores

Como apresentado no Capítulo 4 e ilustrado na Figura 8, para que se possa aplicar a aprendizagem de máquina supervisionada, são necessários dados rotulados e uma divisão dos dados em base de treino e base de teste. Para o caso do presente trabalho, os dados de teste foram escolhidos na proporção 25/75, ou seja, 25% da base de dados será utilizada para o teste e o restante estará empregado no treinamento do modelo escolhido.


### 5.2.2.1 Classificador SVM

O SVM, do inglês *Support Vector Machine*, é um modelo que tem como característica principal a diferenciação de duas classes com a criação de um hiperplano, como mostra a Figura 21.

O classificador tem como vantagem a eficácia para os problemas em que o número de dimensões é maior que o número de amostras e como desvantagem o

baixo desempenho para grandes conjuntos de dados, pois seu tempo de treinamento é relativamente grande.

Figura 21 - Classificação SVM de dois rótulos




Fonte: Adaptado de (JESUS, 2019)

#### 5.2.2.2 Classificador *k*-NN

KNN, do inglês *K-nearest neighbors*, é um dos algoritmos mais conhecidos no âmbito de ciência de dados para aprendizagem supervisionada. O modelo se baseia na categorização de novos dados com base em sua colocação em uma região no espaço de dispersão. Observando-se a Figura 22, nota-se que o fator solucionador do problema será a similaridade entre o novo dado e os vizinhos que já estão classificados.

Um fator determinante no resultado do modelo é referente à letra K de seu nome. K é uma variável que permite a seleção da quantidade de vizinhos classificados que serão impactantes na categorização do novo dado. Para o presente projeto, será usado o fator  $K = 5$ . Com base nos resultados testados e na teoria de que se deve escolher um número que seja uma paridade oposta ao número de classes do sistema. Como o sistema proposto tem duas classes (falha ou não-falha), deve-se escolher um número ímpar para sempre haver um desempate.

Figura 22 – Classificação k-NN de dois rótulos



Fonte: Adaptado de (JESUS, 2019)

## 6 RESULTADOS OBTIDOS

No presente capítulo são apresentados os principais resultados obtidos a partir das implementações dos métodos e modelos descritos, visando à detecção de falhas nos motores de indução.

Após os ajustes gerais necessários, citados na Seção 5.2, com o desenvolvimento da técnica de diminuição amostral, a realização da Transformada Rápida de *Fourier* e a devida concatenação das diversas bases em um arquivo principal, foram aplicadas as implementações dos modelos classificadores SVM e k-NN, explicados na Seção 5.2.2, para cada falha levantada abrangendo todas as variações de carga e desalinhamentos.

### 6.1 DESBALANCEAMENTO DE CARGA

A Tabela 9 representa os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 28644 amostras e um conjunto de teste com 9548 amostras. Foram analisadas as sete variações levantadas nos testes com a MFS: cargas de 6 g; 10 g; 15 g; 20 g; 25 g; 30 g e 35 g.

Pode-se notar que, apesar de uma moderada acurácia em ambos os resultados, as curvas ROC ilustradas na figura 23 e 24 mostraram uma relação satisfatória de verdadeiros positivos, trazendo um AUC no limite entre regular e bom. A Tabela 10 apresenta a AUC para o desbalanceamento de carga.


Uma possível explicação para a baixa acurácia seria que as cargas testadas são muito próximas, gerando uma confusão nos limites das categorias. Isso também pode explicar o motivo pelo qual o k-NN foi melhor neste caso, já que, por característica, o modelo lida melhor com problemas acima de categorias binárias.

Tabela 9 – Métricas de avaliação para desbalanceamento de carga

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,567	0,573	0,567	0,546
k-NN – 5 Vizinhos	0,619	0,643	0,619	0,615

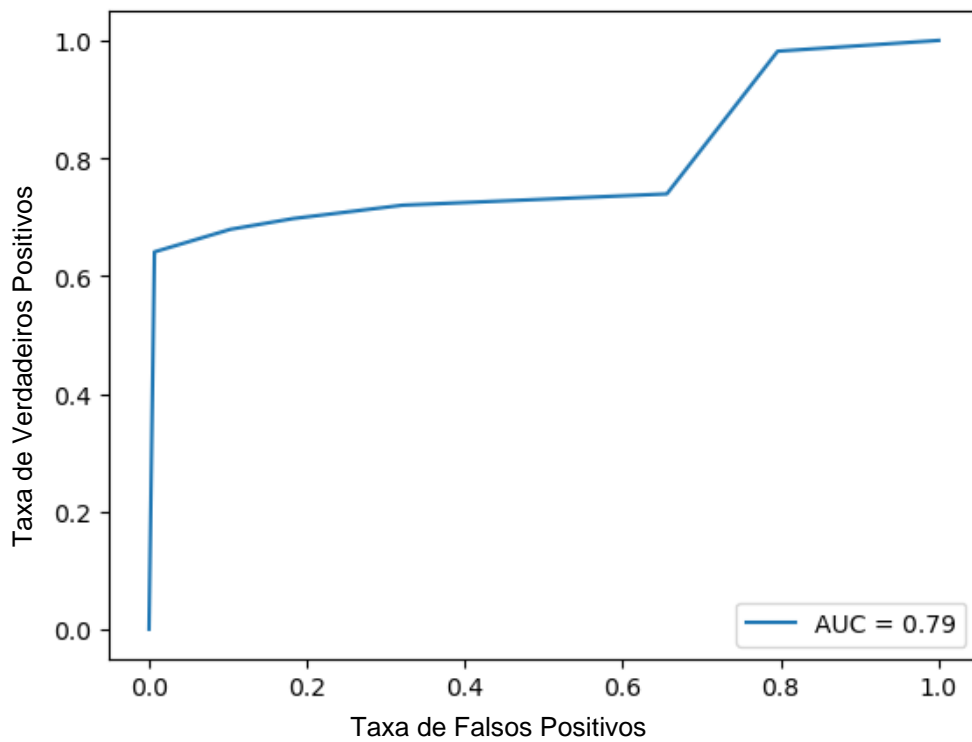
Fonte: Autoria própria

Figura 23 - Curva ROC para desbalancamento de carga – SVM



Fonte: Autoria própria

Figura 24 - Curva ROC para desbalancamento de carga – k-NN



Fonte: Autoria própria

Tabela 10 – AUC para desbalanceamento de carga

Modelos Classificadores	AUC
SVM	0,81
k-NN – 5 Vizinhos	0,79

Fonte: Autoria própria

## 6.2 DESALINHAMENTO HORIZONTAL

A Tabela 11 apresenta os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 18446 amostras e um conjunto de teste com 6149 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: desalinhamentos de 0,5 mm; 1 mm; 1,5 mm e 2 mm. A Figura 25 mostra a curva ROC para desalinhamento horizontal – SVM e a Figura 26 mostra a curva ROC para desalinhamento horizontal – k-NN. Por fim, a Tabela 12 apresenta a AUC para desalinhamento horizontal.

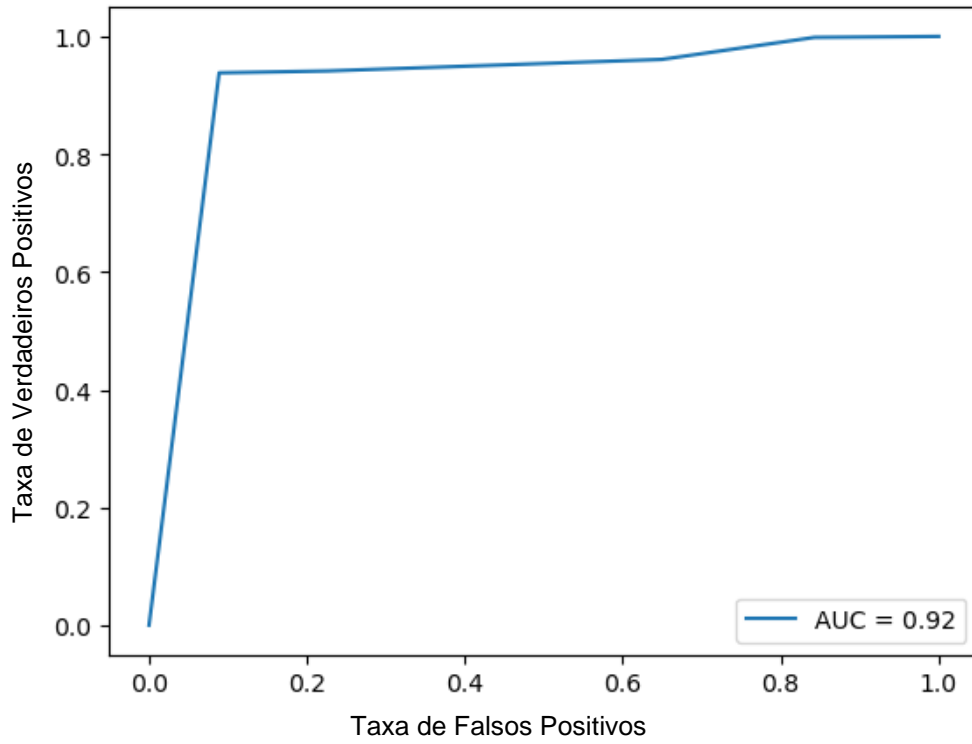
Percebem-se valores melhores de acurácia em ambos os resultados e as curvas ROC para este evento, mostradas na Figura 25 e na Figura 26, beiram o modelo perfeito. Novamente, o classificador k-NN se mostrou uma melhor escolha devido à sua característica de boa definição de limites.

Tabela 11 – Métricas de avaliação para desalinhamento horizontal

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,643	0,663	0,643	0,623
k-NN – 5 Vizinhos	0,729	0,733	0,729	0,727

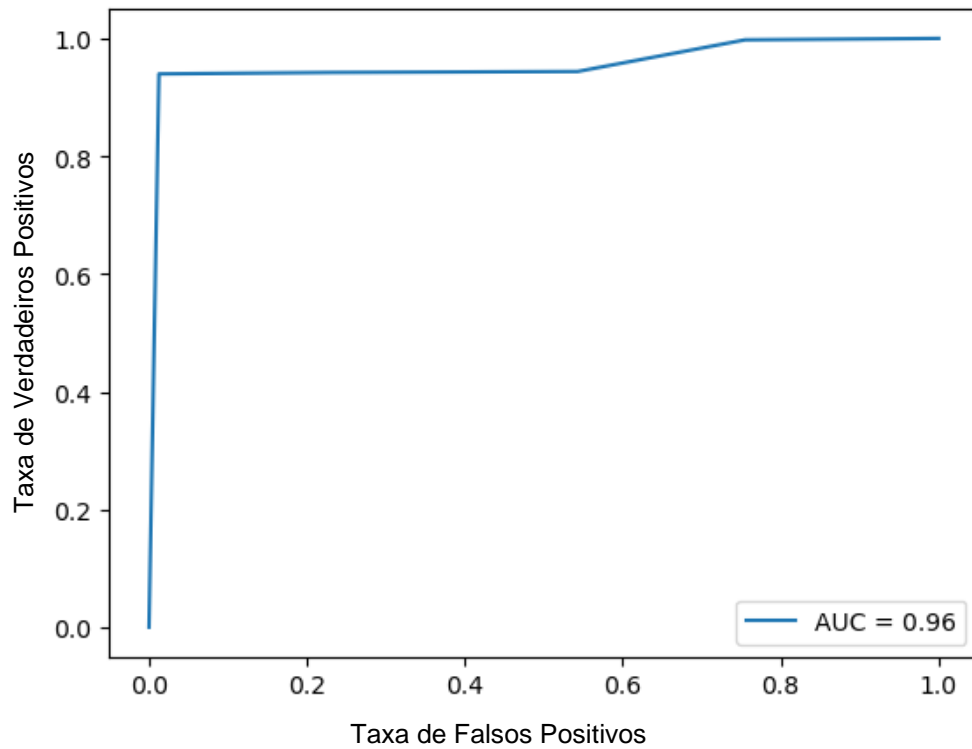
Fonte: Autoria própria

Figura 25 – Curva ROC para desalinhamento horizontal – SVM



Fonte: Autoria própria

Figura 26 – Curva ROC para desalinhamento horizontal – k-NN



Fonte: Autoria própria



Tabela 12 – AUC para desalinhamento horizontal

Modelos Classificadores	AUC
SVM	0,92
k-NN – 5 Vizinhos	0,96

Fonte: Autoria própria

### 6.3 DESALINHAMENTO VERTICAL

A Tabela 13 expõe os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 26244 amostras e um conjunto de teste com 8749 amostras. Foram analisadas as seis variações levantadas nos testes com a MFS: desalinhamentos de 0,51 mm; 0,63 mm; 1,27 mm; 1,40 mm; 1,78 mm e 1,90 mm. A Figura 27 mostra a curva ROC para desalinhamento vertical – SVM e a Figura 28 mostra a curva ROC para desalinhamento vertical – k-NN. Por fim, a Tabela 12 apresenta a AUC para desalinhamento vertical.


O classificador k-NN se mostrou ligeiramente melhor mais uma vez, validando a tendência de um projeto de várias categorias. Pode-se notar também, como no desbalanceamento de cargas, mesmo com uma acuraria não tão boa, as curvas ROC, mostradas na Figura 27 e na Figura 28, ficaram bem classificadas, entrando na categoria de bons modelos.

Tabela 13 – Métricas de avaliação para desalinhamento vertical

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,520	0,565	0,520	0,503
k-NN – 5 Vizinhos	0,601	0,616	0,601	0,605


Fonte: Autoria própria

Figura 27 – Curva ROC para desalinhamento vertical – SVM



Fonte: Autoria própria

Figura 28 – Curva ROC para desalinhamento vertical – k-NN



Fonte: Autoria própria

Tabela 14 – AUC para desalinhamento vertical

Modelos Classificadores	AUC
SVM	0,79
k-NN – 5 Vizinhos	0,84

Fonte: Autoria própria

## 6.4 DESALINHAMENTO ANGULAR NEGATIVO

### 6.4.1 Falha no Anel Externo

A Tabela 15 mostra os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 17471 amostras e um conjunto de teste com 5824 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: massas de 0 g; 6 g; 20 g e 35 g. A Figura 29 mostra a curva ROC para o desalinhamento angular negativo com falha no anel externo – SVM e a Figura 30 mostra a curva ROC para desalinhamento angular negativo com falha no anel externo – k-NN. Por fim, a Tabela 13 apresenta a AUC para desalinhamento angular negativo com falha no anel externo.

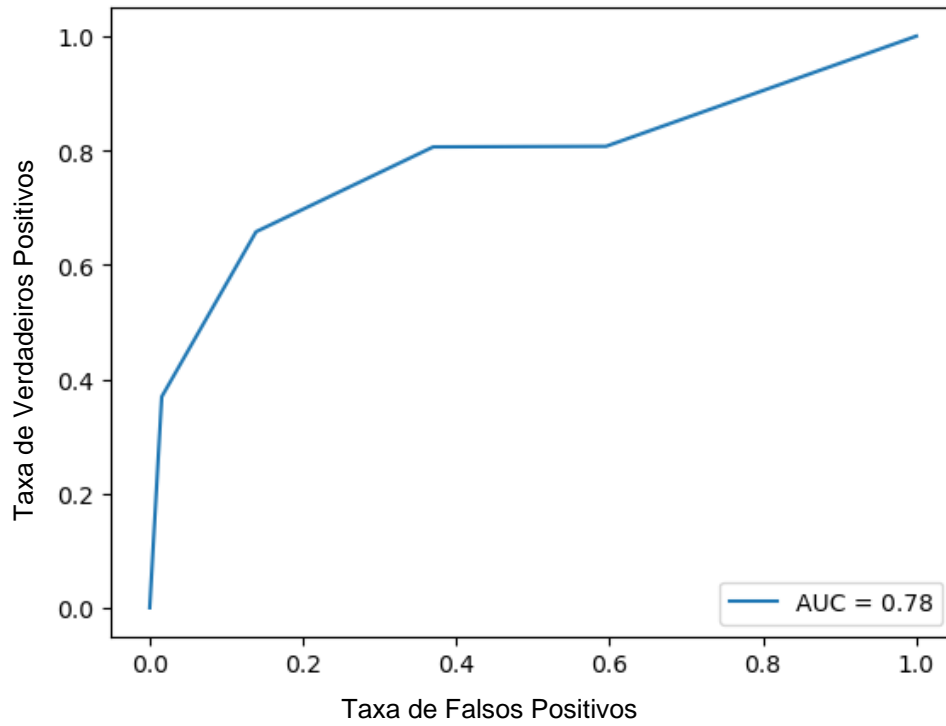
O classificador k-NN, desta vez, atingiu uma notável diferença em se tratando do resultado da curva ROC e seu respectivo AUC, conforme mostram a Figura 29 e a Figura 30.

Tabela 15 – Métricas de avaliação para desalinhamento angular negativo com falha no anel externo

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,662	0,705	0,662	0,655
k-NN – 5 Vizinhos	0,758	0,770	0,758	0,755


Fonte: Autoria própria

Figura 29 – Curva ROC para para desalinhamento angular negativo com falha no anel externo – SVM



Fonte: Autoria própria

Figura 30 – Curva ROC para para desalinhamento angular negativo com falha no anel externo – k-NN



Fonte: Autoria própria

Tabela 16 – AUC para desalinhamento angular negativo com falha no anel externo

Modelos Classificadores	AUC
SVM	0,78
k-NN – 5 Vizinhos	0,87

Fonte: Autoria própria

#### 6.4.2 Falha nas Esferas

A Tabela 17 apresenta os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 17621 amostras e um conjunto de teste com 5874 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: massas de 0 g; 6 g; 20 g e 35 g. A Figura 31 mostra a curva ROC para desalinhamento angular negativo com falha nas esferas – SVM e a Figura 32 mostra a curva ROC para desalinhamento angular negativo com falha nas esferas – k-NN. Por fim, a Tabela 18 apresenta a AUC para desalinhamento angular negativo com falha nas esferas.


Neste caso, ambos os modelos ficaram com resultados muito similares, o que vai de encontro com o restante do projeto. Inclusive, as curvas ROC, mostradas na Figura 31 e na Figura 32, apontam o classificador SVM como uma melhor opção, porém, infelizmente, ambos os resultados são dados apenas como previsões regulares.

Tabela 17 – Métricas de avaliação para desalinhamento angular negativo com falha nas esferas

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,589	0,597	0,589	0,581
k-NN – 5 Vizinhos	0,568	0,587	0,568	0,568


Fonte: Autoria própria

Figura 31 – Curva ROC para para desalinhamento angular negativo com falha nas esferas – SVM



Fonte: Autoria própria

Figura 32 – Curva ROC para desalinhamento angular negativo com falha nas esferas – k-NN



Fonte: Autoria própria

Tabela 18 – AUC para desalinhamento angular negativo com falha nas esferas

Modelos Classificadores	AUC
SVM	0,75
k-NN – 5 Vizinhos	0,73

Fonte: Autoria própria

### 6.4.3 Falha no Separador de Esferas

A Tabela 19 exhibe os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 17771 amostras e um conjunto de teste com 5924 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: massas de 0 g; 6 g; 20 g e 35 g. A Figura 33 mostra a curva ROC para desalinhamento angular negativo com falha no separador esferas – SVM e a Figura 34 mostra a curva ROC para desalinhamento angular negativo com falha no separador esferas – k-NN. Por fim, a Tabela 20 apresenta a AUC para desalinhamento angular negativo com falha no separador esferas.


O caso mais destoante entre os resultados dos classificadores, o SVM (Figura 33) obteve uma péssima acurácia, apesar de seu AUC se manter como um modelo regular. Por outro lado, o k-NN de cinco vizinhos (Figura 34) inferiu o melhor resultado do presente projeto, tanto nas métricas quanto na curva ROC.

Tabela 19 – Métricas de avaliação para desalinhamento angular negativo com falha no separador de esferas

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,348	0,332	0,348	0,275
k-NN – 5 Vizinhos	0,807	0,838	0,807	0,807


Fonte: Autoria própria

Figura 33 – Curva ROC para para desalinhamento angular negativo com falha no separador esferas – SVM



Fonte: Autoria própria

Figura 34 – Curva ROC para desalinhamento angular negativo com falha no separador esferas – k-NN



Fonte: Autoria própria



Tabela 20 – AUC para desalinhamento angular negativo com falha no separador esferas

Modelos Classificadores	AUC
SVM	0,75
k-NN – 5 Vizinhos	0,99

Fonte: Autoria própria

## 6.5 DESALINHAMENTO ANGULAR POSITIVO

### 6.5.1 Falha no Anel Externo

A Tabela 21 expõe os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 17771 amostras e um conjunto de teste com 5294 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: massas de 0 g; 6 g; 20 g e 35 g. A Figura 35 mostra a curva ROC para desalinhamento angular positivo com falha no anel externo – SVM e a Figura 36, a curva ROC para desalinhamento angular positivo com falha no anel externo – k-NN. Por fim, a tabela 22 apresenta a AUC para desalinhamento angular positivo com falha no anel externo.


Ambas as modelagens atingiram níveis satisfatórios de acurácia, com uma leve vantagem de AUC para o classificador de hiperplanos (Figura 35).

Tabela 21 – Métricas de avaliação para desalinhamento angular positivo com falha no anel externo

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,545	0,565	0,545	0,545
k-NN – 5 Vizinhos	0,581	0,624	0,581	0,581


Fonte: Autoria própria

Figura 35 – Curva ROC para para desalinhamento angular positivo com falha no anel externo – SVM



Fonte: Autoria própria

Figura 36 – Curva ROC para para desalinhamento angular positivo com falha no anel externo – k-NN



Fonte: Autoria própria

Tabela 22 – AUC para desalinhamento angular positivo com falha no anel externo

Modelos Classificadores	AUC
SVM	0,80
k-NN – 5 Vizinhos	0,75

Fonte: Autoria própria

### 6.5.2 Falha nas Esferas

A Tabela 23 exhibe os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 13946 amostras e um conjunto de teste com 4649 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: massas de 0 g; 6 g; 20 g e 35 g. A Figura 37 mostra a curva ROC para desalinhamento angular positivo com falha nas esferas – SVM e a Figura 38 mostra a curva ROC para desalinhamento angular positivo com falha nas esferas – k-NN. Por fim, a Tabela 24 apresenta a AUC para desalinhamento angular negativo com falha nas esferas.


Para o presente caso, o empate técnico nas métricas de avaliação não foi sustentado pelas curvas ROC, que mostraram uma ligeira vantagem para o classificador de vizinhos (Figura 38).

Tabela 23 – Métricas de avaliação para desalinhamento angular negativo com falha nas esferas

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,753	0,764	0,753	0,743
k-NN – 5 Vizinhos	0,766	0,767	0,766	0,756


Fonte: Autoria própria

Figura 37 – Curva ROC para desalinhamento angular positivo com falha nas esferas – SVM



Fonte: Autoria própria

Figura 38 – Curva ROC para desalinhamento angular positivo com falha nas esferas – k-NN



Fonte: Autoria própria

Tabela 24 – AUC para desalinhamento angular negativo com falha nas esferas

Modelos Classificadores	AUC
SVM	0,77
k-NN – 5 Vizinhos	0,86

Fonte: Autoria própria

### 6.5.3 Falha no Separador de Esferas

A Tabela 25 representa os resultados obtidos para ambos os classificadores que obtiveram um conjunto de treino composto por 17771 amostras e um conjunto de teste com 5924 amostras. Foram analisadas as quatro variações levantadas nos testes com a MFS: massas de 0 g; 6 g; 20 g e 35 g. A Figura 39 mostra a curva ROC para desalinhamento angular positivo com falha no separador esferas – SVM e a Figura 40 mostra a curva ROC para desalinhamento angular positivo com falha no separador esferas – k-NN. Por fim, a Tabela 26 apresenta a AUC para desalinhamento angular positivo com falha no separador esferas.


Como as curvas ROC obtiveram resultados muito similares, no teste de falhas no separador de esferas com desalinhamento angular positivo do rolamento se pode afirmar que o melhor modelo empregado foi o k-NN de cinco vizinhos (Figura 40), por obter uma ligeira vantagem de acurácia.

Tabela 25 – Métricas de avaliação para desalinhamento angular positivo com falha no separador de esferas

Modelos Classificadores	Acurácia	Precisão	Sensibilidade	F1-Score
SVM	0,548	0,585	0,548	0,556
k-NN – 5 Vizinhos	0,618	0,665	0,618	0,624

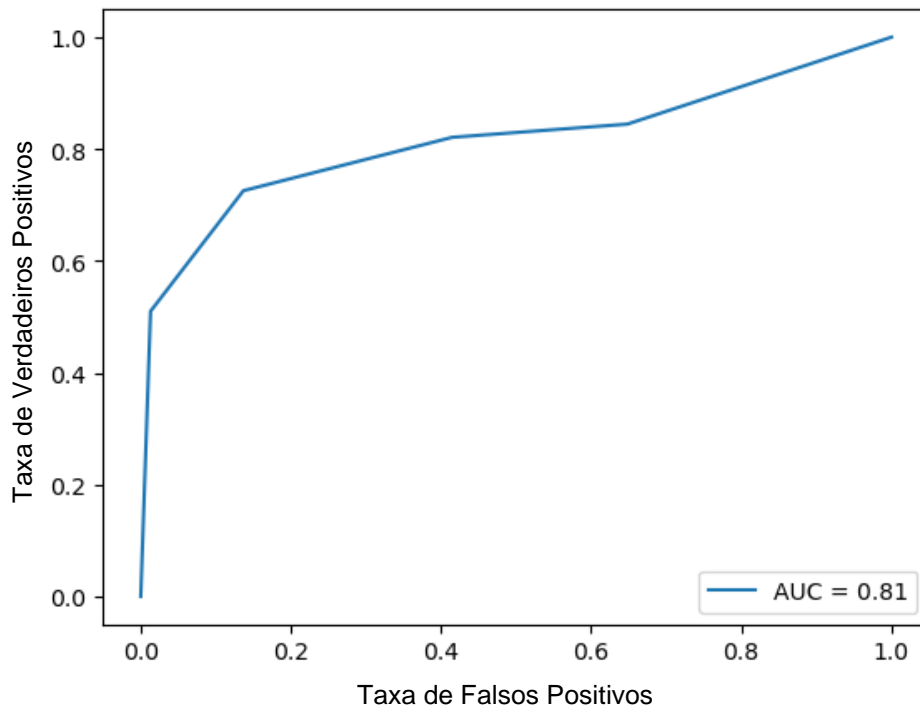
Fonte: Autoria própria

Figura 39 – Curva ROC para desalinhamento angular positivo com falha no separador esferas – SVM



Fonte: Autoria própria

Figura 40 – Curva ROC para desalinhamento angular positivo com falha no separador esferas – k-NN



Fonte: Autoria própria

Tabela 26 – AUC para desalinhamento angular positivo com falha no separador esferas

<b>Modelos Classificadores</b>	<b>AUC</b>
<b>SVM</b>	0,81
<b>k-NN – 5 Vizinhos</b>	0,81

Fonte: Autoria própria

Os resultados obtidos neste capítulo são rapidamente analisados e comentados no Capítulo 7.





## 7 CONSIDERAÇÕES FINAIS

Este trabalho conseguiu atender os objetivos, geral e específicos, apresentados no primeiro capítulo, apresentando um comparativo entre duas modelagens de aprendizagem de máquina classificadoras muito conhecidas no mercado de ciência de dados.

Como levantado durante o projeto, as faltas de motores elétricos de indução podem ocasionar danos às vezes irreparáveis para a máquina ou exigir manutenções corretivas onerosas e que nem sempre recuperam a máquina para o seu estado inicial. Justamente, este custo de manutenção pode ser um dos fatores de ganho em uma eventual aplicação de modelos preditivos em parques fabris.

Os dados utilizados no processo foram extraídos de um importante e complexo estudo brasileiro, o qual teve grande relevância na profundidade dos resultados. Além disso, utilização da FFT no processamento destes dados foi um fator determinante para que os modelos sugeridos fossem mais bem aproveitados.

Os resultados obtidos neste estudo permitem perceber a precisão de dois classificadores inteligentes, SVM e k-NN, uma vez que tais modelos são comumente aplicados em abordagens sobre máquinas elétricas. Todavia, os resultados obtidos mostraram que não existiu uma unanimidade na escolha de uma melhor performance. A depender dos elementos de entrada, foram obtidos resultados excelentes, como as curvas geradas para a falha de desalinhamento horizontal e para o desalinhamento angular negativo com falha no anel externo, assim como resultados regulares, que não garantiriam uma confiança de produção do estudo, como o caso da falha de desalinhamento angular negativo para falha nas esferas. Em resumo, as resoluções foram satisfatórias para um estudo de caso, mas não seriam possíveis na aplicação industrial, a qual demandaria mais eficiência e necessitaria, com certeza, um maior poder de processamento.

Apesar disso, deve-se constatar que a abordagem de vizinhos próximos se mostrou uma opção ligeiramente mais satisfatória, como comentado na seção de resultados. Sua característica de classificação sobre várias categorias acabou impactando em uma melhor acurácia e, conseqüentemente, melhor modelagem para alguns casos testados.

Vale ressaltar também que a melhor solução foi capaz de detectar faltas no rolamento para o caso de desalinhamento angular negativo com falha no separador de esferas em 80% dos casos, independente da carga inserida.

Em vista dos resultados encontrados com os métodos sugeridos, é possível que se façam propostas para trabalhos futuros que estejam relacionados a este estudo, que poderiam envolver diferentes banco de dados ou informações coletadas em laboratório. As proposições estão a seguir:

1. Com o objetivo de melhorar a acurácia dos sistemas, investir em performance de processamento para que não seja necessária a diminuição amostral dos dados;
2. Investigar melhores técnicas de processamento de dados além da FFT, já utilizada;
3. Coletar e utilizar dados próprios em laboratório, a fim de experimentar diferentes falhas que, neste estudo, não foram levantadas;
4. Sugerir modelos de aprendizagem de máquina mais complexos e performáticos, como redes neurais ou classificadores de alta performance.

## REFERÊNCIAS

AMANUEL, Thomas et al. **Design of Vibration Frequency Method with Fine-Tuned Factor for Fault Detection of Three Phase Induction Motor**. Journal of Innovative Image Processing (JIIP), v. 3, n. 01, p. 52-65, 2021.

ARAÚJO, Romero de Souza, **Desgaste Prematuro e Falhas Recorrentes em Rolamentos de Motores de Indução Trifásicos Alimentados por Inversores de Frequência**. UFMG, Belo Horizonte, 2011.

ATO. Three Phase Induction Motor Construction. **Automation Technologies Online**, 2017. Disponível em: <[www.ato.com/three-phase-induction-motor-construction](http://www.ato.com/three-phase-induction-motor-construction)>. Acesso em: 15 mai. 2023.

BARBI, Ivo. **Teoria fundamental do motor de indução**. Florianópolis: Editora da UFSC, 1985.

BONNETT, Austin H.; SOUKUP, George C. **Analysis of rotor failures in squirrel-cage induction motors**. IEEE Transactions on Industry Applications, v. 24, n. 6, p. 1124-1130, 1988.

BÓRNEA, Yuri Piccolo. **Desenvolvimento de sistema para detecção de falhas em rolamentos de motores de indução a partir de seus sinais de vibração**. 2022. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.

BLOCH, Heinz P.; GEITNER, Fred K., **Machinery Failure Analysis and Troubleshooting**. 3a Ed. Volume 2, Gulf Professional Publishing, Houston, 1999.

CHAPMAN, Stephen J. **Fundamentos de máquinas elétricas**. AMGH editora, 2013.

CHINNAMGARI, Sunil Kumar. **R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R 3.5**. Packt Publishing Ltd, 2019.

FELDMAN, Michael. **Hilbert transform in vibration analysis**. Mechanical systems and signal processing, v. 25, n. 3, p. 735-802, 2011.

GORDO, Nívia; FERREIRA, Joel. **Introdução aos elementos de fixação**. Aula 17, 1997. Disponível em: <  
<https://bmalbert.yolasite.com/resources/Elementos%20de%20M%C3%A1quinas.pdf>  
>. Acesso em: 15 mai. 2023.

GUEDES, Manuel Vaz, **O Motor de Indução Trifásico: Seleção e Aplicação**. Faculdade de Engenharia da Universidade do Porto, 1994.

HATTANGADI, A. A., **Plant and Machinery Failure Prevention**. McGraw-Hill, 2005.

IEEE Power Engineering Society, **IEEE Guide for Induction Machinery Maintenance Testing and Failure Analysis**. Nova York, 2007.

JANDREICE, Mateus Persin. **Estudo comparativo de ferramentas estatísticas em falhas de máquinas elétricas**. 2019. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

JESUS, Rodrigo Cardozo de. **Um estudo comparativo entre técnicas de aprendizagem de máquina e processamento de sinais para detectar barras quebradas em um motor de indução trifásico com rotor do tipo gaiola de esquilo**. 2019.

PINHEIRO, Hélio Henrique Cunha. **Sistema para detecção e diagnóstico de falhas em motores elétricos de indução utilizando lógica fuzzy**. 2011. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte.

MALAGOLI, Juliana Almansa; CAMACHO, José Roberto; DA LUZ, Mauricio Valencia Ferreira. **Projeto de rotor de máquina de indução trifásica usando o algoritmo de evolução diferencial**. empírica, v. 1, p. 4, 2014.

NANDI, Subhasis; TOLIYAT, Hamid A.; LI, Xiaodong, **Condition Monitoring and Fault Diagnosis of Electrical Motors – A Review**. IEEE Transactions on Energy Conversion, Vol. 20, No. 4, Dezembro de 2005, pp 719-729.

PARK, Seong Ho; GOO, Jin Mo; JO, Chan-Hee. **Receiver operating characteristic (ROC) curve: practical review for radiologists**. Korean journal of radiology, v. 5, n. 1, p. 11-18, 2004.

RAI, V. K.; MOHANTY, A. R. **Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform**. Mechanical Systems and Signal Processing, v. 21, n. 6, p. 2607-2615, aug. 2007.

REIS, Aderson Jamier Santos, **Reconhecimento de Padrões de Falhas em Motores Trifásicos Utilizando Redes Neurais**. UFRN, Natal, 2010.

RIBEIRO, Felipe M. L.; **Machinery Fault Simulator**. Coppe UFRJ, 2021. Disponível em: <<https://www02.smt.ufrj.br/~offshore/mfs/index.html#TOC1>>. Acesso em: 18 jun. 2023.

SIDDIQUE, Arfat; YADAVA, G. S.; SINGH, Bhim. **A review of stator fault monitoring techniques of induction motors**. IEEE transactions on energy conversion, v. 20, n. 1, p. 106-114, 2005.

SMITH, Steven. **Digital signal processing: a practical guide for engineers and scientists**. Elsevier, 2013.

SPECTRAQUEST, Inc. **Machinery Fault Simulators**. Disponível em: <<https://spectraquest.com/products/simulators/machinery-fault-simulators/>>. Acesso em: 19 jun. 2023.

WEG. **Motor de Indução Trifásico: Rotor Bobinado com Sistema Motorizado de Levantamento das Escovas**. 2013.