

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

**DIEGO ALVES PEDROSO GALO
RENAN STRINA SARAIVA DE QUEIROZ**

**DESENVOLVIMENTO DE SISTEMA BASEADO EM CONHECIMENTO PARA
DIAGNÓSTICO DE MOTORES DE INDUÇÃO TRIFÁSICOS**

CURITIBA

2026

**DIEGO ALVES PEDROSO GALO
RENAN STRINA SARAIVA DE QUEIROZ**

**DESENVOLVIMENTO DE SISTEMA BASEADO EM CONHECIMENTO PARA
DIAGNÓSTICO DE MOTORES DE INDUÇÃO TRIFÁSICOS**

**Development of a Knowledge-Based System for Fault Diagnosis in Three-
Phase Induction Motors**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Elétrica do Curso de
Engenharia Elétrica da Universidade Tecnológica
Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Narco Afonso Ravazzoli
Maciejewski

Coorientador: Prof. Dr. Thiago de Paula Machado
Bazzo

CURITIBA

2026



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.

DIEGO ALVES PEDROSO GALO
RENAN STRINA SARAIVA DE QUEIROZ

**DESENVOLVIMENTO DE SISTEMA BASEADO EM CONHECIMENTO PARA
DIAGNÓSTICO DE MOTORES DE INDUÇÃO TRIFÁSICOS**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Elétrica do Curso de
Engenharia Elétrica da Universidade Tecnológica
Federal do Paraná (UTFPR).

Data de aprovação: 22/junho/2026

Narco Afonso Ravazzoli Maciejewski
Doutorado
Universidade Tecnológica Federal do Paraná

Thiago de Paula Machado Bazzo
Doutorado
Universidade Tecnológica Federal do Paraná

Bruno Akihiro Tanno Iamamura
Doutorado
Universidade Tecnológica Federal do Paraná

Uilian José Dreyer
Doutorado
Universidade Tecnológica Federal do Paraná

CURITIBA

2026

RESUMO

Os motores de indução trifásicos constituem o principal elemento utilizados para conversão de energia elétrica em mecânica na indústria e estão sujeitos a defeitos que, quando não detectadas precocemente, geram paradas não programadas e elevados custos de manutenção. Este trabalho apresenta o desenvolvimento de um sistema baseado em conhecimento para diagnóstico de barras rotóricas quebradas, curto-circuito entre espiras do estator e defeitos em rolamentos, fundamentado na extração de atributos fisicamente interpretáveis do sinal de corrente do estator. Foram investigadas técnicas de processamento para extração de atributos nos domínios do tempo, da frequência e tempo-frequência, incluindo análise espectral, operadores de energia de *Teager-Kaiser* e de terceira ordem, transformada discreta de *Wavelet*, decomposição em pacotes de *Wavelet* e vetor de Park. A classificação foi conduzida por três redes neurais do tipo *Multi-Layer Perceptron* especialistas, treinadas independentemente para cada tipo de defeito a partir de bancos de dados públicos. Desenvolveu-se um *software* que conduz o usuário até a etapa de diagnóstico, centralizando a extração de atributos, o treinamento, os testes em massa e a simulação de diagnóstico em tempo real. Os atributos foram validados antes da integração ao sistema. A rede neural foi avaliada sobre um conjunto de teste, comparando severidade e condição de carga, atingindo acurácia global de 99,16% com os todos atributos selecionados. O operador de energia de terceira ordem destacou-se para barras quebradas, a combinação de análise espectral com razão energética de *Wavelet* apresentou o melhor desempenho para curto-circuito, e a decomposição em pacotes *Wavelet* atingiu o melhor desempenho para defeitos de rolamento. Os resultados validam a abordagem proposta e estabelecem base para futura aplicação em monitoramento contínuo industrial.

Palavras-chave: manutenção preditiva; detecção de defeitos; aprendizado de máquina; extração de atributos.

ABSTRACT

Three-phase induction motors are the main element used for converting electrical energy into mechanical energy in industry and are subject to faults that, when not detected at an early stage, lead to unscheduled downtime and high maintenance costs. This work presents the development of a knowledge-based diagnostic system targeting three of the most common fault types, broken rotor bars, stator inter-turn short-circuits, and bearing defects. The approach is based on physically interpretable features extracted from the stator current signal rather than purely statistical descriptors. Signal processing techniques were investigated across the time, frequency, and time-frequency domains, including spectral analysis, the Teager-Kaiser and third-order energy operators, the discrete Wavelet transform, Wavelet packet decomposition, and the Park vector approach. Classification is performed by three specialist Multi-Layer Perceptron neural networks, each trained independently on a dedicated public dataset for one fault type. A software application was developed that guides the user through to the diagnosis stage, centralizing feature extraction, training, batch testing, and real-time diagnostic simulation. The features were validated before integration into the system. The neural network was evaluated on a test set, comparing severity and load condition, reaching an overall accuracy of 99.16% with all selected features. The third-order energy operator showed the highest discriminative capability for broken rotor bars, the combination of spectral analysis and Wavelet energy ratios achieved the best performance for inter-turn short-circuits, and Wavelet packet decomposition reached optimal performance for bearing faults. The results validate the proposed approach and establish a foundation for future deployment in continuous industrial condition monitoring.

Keywords: predictive maintenance; fault detection; machine learning; feature extraction.

LISTA DE ILUSTRAÇÕES

Figura 1 - Vista em Corte de um Motor de Indução Tipo Gaiola de Esquilo.....	16
Figura 2 – Rotor Saudável e com Barras Perfuradas para Simular o Defeito de Barras Quebradas	18
Figura 3 – Barras Rotóricas	19
Figura 4 – Estrutura de um Rolamento	20
Figura 5 - Marcas nos Anéis Internos do Rolamento em Teste de Vida Útil.....	21
Figura 6 - Arvore de Decomposição <i>Wavelet</i> de Nível Três.....	26
Figura 7 – Decomposição em Pacotes de <i>Wavelet</i> de Nível Três	27
Figura 8 - Fluxograma Simplificado da Metodologia MCSA.....	30
Figura 9 – FFT da Corrente do Motor Alimentado pelo Inversor	31
Figura 10 – Fluxograma Simplificado da Metodologia.....	32
Figura 11 – Fluxograma Simplificado da Metodologia TOEO.....	32
Figura 12 - Amplitude Espectral da Corrente com a Aplicação do TOEO para o Motor com Três Barras Quebradas e Alimentado pela Rede Elétrica.....	33
Figura 13 – Fluxograma Simplificado da Metodologia MCSA.....	34
Figura 14 - Espectro da Corrente do Estator para o Motor a Vazio. +Fcc1 e – Fcc1 São as Frequências Características de Curto-Circuito.	34
Figura 15 – Fluxograma Simplificado da Metodologia de Razão dos Coeficientes de Decomposição <i>Wavelet</i>	35
Figura 16 - Razões Calculadas das Energias de <i>Wavelet</i> para Curto-Circuito Entre Espiras na Fase A, B e C nos Experimentos com o Motor	36
Figura 17 – Fluxograma Simplificado da Metodologia de Análise do Vetor de Park. ..	37
Figura 18 - Corrente de Park Plotado no Plano Complexo. A Severidade do Defeito é Dada por: Azul – 2 Espiras, Verde – 5 Espiras, Magenta – 10 Espiras, Vermelho – 14 Espiras	37
Figura 19 – Fluxograma Simplificado da Metodologia WPD	38
Figura 20 – Fluxograma Simplificado da Metodologia MCSA.....	39
Figura 21 – Fluxo de Dados em uma <i>Multi-layer Perceptron</i>	41
Figura 22 – Fluxo de Seleção	45
Figura 23 – Distribuição da Quantidade de Artigos por Tipos de Defeito.....	46
Figura 24 - Distribuição da Quantidade de Artigos por Métodos de Processamento....	47
Figura 25 - Disposição Geral da Bancada de Experimentos para Ensaios de Defeito de Barra Quebrada.....	51
Figura 26 - Disposição Geral da Bancada de Experimentos para Ensaios de Defeito de Rolamento	52

Figura 27 – Fluxo de Processamento para um Modelo Especialista.....	54
Figura 28 – Representação de Arquitetura da Rede Neural	57
Figura 29 – Espectro da Corrente do Estator do Motor com 4 Barras Quebradas e Torque Nominal.....	62
Figura 30 - Espectro da Corrente do Estator do Motor com 3 Barras Quebradas após Aplicação do TOEO	65
Figura 31 - Espectro da Corrente do Estator do Motor com 9,26% das Espiras em Curto-Circuito e 50% de Carregamento.....	67
Figura 32 – Elipses Formadas pela Corrente de Park nos Eixos d e q.....	68
Figura 33 – Aba de Dados e Extração	73
Figura 34 – Aba de Treinamento	74
Figura 35 – Aba de Teste	75
Figura 36 - Aba de Diagnóstico	76
Figura 37 - Acurácia Global por Especialista e Configuração de Atributos	78
Figura 38 (a) - Configuração A	80
Figura 39 – Matrizes de Confusão do Especialista em Barra Quebrada	81
Figura 40 – Matrizes de Confusão para os Atributos do Especialista em Curto-Circuito	84
Figura 41 – Razões de Energia entre Fases para Experimento Saudável da Bancada de Curto-circuito com Motor em Plena Carga	86
Figura 42 - Matrizes de Confusão para os Atributos do Especialista em Rolamento....	88
Quadro 1 - Palavras-Chave Usadas na String de Busca	44

LISTA DE TABELAS

Tabela 1 - Lista de Atributos Selecionados para o Sistema de Diagnóstico.....	56
Tabela 2 - Amplitude Média das Bandas Laterais de Barra Quebrada com MCSA.....	63
Tabela 3 – Amplitude Média das Bandas Laterais de Barra Quebrada com DWT + TKEO.....	64
Tabela 4 - Amplitude Média das Bandas Laterais de Barra Quebrada com TOEO.....	65
Tabela 5 - Amplitude Média das Bandas Laterais de Curto-Circuito com MCSA.....	67
Tabela 6 - Fatores de Excentricidade Médio Obtidos Analisando as Elipses Produzidas	69
Tabela 7- Razões Energéticas Médias Entre os Coeficientes da Decomposição <i>Wavelet</i>	69
Tabela 8 - Índices de Severidade Calculados para cada Severidade e Torque.....	71
Tabela 9 - Grupos de Atributos por Especialista em Cada Configuração Experimental	77
Tabela 10 - Acurácia Geral de Janelas Experimentais por Configuração e por Classe	78
Tabela 11 - Acurácia por Bloco dos Motores Saudáveis da Bancada de Barras Quebradas, por Condição de Torque	81
Tabela 12 - Acurácia por Bloco dos Motores com Barras Quebradas, por Condição de Torque	81
Tabela 13 - Acurácia por Bloco dos Motores com Curto-Circuito, por Condição de Carga	83
Tabela 14 - Acurácia por Bloco dos Motores Saudáveis da Bancada de Curto-Circuito, por Condição de Carga	84
Tabela 15 - Acurácia por Bloco do Especialista em Curto-Circuito, por Configuração e Severidade do Defeito	84
Tabela 16 - Acurácia por Bloco da Classe RL, por Tipo de Defeito e Severidade, com Saudáveis	87

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Objetivos	12
1.1.1	Objetivo Geral	12
1.1.2	Objetivos Específicos	12
1.2	Estrutura do Trabalho	13
2	REFERENCIAL TEÓRICO	15
2.1	Os Motores de Indução	15
2.2	Defeitos em Motores de Indução Trifásicos	17
2.2.1	Barras Rotóricas Quebradas	17
2.2.2	Defeitos em Rolamentos	20
2.2.3	Curto-circuito Entre Espiras do Estator	22
2.3	Técnicas de Processamento de Sinal	23
2.3.1	Transformada Rápida de Fourier	23
2.3.2	Transformada Discreta de <i>Wavelet</i>	24
<u>2.3.2.1</u>	<u>Níveis de Decomposição:</u>	<u>26</u>
<u>2.3.2.2</u>	<u>Decomposição em Pacotes de <i>Wavelet</i></u>	<u>26</u>
2.3.3	Operador de Energia de <i>Teager-Kaiser</i>	27
2.3.4	Operador de Energia de Terceira Ordem	28
2.4	Métodos de Diagnóstico	29
2.4.1	Barras Quebradas	30
<u>2.4.1.1</u>	<u>Amplitude Espectral da Corrente Via MCSA</u>	<u>30</u>
<u>2.4.1.2</u>	<u>Amplitude Espectral da Corrente Pós-TKEO e DWT</u>	<u>31</u>
<u>2.4.1.3</u>	<u>Amplitude Espectral Pós-TOEO</u>	<u>32</u>
2.4.2	Curto-circuito Entre Espiras do Estator	33
<u>2.4.2.1</u>	<u>Amplitude Espectral da Corrente Via MCSA</u>	<u>33</u>
<u>2.4.2.2</u>	<u>Razão de Energia <i>Wavelet</i> Discreta</u>	<u>35</u>
<u>2.4.2.3</u>	<u>Abordagem do Vetor de Park</u>	<u>36</u>
2.4.3	Defeitos em Rolamentos	37
<u>2.4.3.1</u>	<u><i>Wavelet Packet Decomposition</i> e Índices de Severidade</u>	<u>38</u>
<u>2.4.3.2</u>	<u>Amplitude Espectral via MCSA</u>	<u>38</u>
2.5	Redes Neurais Artificiais	39
3	REVISÃO SISTEMÁTICA DA LITERATURA	43
3.1	Definição da Pergunta de Pesquisa	43

3.2	Identificação dos Bancos de Dados	43
3.3	CrITÉrios de Seleção	43
3.4	<i>String</i> de Busca.....	44
3.5	SÍntese dos Resultados.....	46
3.6	Metanálise.....	47
<u>3.6.1.1</u>	<u>Barras Quebradas.....</u>	<u>48</u>
<u>3.6.1.2</u>	<u>Curto-circuito entre Espiras do Estator.....</u>	<u>48</u>
<u>3.6.1.3</u>	<u>Defeito de Rolamento</u>	<u>48</u>
<u>3.6.1.4</u>	<u>Contribuições da Revisão Sistemática da Literatura</u>	<u>49</u>
4	MATERIAIS E MÉTODOS	50
4.1	Banco de Dados de Barra Quebrada	50
4.2	Banco de Dados de Curto-circuito Entre Espiras do Estator.....	51
4.3	Banco de Dados de Defeito em Rolamento	52
4.4	Processamento de Dados de Corrente Elétrica Trifásica.....	53
4.5	Pré-Processamento	54
4.6	Extração de Atributos	55
4.7	Rede Neural Artificial	56
4.8	Estratégia de Treinamento.....	57
4.9	Desenvolvimento de <i>Software</i>	58
4.10	Método de Refinamento de Atributos.....	60
5	RESULTADOS E DISCUSSÕES.....	62
5.1	Resultados do Refinamento de Atributos	62
5.1.1	Detecção de Barras Quebradas	62
<u>5.1.1.1</u>	<u>MCSA.....</u>	<u>62</u>
<u>5.1.1.2</u>	<u>DWT + TKEO</u>	<u>63</u>
<u>5.1.1.3</u>	<u>TOEO.....</u>	<u>64</u>
5.1.2	Detecção de Curto-Circuito Entre Espiras do Estator	66
<u>5.1.2.1</u>	<u>MCSA.....</u>	<u>66</u>
<u>5.1.2.2</u>	<u>Análise do Vetor de Park (PVA)</u>	<u>68</u>
<u>5.1.2.3</u>	<u>Razão de Energia de <i>Wavelet</i></u>	<u>69</u>
5.1.3	Detecção de Defeitos em Rolamentos	70
<u>5.1.3.1</u>	<u>MCSA.....</u>	<u>70</u>
<u>5.1.3.2</u>	<u>WPD</u>	<u>71</u>
5.2	Resultados do Desenvolvimento do Sistema.....	72
5.2.1	<i>Software</i> Desenvolvido	72

5.2.2	Resultados Gerais dos Testes.....	76
5.2.3	Especialista em Barras Quebradas.....	80
5.2.4	Especialista em Curto-Circuito.....	83
5.2.5	Especialista em Defeitos em Rolamentos.....	87
6	CONCLUSÃO.....	90

1 INTRODUÇÃO

Os motores de indução trifásicos (MIT) constituem o principal elemento de conversão de energia elétrica em mecânica no setor industrial, sendo amplamente utilizados como força motriz em processos de manufatura, bombeamento, ventilação e movimentação de cargas (Khalique et al., 2021), representando cerca de 85% dos motores na indústria (Agah et al., 2022). Apesar de sua robustez e confiabilidade operacional, esses equipamentos estão sujeitos a diferentes tipos de falha decorrentes de esforços mecânicos, térmicos, elétricos e ambientais acumulados durante operação contínua, destacando-se a quebra de barras rotóricas, defeitos em rolamentos e o curto-circuito entre espiras do estator (Khalique et al., 2021; Li et al., 2021). Uma falha incipiente não detectada pode evoluir rapidamente, provocando paradas não programadas da linha de produção, cujos custos, incluindo perda de matéria-prima, danos colaterais e interrupção da cadeia produtiva superam significativamente o valor de reposição do próprio motor.

Diante desse cenário, o desenvolvimento de sistemas inteligentes capazes de detectar e diagnosticar defeitos em motores de indução em estágios iniciais, possibilitando intervenções de manutenção preditiva, torna-se essencial para garantir a continuidade operacional, reduzir custos de manutenção e maximizar a disponibilidade dos ativos produtivos no contexto da Indústria 4.0 (Kouadria et al., 2024).

O sistema proposto fundamenta-se na análise do sinal de corrente elétrica do estator, do qual são extraídos atributos estudados e selecionados a partir de metodologias reportadas na literatura científica. A seleção desses atributos orienta-se majoritariamente por critérios fisicamente interpretáveis, de modo que as características utilizadas como entrada do classificador possuam correlação direta com as manifestações eletromagnéticas de cada defeito. Foram escolhidos para estudo defeitos de barras rotóricas quebradas, defeitos em rolamentos e curto-circuito entre espiras do estator. O diagnóstico foi realizado por meio de redes neurais artificiais do tipo *Multi-Layer Perceptron* (MLP), treinadas para discriminar entre o estado saudável do motor e as diferentes classes de defeito. A arquitetura do sistema foi concebida para processar janelas temporais do sinal de corrente, visando sua aplicação em manutenção preditiva. Para reunir essas etapas em um ambiente unificado, foi desenvolvido um *software* que integra o processamento do sinal, a extração dos atributos, treinamento e diagnóstico dos MIT. A abordagem proposta diferencia-se de trabalhos que aplicam algoritmos de classificação diretamente sobre sinais brutos ou atributos totalmente estatísticos ao fundamentar a seleção de atributos em critérios fisicamente interpretáveis, buscando garantir que cada atributo utilizado

pelo classificador possua correspondência com fenômenos associados aos defeitos investigados. Essa estratégia confere ao sistema a capacidade de determinar a causalidade dos defeitos, trazendo luz à abordagem de sistemas cognitivos para diagnóstico das condições de máquinas elétricas, aliando-se aos preceitos da Indústria 4.0 e 5.0.

1.1 Objetivos

Esta seção apresenta o objetivo geral que norteia o desenvolvimento deste trabalho, seguido dos objetivos específicos definidos para alcançá-lo.

1.1.1 Objetivo Geral

Desenvolver um sistema inteligente baseado em conhecimento para diagnóstico de defeitos em motores de indução trifásicos.

1.1.2 Objetivos Específicos

Para alcance do objetivo geral foram delineados os seguintes objetivos específicos:

- 1) Investigar como os principais defeitos em motores de indução (barras quebradas, defeitos em rolamentos e curto-circuito nas espiras do estator) se manifestam no sinal de corrente do estator.
- 2) Revisar métodos matemáticos consolidados para extrair atributos dos sinais de corrente elétrica nos domínios do tempo, frequência e tempo-frequência.
- 3) Selecionar atributos, garantindo correlação entre efeito físico e a representação numérica correspondente.
- 4) Coletar bases de dados públicas contendo registros de corrente de motores saudáveis e com os defeitos estudados.
- 5) Desenvolver modelos de redes neurais artificiais utilizando os atributos selecionados como entrada.
- 6) Avaliar o desempenho dos modelos por métricas como acurácia, matriz de confusão, selecionando a configuração de melhor resultado.
- 7) Desenvolver uma aplicação que contemple desde o processo de extração de atributos até o diagnóstico de múltiplos defeitos em MIT.

1.2 Estrutura do Trabalho

O presente trabalho está organizado em 7 capítulos. O primeiro capítulo apresenta a introdução ao tema de diagnóstico de defeitos em motores de indução trifásicos, contextualizando o problema, definindo os objetivos geral e específicos a serem alcançados, bem como a justificativa para o desenvolvimento desta pesquisa.

O segundo capítulo aborda o referencial teórico necessário para o desenvolvimento do trabalho. Inicialmente, são apresentados os conceitos fundamentais dos motores de indução trifásicos e seu princípio de funcionamento. Em seguida, são descritos os principais defeitos que acometem essas máquinas, incluindo barras rotóricas quebradas, defeitos em rolamentos e curto-circuito entre espiras do estator, detalhando como cada defeito se manifesta no sinal de corrente do estator. O capítulo também contempla as técnicas de processamento de sinal empregadas, além dos métodos de diagnóstico baseados na análise da corrente elétrica e os fundamentos das redes neurais artificiais.

O terceiro capítulo é dedicado à revisão sistemática da literatura, apresentando o processo metodológico adotado para identificação, seleção e análise dos estudos relevantes sobre detecção de defeitos em motores de indução utilizando sinais de corrente elétrica e técnicas de aprendizado de máquina.

O quarto capítulo descreve os materiais e métodos utilizados na pesquisa. São apresentados os bancos de dados empregados, o fluxo de dados de processamento dos sinais de corrente elétrica trifásica, contemplando as etapas de pré-processamento, extração e seleção de atributos, a arquitetura das redes neurais artificiais, a estratégia de treinamento adotada, a lógica de diagnóstico implementada além dos princípios do desenvolvimento do sistema e a etapa de refinamento de atributos.

O quinto capítulo apresenta os resultados obtidos a partir da aplicação da metodologia. Inicialmente, são expostos os resultados do refinamento de atributos para os três tipos de defeitos investigados, barras rotóricas quebradas, curto-circuito entre espiras do estator e defeitos em rolamentos, a partir dos bancos de dados selecionados, comparando as diferentes técnicas de processamento de sinal aplicadas em cada contexto e evidenciando suas limitações e complementaridades. Em seguida, descreve-se a versão final do *software* desenvolvido, organizado em quatro abas que contemplam a extração de atributos, o treinamento das redes neurais, o teste em massa e a simulação de diagnóstico em tempo real, sendo então apresentados os resultados e a análise de desempenho dos modelos de rede neural.

O sexto capítulo apresenta as conclusões do trabalho, retomando os principais resultados obtidos e avaliando o cumprimento dos objetivos propostos. São sintetizadas as contribuições da abordagem baseada em atributos fisicamente interpretáveis combinados com classificadores especialistas, bem como as limitações identificadas ao longo do desenvolvimento. Por fim, são apresentadas sugestões de trabalhos futuros, voltadas à ampliação dos bancos de dados, à validação dos atributos em ambiente industrial e à investigação de atributos complementares para as condições de menor desempenho.

2 REFERENCIAL TEÓRICO

As máquinas elétricas rotativas constituem o meio fundamental de conversão eletromecânica de energia, transformando energia elétrica em mecânica ou vice-versa através da interação entre campos magnéticos e correntes elétricas (Fitzgerald; Kingsley; Umans, 2003). Dentre as diversas topologias existentes, o motor de indução trifásico com rotor de gaiola de esquilo consolidou-se como o equipamento predominante em ambientes industriais, em razão de sua robustez construtiva, sujeitos a menos tipos de desgaste mecânico, e custo de fabricação relativamente baixo (Fitzgerald; Kingsley; Umans, 2003). A compreensão dos princípios físicos que regem o funcionamento dessas máquinas é essencial para o desenvolvimento de técnicas de diagnóstico, uma vez que os defeitos se manifestam como perturbações nos fenômenos eletromagnéticos que governam a operação normal do motor.

A complexidade inerente à detecção de defeitos reside na necessidade de identificar alterações sutis em sinais elétricos, distinguindo assinaturas de defeitos de perturbações operacionais normais e adaptando-se a condições diversas. Este capítulo estabelece os fundamentos teóricos para o desenvolvimento de um sistema de diagnóstico baseado na análise da corrente elétrica do estator de motores de indução trifásico. Inicialmente, apresentam-se os princípios operacionais, em seguida, caracterizam-se os principais defeitos que acometem estes equipamentos detalhando suas origens físicas, mecanismos de propagação e manifestações no sinal de corrente do estator do motor.


A extração de informações a partir dos sinais de corrente elétrica adquiridos requer técnicas apropriadas de processamento, através da análise de métodos no domínio do tempo, frequência e tempo-frequência. A partir das técnicas de processamento é possível extrair os atributos discriminativos dos defeitos. Por fim, introduzem-se os conceitos fundamentais de redes neurais artificiais, justificando sua aplicação como classificadores capazes de mapear os atributos extraídos às respectivas classes de defeito.

2.1 Os Motores de Indução

O motor de indução é um dos tipos mais difundidos de máquina elétrica rotativa, representando a maior parcela dos acionamentos industriais devido à sua robustez, confiabilidade e custo relativamente baixo (Fitzgerald; Kingsley; Umans, 2003). Diferente das máquinas síncronas, nas quais o fluxo do rotor é gerado diretamente por corrente contínua, por meio de escovas ou por ímãs permanentes, no motor de indução, o fluxo e as correntes do rotor são induzidos a partir do campo girante produzido pelos enrolamentos estatóricos.

No estator do motor de indução, são alojados enrolamentos trifásicos distribuídos espacialmente de forma a produzir, quando alimentados por correntes alternadas defasadas no tempo, um campo magnético girante. Esse campo rotaciona com velocidade síncrona, determinada pela frequência da rede de alimentação e pelo número de polos da máquina. O rotor, em motores de gaiola de esquilo, é constituído por barras condutoras sólidas, dispostas em ranhuras ao longo do núcleo cilíndrico e curto-circuitadas nas extremidades por anéis condutores. A Figura 1 ilustra um motor de indução do tipo gaiola de esquilo.

Figura 1 - Vista em Corte de um Motor de Indução Tipo Gaiola de Esquilo.



Fonte: (Stephen J. Chapman, 2013).

Essa configuração dispensa aplicação de uma tensão externa ao rotor, uma vez que as correntes rotóricas são inteiramente induzidas a partir do campo estatórico. Em motores de maior porte ou aplicações específicas, podem ser empregados rotores bobinados com anéis coletores, permitindo o acesso externo aos enrolamentos rotóricos, todavia, a configuração em gaiola é predominante em aplicações industriais convencionais devido à simplicidade construtiva, ao baixo custo de fabricação e à elevada confiabilidade, decorrente da ausência de componentes sujeitos a desgaste mecânico, como escovas e anéis coletores.

Segundo Stephen J. Chapman, 2013, o princípio de operação fundamenta-se na interação entre o campo magnético girante do estator e as correntes induzidas no rotor. Quando o rotor gira a uma velocidade inferior à velocidade síncrona do campo estatórico, condição denominada escorregamento, as barras rotóricas são atravessadas por um fluxo magnético variável no tempo, induzindo forças eletromotrizes e, conseqüentemente, correntes. O campo magnético produzido por essas correntes rotóricas, por sua vez, interagem com o campo girante estatórico, produzindo o conjugado eletromagnético responsável pela conversão de energia elétrica em energia mecânica. O motor de indução opera, portanto, em regime assíncrono, sendo

o escorregamento o parâmetro que governa a magnitude das correntes rotóricas e, por consequência, o torque desenvolvido. Durante a partida, o conjugado pode atingir valores elevados, a corrente de partida é significativamente superior à corrente nominal, impondo desafios aos sistemas de proteção e à rede elétrica.

2.2 Defeitos em Motores de Indução Trifásicos

Os motores de indução trifásicos, devido ao uso contínuo e intensivo em ambientes industriais, estão sujeitos a diversos tipos de falhas. Uma falha incipiente, se não detectada precocemente, pode evoluir e causar a parada não planejada de uma linha de produção (Khalique et al., 2021; Maciejewski; Tremł; Flauzino, 2020).

As falhas podem ser classificadas de acordo com sua origem em três categorias principais: falhas mecânicas, falhas elétricas e falhas relacionadas ao ambiente operacional (Khalique et al., 2021). As falhas mecânicas abrangem problemas em componentes rotativos e estruturais, como desgaste de rolamentos, desalinhamento de eixos, desbalanceamento do rotor. As falhas elétricas envolvem deterioração do isolamento, curtos-circuitos entre espiras e problemas nas conexões dos enrolamentos do estator. Já as falhas relacionadas ao ambiente operacional incluem exposição a condições adversas de temperatura, umidade, vibração excessiva e contaminação por agentes químicos ou particulados.

Entre os diversos tipos de defeitos que podem acometer esses equipamentos, três são considerados hegemônicos e demandam maior atenção: defeitos em rolamentos, curto-circuito entre espiras do estator e problemas relacionados à quebra de barras rotóricas (Khalique et al., 2021). Cada um desses defeitos manifesta características físicas distintas que se traduzem em assinaturas específicas no sinal de corrente do estator. A compreensão dessas assinaturas constitui a base para o desenvolvimento de técnicas de diagnóstico eficazes baseadas na análise da corrente elétrica.

Neste trabalho, são abordados especificamente três tipos de defeitos em motores de indução trifásicos e cuja detecção por análise da corrente do estator apresenta maior viabilidade técnica. Estes defeitos são detalhados nas subseções seguintes.

2.2.1 Barras Rotóricas Quebradas

A quebra de barras rotóricas em motores de indução trifásicos de gaiola de esquilo correspondem a aproximadamente 8% a 9% do total de falhas registradas (Ali; Liang, 2020). Este tipo de defeito pode ter origem devido a diversos fatores que atuam isoladamente ou de

forma combinada. Entre as principais causas estão os esforços térmicos resultantes de sobrecargas ou pontos quentes localizados, fadiga mecânica decorrente de ciclos repetidos de partida e parada, especialmente em motores de grande porte, e vibrações excessivas. Também contribuem correntes de curto-circuito durante transitórios, defeitos de fabricação e corrosão do material das barras (Drobnic et al., 2025; Hajnayeb et al., 2024). Uma característica deste defeito é que a quebra de uma única barra raramente provoca a parada imediata do motor, permitindo que a máquina continue operando. Contudo, se não detectado precocemente, o defeito se propaga devido ao aumento de corrente nas barras adjacentes, acelerando a deterioração e podendo culminar em falhas no enrolamento estatórico (Drobnic et al., 2025; Hajnayeb et al., 2024). A Figura 2 representa rotores perfurados para simular barras quebradas rotóricas (BRB).


Figura 2 – Rotor Saudável e com Barras Perfuradas para Simular o Defeito de Barras Quebradas



Fonte: (Hajnayeb et al., 2024).

Para compreender como este defeito se manifesta no sinal de corrente elétrica, é fundamental analisar o que ocorre fisicamente no interior do motor. Em condições normais de operação, a gaiola de esquilo possui todas as suas barras íntegras, conforme a Figura 3, e a distribuição de corrente entre elas é essencialmente simétrica. Esta simetria resulta em um campo magnético rotórico uniforme que interage harmoniosamente com o campo magnético produzido pelo estator, gerando torque de forma regular e previsível (Hajnayeb et al., 2024). Quando uma ou mais barras se rompem, uma irregularidade é criada. A interrupção do caminho condutor obriga a corrente elétrica induzida no rotor a redistribuir-se pelas barras adjacentes ainda íntegras, criando uma assimetria no campo magnético rotórico (Hajnayeb et al., 2024; Puche-Panadero et al., 2020). Esta assimetria não é estática, mas acompanha a velocidade do rotor, passando periodicamente pelas mesmas posições em relação ao estator a cada rotação completa. Conseqüentemente, o campo magnético resultante deixa de ser constante no referencial do estator, apresentando flutuações periódicas que dependem da velocidade de rotação do rotor (Drobnic et al., 2025; Hajnayeb et al., 2024; Puche-Panadero et al., 2020).

Figura 3 – Barras Rotóricas



Fonte: Adaptado de (“Motor Elétrico de Indução (Gaiola de Esquilo) - saVRee”, 2020).

Estas flutuações magnéticas induzem perturbações no enrolamento estatórico, manifestando-se como variações na corrente elétrica de alimentação do motor de indução. Do ponto de vista prático, o sinal de corrente que em um motor saudável seria puramente senoidal, passa a apresentar componentes adicionais que oscilam em frequências específicas relacionadas ao escorregamento do motor (Drobnic et al., 2025; Hajnayeb et al., 2024; Puche-Panadero et al., 2020).


Além disso, o nível de carregamento mecânico aplicado ao motor exerce influência significativa na detectabilidade do defeito (Agah et al., 2022; Drobnic et al., 2025; Puche-Panadero et al., 2021). Em condições de operação com carga elevada, o escorregamento do motor aumenta, tornando as perturbações causadas pela assimetria rotórica mais evidentes e facilitando sua identificação. Por outro lado, em regimes de baixa carga ou em vazio, onde o escorregamento é reduzido, as alterações no sinal de corrente se tornam sutis e a detecção se torna mais complexa (Drobnic et al., 2025).

Adicionalmente, é preciso considerar que outros fenômenos operacionais podem gerar assinaturas elétricas similares às produzidas por barras quebradas, dificultando o diagnóstico. Oscilações na carga mecânica, comuns em sistemas acoplados a caixas redutoras, compressores ou bombas, podem introduzir variações periódicas na corrente do estator que, em determinadas condições, sobrepõem-se ou confundem-se com as assinaturas características de barras quebradas. Esta sobreposição de efeitos reforça a importância de técnicas de processamento de sinal que permitam separar adequadamente as contribuições de cada fenômeno, garantindo diagnósticos confiáveis mesmo em ambientes industriais complexos (Li et al., 2021).

2.2.2 Defeitos em Rolamentos

Os rolamentos são componentes críticos dos motores de indução trifásicos e constituem a principal fonte de falha no sistema mecânico. Os defeitos nesses componentes respondem por mais de 40% das falhas em motores elétricos de indução (Ali et al., 2020). A degradação dos rolamentos, quando não detectada precocemente, pode evoluir de defeitos localizados até falhas de maiores dimensões, comprometendo a integridade do motor e gerando custos elevados de manutenção corretiva (Kouadria et al., 2024; Nasiri et al., 2025). No contexto de diagnóstico baseado na análise da corrente do estator, *Motor Current Signal Analysis* (MCSA), a detecção de defeitos em rolamentos aproveita o acoplamento eletromecânico existente no motor, vibrações mecânicas geradas por imperfeições nos componentes do rolamento modulam o entreferro entre estator e rotor, alterando a permeância magnética e, conseqüentemente, introduzindo componentes característicos no espectro de corrente (Ali et al., 2020; Toma et al., 2022). Essa manifestação permite a identificação de defeitos através de técnicas não invasivas e de baixo custo, justificando sua importância em sistemas de diagnóstico multi-classe para manutenção preditiva. A Figura 4 ilustra a estrutura e principais partes de um rolamento.

Figura 4 – Estrutura de um Rolamento




Fonte: (FIRMINO, 2020).

A degradação de rolamentos em motores de indução ocorre predominantemente através de mecanismos físicos inter-relacionados. A fadiga por contato superficial constitui o mecanismo mais comum, resultante de cargas cíclicas repetidas aplicadas às superfícies das pistas e dos elementos rolantes. Cada ciclo de operação submete o material a tensões de contato elevadas, gerando microtrincas subsuperficiais que se propagam gradualmente até provocar o destacamento de fragmentos de material, fenômeno conhecido como *spalling* quando ocorre

em placas maiores ou *pitting* quando resulta em cavidades menores (Ali et al., 2020; Nasiri et al., 2025). Defeitos originados por fadiga caracterizam-se por serem localizados espacialmente, gerando impactos mecânicos periódicos toda vez que um elemento rolante passa sobre a região danificada (Toma et al., 2022).

O desgaste abrasivo e a contaminação representam outro modo de falha significativo. A presença de partículas sólidas externas, fragmentos metálicos gerados internamente ou a degradação do lubrificante removem material das superfícies de contato de forma contínua e distribuída, alterando progressivamente a geometria do rolamento e aumentando as folgas internas (Ali et al., 2020; Nasiri et al., 2025). Diferentemente da fadiga, o desgaste tende a produzir defeitos distribuídos ao longo de toda a superfície, como pode ser visto na Figura 5, resultando em vibrações de caráter menos impulsivo e mais semelhantes a um ruído distribuído em ampla faixa de frequências. Além disso, em motores alimentados por inversores de frequência, as altas frequências de chaveamento podem refletir vibrações indesejadas nos rolamentos, acelerando a deterioração das pistas (Sameh; Tarek; Yassine, 2020). A Figura 5 representa os defeitos que surgiram na banda de rolagem devido ao uso contínuo em teste de vida útil.



Fonte: Adaptado de (Lessmeier et al., 2016).

A progressão temporal dos defeitos em rolamentos segue tipicamente uma trajetória previsível, inicia-se em estágio incipiente com alterações microestruturais imperceptíveis, evolui para defeitos localizados detectáveis, avança para degradação distribuída e pode culminar em falha severa caso não seja interrompida por manutenção (Ali et al., 2020; Kouadria et al., 2024; Toma et al., 2022). Essa evolução gradual, característica dos defeitos mecânicos em rolamentos, oferece uma janela de oportunidade para diagnóstico precoce e intervenção planejada, contrastando com falhas elétricas que podem ocorrer de forma mais abrupta. A distinção entre defeitos localizados (geradores de impactos repetitivos) e distribuídos

(geradores de elevação contínua de vibração) é fundamental para a seleção de atributos de diagnóstico, pois diferentes estágios e tipos de degradação manifestam-se de formas distintas tanto no domínio do tempo quanto no domínio da frequência.

2.2.3 Curto-circuito Entre Espiras do Estator

O curto-circuito entre espiras do estator constitui uma das falhas mais frequentes em motores de indução trifásicos, representando entre 21% e 40% dos casos de defeitos registrados (Almounajjed; Sahoo; Kumar, 2021). Essa falha caracteriza-se pelo contato elétrico entre uma certa quantidade de espiras do enrolamento estatórico, resultando em aumento da corrente circulante e causando danos às bobinas do motor (Almounajjed; Sahoo; Kumar, 2021). No contexto de diagnóstico baseado em MCSA, a identificação desse defeito explora as perturbações características introduzidas no campo magnético do entreferro, que se manifestam como componentes espectrais de frequência no espectro da corrente do estator.

A origem do curto-circuito entre espiras está na degradação de isolamento dos enrolamentos do estator, processo provocado por diversos tipos de estresse atuando sobre o motor. O estresse térmico, o estresse mecânico, o estresse elétrico e a exposição a condições ambientais adversas contribuem de forma combinada para a degradação progressiva das propriedades isolantes dos materiais que separam as espiras adjacentes. A exposição contínua a essas condições de estresse compromete a integridade do isolamento até o ponto em que ocorre a ruptura dielétrica, estabelecendo um caminho condutor de baixa impedância entre espiras que deveriam permanecer eletricamente isoladas (Almounajjed; Sahoo; Kumar, 2021). Quando o curto-circuito entre espiras se estabelece, a corrente que circula pela região em curto desequilibra as correntes trifásicas do motor (Parra et al., 2013). Esse desequilíbrio perturba o campo magnético no entreferro e introduz componentes de frequência características no espectro da corrente do estator (Almounajjed; Sahoo; Kumar, 2021). A amplitude e a presença dessas componentes espectrais características constituem a base para a detecção desse tipo de defeito através da análise da corrente elétrica.

Diversos métodos têm sido propostos na literatura para a detecção de curtos entre espiras em motores de indução. Muitos desses métodos baseiam-se em modelos matemáticos ou metodologias lineares que assumem conhecimento preciso dos parâmetros do motor e condições operacionais controladas. Entretanto, em ambientes industriais reais, os motores são difíceis de modelar com precisão e estão expostos a níveis elevados de ruído elétrico e interferências, como desbalanceamento de tensão da rede de alimentação (Almounajjed; Sahoo; Kumar, 2021).

Nesse contexto, técnicas de inteligência artificial surgem como uma alternativa promissora, oferecendo a capacidade de contornar ruídos e interferências. Abordagens baseadas em aprendizado de máquina podem extrair padrões discriminativos diretamente dos sinais de corrente, adaptando-se às condições operacionais variáveis e à presença de perturbações, aspectos que tornam essas técnicas particularmente adequadas para aplicações práticas de diagnóstico em ambientes industriais.

2.3 Técnicas de Processamento de Sinal

A análise da corrente do estator para diagnóstico de defeitos em motores de indução requer técnicas de processamento de sinal capazes de extrair informações relevantes sobre o estado operacional da máquina. As técnicas tradicionais, como MCSA, que é baseada em transformada de Fourier apresentam componentes de defeito próximos à frequência fundamental de alimentação em casos em que a carga mecânica no eixo do motor é baixa (Wang et al., 2022). Neste contexto, operadores de energia de ordem superior e técnicas de decomposição tempo-frequência têm surgido como uma alternativa para esses casos.

2.3.1 Transformada Rápida de Fourier

A análise espectral de sinais constitui ferramenta essencial para o diagnóstico de defeitos em motores de indução, pois permite identificar componentes harmônicas características de diferentes defeitos (Jung; Lee; Kwon, 2006). A transformada discreta de Fourier (DFT) converte um sinal discreto no domínio do tempo para o domínio da frequência, sendo definida por (Brigham; Morrow, 1967; Jung; Lee; Kwon, 2006):

$$S(n) = \Delta t \sum_{k=0}^{N-1} x(k) e^{-j2\pi nk/N}, \quad n = 0, 1, \dots, N-1, \quad (1)$$

onde $x(k)$ representa as amostras do sinal no domínio do tempo, N é o número de amostras, Δt é o intervalo de amostragem e $S(n)$ são os componentes espectrais. A transformada inversa é dada por (Brigham; Morrow, 1967):

$$x(k) = \Delta f \sum_{n=0}^{N-1} S(n) e^{j2\pi nk/N}, \quad k = 0, 1, \dots, N-1, \quad (2)$$

a implementação direta da DFT requer N^2 multiplicações e adições complexas, resultando em elevado custo computacional. O algoritmo da transformada rápida de Fourier (FFT),

desenvolvido por Cooley e Tukey, reduz a complexidade computacional para $N \log_2 N$ operações, onde $N = 2^\gamma$ e γ é um número inteiro (Brigham; Morrow, 1967). A relação entre o tempo de computação da FFT e do método discreto tradicional é aproximadamente:

$$\frac{N \log_2 N}{N^2} = \frac{\log_2 N}{N} = \frac{\gamma}{N}. \quad (3)$$

Para $N = 2^{10} = 1024$ pontos, a FFT requer menos de 1% do tempo computacional do método discreto tradicional (Brigham; Morrow, 1967).

2.3.2 Transformada Discreta de *Wavelet*

A Transformada Discreta de *Wavelet* (DWT) constitui uma ferramenta de processamento de sinais que se estabeleceu em diversas aplicações como método confiável para tratamento de sinais estacionários e não-estacionários. Este método possibilita interpretação de sinais tanto no domínio do tempo quanto no domínio da frequência simultaneamente. Comparada à Transformada *Wavelet* Contínua, a DWT revela informações igualmente significativas do sinal, porém com tempos computacionais substancialmente menores, tornando-se adequada para aplicações que demandam processamento de sinais com eficiência e velocidade de processamento, como sistemas de diagnóstico em tempo real (Cherif et al., 2020).

A DWT é realizada através de uma série de filtros passa-altas para analisar as altas frequências e uma série de filtros passa-baixas para analisar as baixas frequências dos sinais. Desta forma, o sinal é decomposto em sua versão detalhada (componentes de alta frequência) e versão aproximada (componentes de baixa frequência). Essa decomposição possui fundamentação matemática na teoria das *Wavelets*. Se a função $\psi(t)$ pertence ao espaço $L^2(\mathbb{R})$, espaço de funções de quadrado integrável, e satisfaz a condição de admissibilidade (Zhang et al., 2015), então:

$$\int \frac{|\Psi(\omega)|^2}{\omega} d\omega < \infty, \quad (4)$$

onde $\Psi(\omega)$ é a transformada de Fourier de ψ e $\psi(t)$ é denominada função *Wavelet* mãe. A função *Wavelet* $\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi_{a,b}\left(\frac{t-b}{a}\right)$ é derivada da função *Wavelet* mãe com escala a e translação b .

A transformada de *Wavelet* do sinal $f(t)$ é definida como o produto interno entre o sinal e a função *Wavelet* (Zhang et al., 2015),

$$f(a, b) = \langle f, \psi_{a,b} \rangle = \int f(t) \frac{1}{\sqrt{a}} \psi^* \left(\frac{t-b}{a} \right) dt, \quad (5)$$

onde $\psi^* \left(\frac{t-b}{a} \right)$ representa o conjugado de $\psi \left(\frac{t-b}{a} \right)$.

Na transformada *Wavelet* contínua, a *Wavelet* mãe é escalonada e deslocada continuamente. Entretanto, na DWT, a *Wavelet* mãe não é escalonada continuamente, mas sim em potências de 2^{-j} , onde j é um inteiro positivo. Esta característica torna a DWT de fácil implementação em sistemas computacionais, reduzindo significativamente o tempo de execução (Zhang et al., 2015).

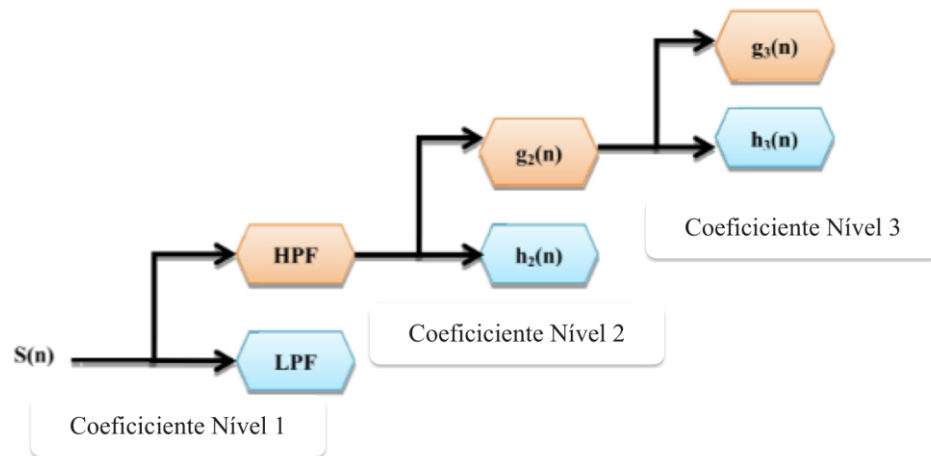
Seja $f(t)$ um sinal discreto no tempo a ser decomposto em suas versões aproximada e detalhada utilizando a análise de *Wavelet* discreta. Os coeficientes de decomposição do primeiro nível são A_j e D_j , onde A_j representa a versão aproximada de $f(t)$ e D_j representa a versão detalhada de $f(t)$. Estes coeficientes são definidos por (Bouzida et al., 2011) :

$$A_j(k) = \sum_k^\infty h(k - 2n)A_{j-1} \quad n = 1, 2, 3, \dots, \quad (6)$$

$$e D_j(k) = \sum_k^\infty g(k - 2n)A_{j-1} \quad n = 1, 2, 3, \dots, \quad (7)$$

onde h e g são os filtros de decomposição de $f(n)$ e $A_0(k)$ é por próprio sinal. A Figura 6 ilustra uma decomposição *Wavelet* de três níveis, onde HPF (*High Pass Filter*) e LPF (*Low Pass Filter*) são os filtros passa- alta e passa-baixa respectivamente.

Figura 6 - Arvore de Decomposição *Wavelet* de Nível Três



Fonte: Adaptado de (Cherif et al., 2020).

Em cada nível, o sinal é separado em coeficientes de aproximação e de detalhe, sendo o coeficiente de aproximação subsequentemente decomposto no próximo nível. Este processo iterativo permite a análise multi-resolução do sinal, onde cada nível fornece informações sobre diferentes bandas de frequência (Bouzida et al., 2011). A escolha adequada do número de níveis de decomposição é fundamental para isolar as componentes de frequência associadas a cada tipo de defeito e é explicado com detalhes na próxima subseção.

2.3.2.1 Níveis de Decomposição:

O nível de decomposição é determinado pelas componentes de baixa frequência de interesse no diagnóstico. Para extração das componentes de frequência causadas por curto-circuito entre espiras, por exemplo, os coeficientes de aproximação utilizados para construir o critério diagnóstico devem conter não apenas as frequências de defeito, mas também o mínimo possível de frequências não relacionadas ao defeito (Zhang et al., 2015).

A ordem do nível de decomposição N_f é dada por:

$$N_f = \frac{\log\left(\frac{f_s}{f_1}\right)}{\log(2)}, \quad (8)$$

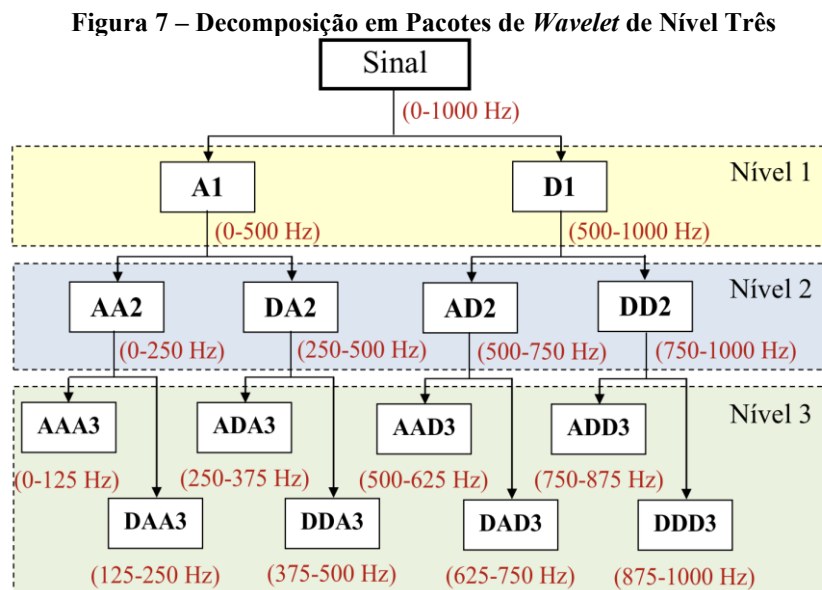
onde f_s representa a frequência de amostragem do sinal e f_1 a frequência fundamental.

2.3.2.2 Decomposição em Pacotes de *Wavelet*

Uma extensão da DWT é a decomposição em pacotes de *Wavelet* (WPD, do inglês *Wavelet Packet Decomposition*). Enquanto na DWT apenas os coeficientes de aproximação são

decompostos recursivamente a cada nível, a WPD decompõe tanto os coeficientes de aproximação quanto os de detalhe, resultando em uma árvore de decomposição completa com 2^n segmentos no nível n , conforme indicado na Figura 7. O intervalo de frequência de cada segmento é determinado por (Nasiri et al., 2025) :

$$[N, N + 1) \frac{f_{sp}}{2^{n+1}}, \quad (9)$$



2.3.3 Operador de Energia de *Teager-Kaiser*

O operador de energia de *Teager-Kaiser*, TKEO (*Teager Kaiser Energy Operator*), constitui uma ferramenta fundamental para análise diferencial de energia em sinais modulados. O TKEO tem sido extensivamente aplicado em diagnóstico de defeitos em máquinas rotativas, conforme demonstrado em trabalhos sobre detecção de barras quebradas (Agah et al., 2022).

Para um sinal contínuo no tempo $x(t)$, o TKEO é definido através do colchete de Lie (Maragos; Potamianos, 1995):

$$\psi(x(t)) = (x(t))'{}^2 - x(t)x(t)'', \quad (10)$$

onde $x(t)'$ e $x(t)''$ representam, respectivamente, a primeira e segunda derivadas temporais de $x(t)$. O colchete de Lie, $[x, y] = \dot{x}y - x\dot{y}$, mede diferenças instantâneas na taxa relativa de

variação entre dois sinais, e quando $y = \dot{x}$, resulta no operador de energia de *Teager-Kaiser* (Maragos; Potamianos, 1995).

A forma discreta do TKEO, pode ser obtida substituindo $x(t)$ pela sua forma discreta, com n sendo o número de amostras e f a frequência de amostragem:

$$x[n] = x(n\Delta t) \quad n = 0, 1, 2, \dots, \quad (11)$$

$$\Delta t = \frac{1}{f}. \quad (12)$$

Aproximando a derivada $\dot{x}(t)$ por sua versão discreta, obtém-se:

$$\dot{x}(t) = \frac{x[n] - x[n-1]}{\Delta t}. \quad (13)$$

A definição discreta do TKEO, obtida pela aproximação das derivadas por diferenças retroativas, pode ser definida como (Maragos; Potamianos, 1995).

$$\psi[x[n]] = x[n]^2 - x[n-1]x[n+1], \quad (14)$$

esta formulação discreta apresenta vantagens computacionais, requerendo apenas três amostras consecutivas e duas multiplicações, o que a torna adequada para implementação em sistemas de diagnóstico (Agah et al., 2022).

No contexto de diagnóstico de defeitos em motores de indução, o TKEO opera removendo a componente fundamental da corrente do estator e destacando as componentes características de defeito (Agah et al., 2022). Esta característica é especialmente vantajosa em condições de baixo escorregamento, onde os componentes laterais estão muito próximos da frequência fundamental.

2.3.4 Operador de Energia de Terceira Ordem

O operador de energia de terceira ordem TOEO (*Third Order Energy Operator*) representa uma extensão do conceito de operadores de energia diferencial para ordens superiores. Maragos e Potamianos, em "Higher Order Differential Energy Operators", definem os operadores de energia diferencial de ordem k genericamente como:

$$Y_k(x) = [x, x^{(k-1)}] = \dot{x}x^{(k-1)} - xx^{(k)}, k = 0, \pm 1, \pm 2, \dots, \quad (15)$$

onde $[\cdot, \cdot]$ denota o colchete de Lie, e $x^{(k)}$ representa a k -ésima derivada de $x(t)$ para k positivo ou a integral para k negativo. O TOEO corresponde ao caso particular $k = 3$ (Maragos; Potamianos, 1995; Wang et al., 2022).

Enquanto o TKEO ($k = 2$) mede a energia instantânea, o TOEO ($k = 3$) atua como um operador de velocidade de energia (Maragos; Potamianos, 1995). Operadores de ordem superior apresentam maior capacidade de destacar componentes energéticos e de impacto no sinal. Entretanto, o aumento da ordem implica em maior complexidade computacional. O TOEO representa um compromisso adequado entre acurácia e eficiência computacional para aplicações de diagnóstico de defeitos (Wang et al., 2022).

A discretização do TOEO pode ser realizada substituindo as derivadas por diferenças finitas, de forma análoga a discretização do TKEO:

$$Y_3(x[n]) = x[n]x[n+1] - x[n-1]x[n+2], k = 0, \pm 1, \pm 2, \dots, \quad (16)$$

esta formulação requer apenas quatro amostras consecutivas e duas multiplicações. Além disso, o TOEO apresenta melhor desempenho em motores alimentados por inversores, onde a presença de harmônicos de chaveamento compromete a eficácia do TKEO. A aplicação do TOEO à corrente elétrica permite superar os efeitos de vazamento espectral da frequência fundamental através de uma abordagem mais robusta (Wang et al., 2022).

2.4 Métodos de Diagnóstico

As técnicas de processamento de sinal apresentadas na seção anterior constituem ferramentas matemáticas que, aplicadas ao sinal de corrente do estator, permitem a extração de informações diagnósticas sobre o estado do motor. A seleção adequada do método de diagnóstico requer, portanto, o conhecimento das manifestações específicas de cada defeito e das limitações de cada abordagem de processamento. Esta seção apresenta os atributos específicos para os defeitos que são abordados nesse trabalho, detalhando como as técnicas de processamento são aplicadas para extração de atributos.

2.4.1 Barras Quebradas

A presença de barras quebradas induz componentes de frequência características no espectro da corrente do estator (Agah et al., 2022; Hajnayeb et al., 2024). Esta seção apresenta atributos diagnósticos extraídos por diferentes técnicas de processamento de sinal para detecção de barras rotóricas quebradas.

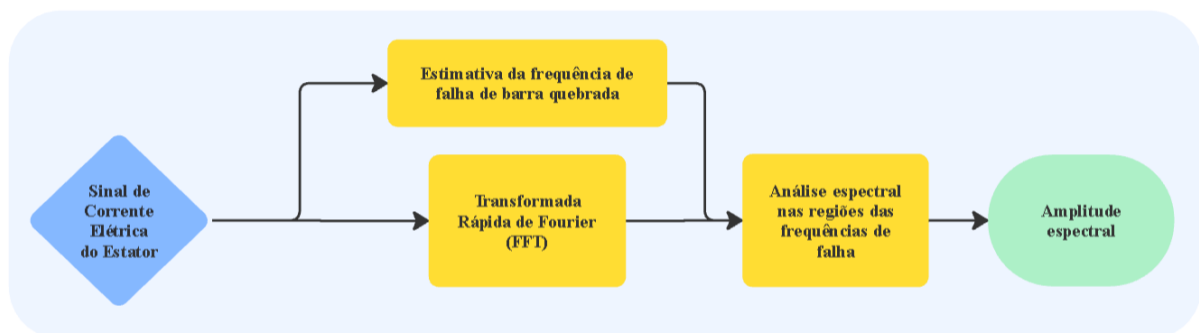
2.4.1.1 Amplitude Espectral da Corrente Via MCSA

A MCSA tradicional baseia-se na análise espectral da corrente do estator via FFT, identificando harmônicas características de diferentes tipos de defeito (Jung; Lee; Kwon, 2006). As componentes de bandas laterais características para defeito de barras rotóricas quebradas aparecem nas frequências:

$$f_{brb} = f_s(1 \pm 2ks), \quad k = 1, 2, 3, \dots, \quad (17)$$

onde f_s é a frequência de alimentação, s o escorregamento e k um número inteiro. O método utiliza os espectros de corrente do motor, cujas componentes harmônicas características de defeito são funções da distribuição da força magnetomotriz (FMM) e da representação das ondas de permeância do entreferro. (Jung; Lee; Kwon, 2006). O atributo diagnóstico consiste na amplitude espectral destas bandas laterais, tipicamente expressa em dB. A Figura 8 representa o fluxograma simplificado do método.

Figura 8 - Fluxograma Simplificado da Metodologia MCSA



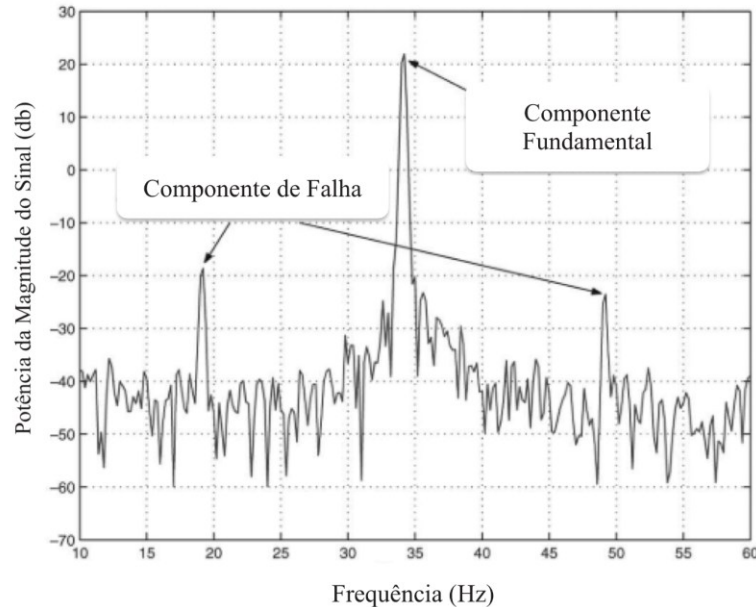
Fonte: Autoria Própria – Elaborado no Miro¹.

Jung, Lee e Kwon, (2006) conduziram experimentos com motores de 3,7 kW (acionados por inversor PWM a 30 Hz com controle vetorial) e 30 kW (alimentação direta da rede 440 V a 60 Hz) para validação do método. Os espectros de frequência demonstraram a

¹ <https://miro.com>

presença de componentes laterais simétricas em motores com barras quebradas como na Figura 9, contrastando com o espectro de motor saudável.

Figura 9 – FFT da Corrente do Motor Alimentado pelo Inversor




Fonte: Adaptado de (Jung; Lee; Kwon, 2006).

Sob condições de baixa carga ou operação a vazio, o escorregamento reduzido provoca aproximação entre as bandas laterais e a fundamental, com as componentes de defeito ficando menos evidentes devido vazamento espectral da componente fundamental (Wang et al., 2022). Esta limitação motivou o desenvolvimento de técnicas baseadas em operadores energéticos, que removem a componente fundamental da análise ao deslocar as frequências de interesse para uma faixa espectral distinta (Agah et al., 2022; Hajnayeb et al., 2024).

2.4.1.2 Amplitude Espectral da Corrente Pós-TKEO e DWT

Agah et al., (2022) propõem um método híbrido combinando as técnicas DWT e TKEO especificamente para preencher a lacuna da MCSA em condições de baixo escorregamento. O método decompõe a corrente via *Wavelet* Daubechies de ordem 45 (db45), aplica o TKEO aos coeficientes de detalhe D7 e D8 cobrindo [19,53; 78,12] Hz, faixa que engloba componentes de barras quebradas e analisa a amplitude espectral do sinal. O atributo diagnóstico consiste no valor da amplitude espectral na frequência característica $f_0 = 2fs$ após processamento DWT-TKEO. A decomposição *Wavelet* filtra componentes indesejadas, enquanto o TKEO remove a componente fundamental, deslocando as bandas laterais para f_0 . A Figura 10 representa o fluxograma simplificado do método.

Figura 10 – Fluxograma Simplificado da Metodologia



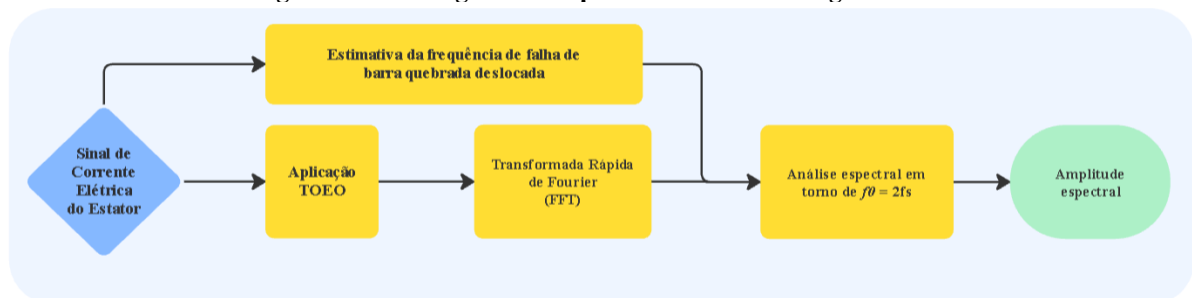
Fonte: Autoria Própria – Elaborado no Miro¹.

Para validação, os autores realizaram experimentos com um motor de indução trifásico de 1,5 kW, 50 Hz, sob três tipos de alimentação (rede, inversor com controle escalar e inversor com controle de torque direto). Para o caso do motor conectado direto à rede, o método se mostra superior em cenários de carga mecânica reduzida. Para o motor com uma barra quebrada operando a 12,5% da carga nominal, o método distinguiu claramente o defeito, apresentando uma diferença de amplitude de 8 dB entre as bandas laterais do motor com uma barra quebrada e as bandas laterais do motor saudável (Agah et al., 2022).

2.4.1.3 Amplitude Espectral Pós-TOEO

Wang et al., (2022) demonstram que o operador TOEO supera o TKEO na detecção de barras quebradas, especialmente em motores alimentados por inversor, mantendo eficácia desde operação a vazio até plena carga. O operador requer apenas duas multiplicações e uma adição por amostra, após essas operações aplica-se normalização e FFT. O atributo diagnóstico é a amplitude espectral do sinal na frequência $f_0 = 2fs$. A Figura 11 representa o fluxograma simplificado do método.

Figura 11 – Fluxograma Simplificado da Metodologia TOEO.




Fonte: Autoria Própria – Elaborado no Miro¹.

Wang et al., (2022) validaram o método com um motor de 3 kW, 380 V, 50 Hz, trifásico, testado sob alimentação pela rede e por inversor Siemens Micromaster 440. Os resultados demonstram distinção clara entre motor saudável e com três barras quebradas sob carga mecânica variável, desde operação a vazio até plena carga. O método mantém eficácia

sob diferentes frequências de alimentação (32 Hz, 40 Hz, 45 Hz, 50 Hz), característica essencial para aplicações com controle de velocidade. A Figura 12 demonstra amplitude espectral da corrente de TOEO para o motor com três barras quebradas e baixo carregamento mecânico.

Figura 12 - Amplitude Espectral da Corrente com a Aplicação do TOEO para o Motor com Três Barras Quebradas e Alimentado pela Rede Elétrica.



Fonte: (Wang et al., 2022).

A validação não inclui motores com uma ou duas barras quebradas (Wang et al., 2022), impossibilitando a caracterização da progressão do defeito. Esta lacuna foi endereçada pela inclusão do método DWT-TKEO (Agah et al., 2022) no conjunto de atributos, que valida especificamente essas severidades intermediárias.

2.4.2 Curto-circuito Entre Espiras do Estator

O defeito de curto-circuito entre espiras (*inter-turn short circuit*) constitui uma das principais causas de degradação do estator, manifestando-se inicialmente como defeito localizado que evolui para falhas catastróficas fase-terra ou fase-fase (Alberto Pereira; Gazzana; F. A. Pereira, 2005). O desbalanceamento de corrente resultante induz componentes harmônicas características no espectro da corrente do estator. Esta seção apresenta atributos diagnósticos extraídos por técnicas complementares de processamento de sinal.

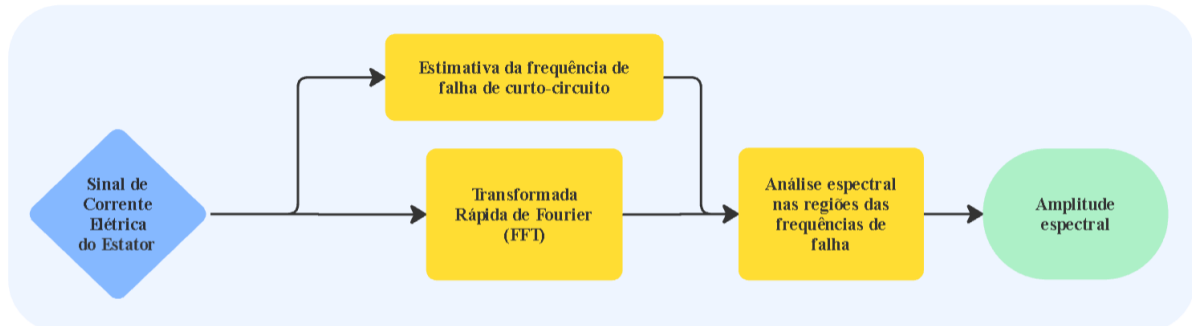
2.4.2.1 Amplitude Espectral da Corrente Via MCSA

A MCSA para detecção de curto-circuito entre espiras baseia-se na análise espectral da corrente do estator via FFT, identificando componentes harmônicas anormais induzidas pelo desbalanceamento das correntes de fase (Jung; Lee; Kwon, 2006). O atributo diagnóstico consiste na amplitude espectral dessas componentes. As componentes de bandas laterais características para defeito de curto-circuito aparecem nas frequências:

$$f_{cc} = f_s \left\{ k \pm \frac{n}{p} (1 - s) \right\}, \quad (18)$$

onde f_s é a frequência de alimentação, s o escorregamento, p o número de pares de polo, k e n , são números inteiros. A Figura 13 representa o fluxograma simplificado do método.

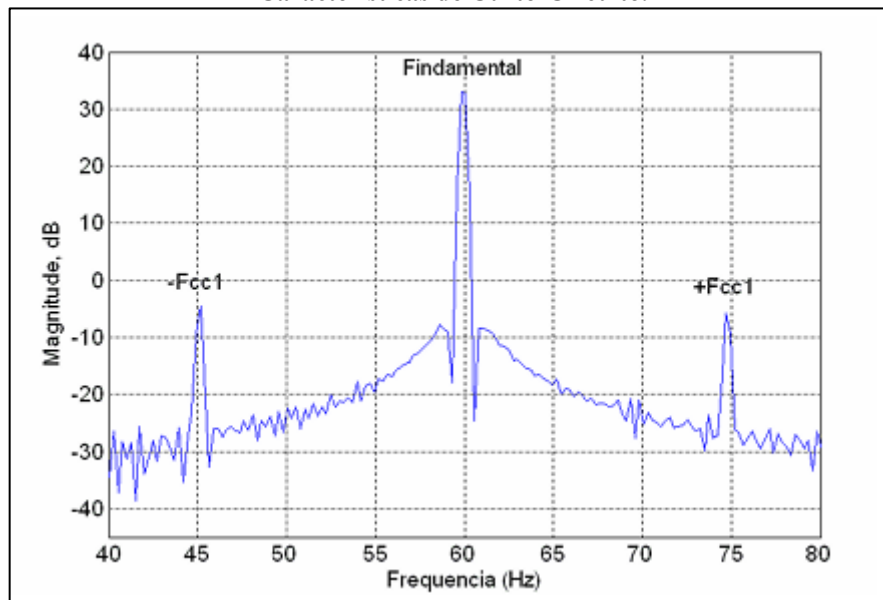
Figura 13 – Fluxograma Simplificado da Metodologia MCSA



Fonte: Autoria Própria – Elaborado no Miro¹.

Para validação do método, Pereira, Gazzana e Pereira (2005), conduziram experimentos com um motor trifásico de 0,25 kW, 8 polos, 60 Hz, 220 V, modificado para permitir emulação controlada de curto-circuito em diferentes percentuais do enrolamento (2%, 4%, 16% e 32%) das espiras de fase. Os espectros demonstraram componentes laterais simétricas crescentes com a severidade do defeito. A Figura 14 demonstra o espectro da corrente obtido com o método.

Figura 14 - Espectro da Corrente do Estator para o Motor a Vazio. +Fcc1 e -Fcc1 São as Frequências Características de Curto-Circuito.



Fonte: (Alberto Pereira; Gazzana; F. A. Pereira, 2005).

Sob operação com carga acoplada, surgem dificuldades significativas de diagnóstico devido à proximidade espectral entre as frequências de curto-circuito e excentricidade.

2.4.2.2 Razão de Energia *Wavelet* Discreta


Cherif et al., (2020) propõem um método baseado na transformada discreta de *Wavelet* (DWT) combinada com razões energéticas para superar limitações da MCSA tradicional. O método decompõe a corrente trifásica via *Wavelet Daubechies* de ordem 44 (db44) em múltiplos níveis, calculando a energia armazenada nos coeficientes de detalhe D_j para cada nível de decomposição. Experimentos identificaram o nível 7 (faixa de frequência [39,0625; 78,125] Hz) como portador da maior energia e melhor discriminação de defeito (Cherif et al., 2020).

O atributo diagnóstico consiste nas razões de energia dos coeficientes de detalhe entre as fases. Em condição saudável, as três razões aproximam-se de 1,0. Sob defeito, as razões variam de acordo com a fase defeituosa, permitindo não apenas detecção, mas localização da fase defeituosa, como demonstrado na Figura 16. As razões de energia de *Wavelet* são dadas por:

$$DWER1 = \frac{Ed_{7a}}{Ed_{7b}}, \quad DWER2 = \frac{Ed_{7b}}{Ed_{7c}}, \quad DWER3 = \frac{Ed_{7c}}{Ed_{7a}}, \quad (19)$$

onde $DWER1$ é a razão de energia de *Wavelet* 1, baseado nas fases a e b, $DWER2$ é a razão de energia de *Wavelet* 2, baseado nas fases b e c e $DWER3$ é a razão de energia de *Wavelet* 3, baseado nas fases c e a. A Figura 15 apresenta o fluxograma simplificado do método.

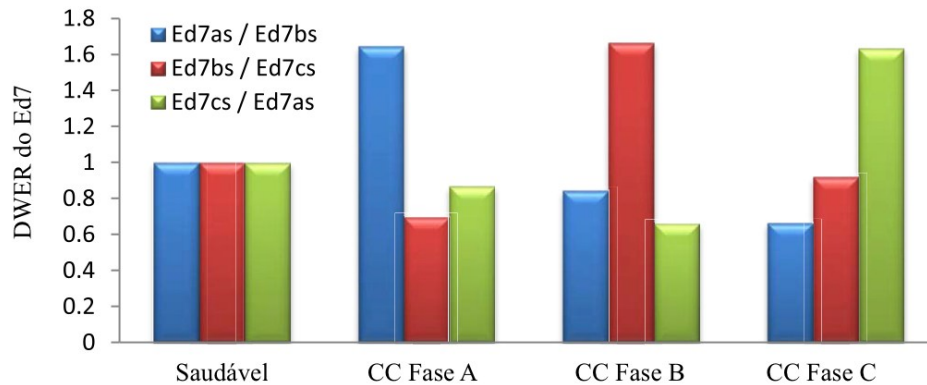
Figura 15 – Fluxograma Simplificado da Metodologia de Razão dos Coeficientes de Decomposição *Wavelet*



Fonte: Autoria Própria – Elaborado no Miro¹.

Para validação, Cherif et al., (2020) utilizaram um motor trifásico de 1,1 kW, 400 V, 50 Hz, com 7, 13, 15, 20 e 30 espiras curto-circuitadas, testado sob cargas variáveis (0%, 10%, 30%, 50%, 70%, 90% da nominal). Redes neurais MLP e Elman (ENN) alcançaram desempenho superior com erro MSE (*Mean Squared Error*) de 10^{-9} no treinamento e 10^{-8} no teste para detecção dos defeitos.

Figura 16 - Razões Calculadas das Energias de *Wavelet* para Curto-Circuito Entre Espiras na Fase A, B e C nos Experimentos com o Motor



Fonte: Adaptado de (Cherif et al., 2020).

2.4.2.3 Abordagem do Vetor de Park

A Abordagem do vetor de Park (PVA) analisa o vetor de Park obtido pela transformação das correntes trifásicas em componentes d - q dadas por (Parra et al., 2013):


$$i_d = \sqrt{\frac{2}{3}} \left(i_a - \frac{1}{\sqrt{2}} i_b - \frac{1}{\sqrt{2}} i_c \right), \quad (20)$$

$$i_q = \left(\frac{1}{\sqrt{2}} i_b - \frac{1}{\sqrt{2}} i_c \right), \quad (21)$$

$$i_p = i_d + j i_q. \quad (22)$$

Sob operação balanceada, a representação complexa descreve circunferência perfeita no plano de Gauss (Parra et al., 2013). Correntes desbalanceadas causadas por curto-circuito deformam a trajetória para elipse, cuja excentricidade correlaciona-se com a severidade do defeito (Parra et al., 2013). Dessa forma, o atributo diagnóstico consiste no fator de excentricidade da curva descrita pela corrente de Park no plano complexo. A Figura 17 representa o fluxograma simplificado do método.


Figura 17 – Fluxograma Simplificado da Metodologia de Análise do Vetor de Park.



Fonte: Autoria Própria – Elaborado no Miro¹.

Para validação experimental, Parra et al., (2013) utilizaram um motor de 2,2 kW, 220 V, 4 polos, 1740 rpm, modificado para permitir curto-circuito de 2, 5, 10 e 14 espiras de uma mesma bobina. Ensaios demonstraram que a excentricidade da curva descrita pela corrente de Park no plano Complexo varia com a severidade do defeito, como demonstrado na Figura 18.

Figura 18 - Corrente de Park Plotado no Plano Complexo. A Severidade do Defeito é Dada por: Azul – 2 Espiras, Verde – 5 Espiras, Magenta – 10 Espiras, Vermelho – 14 Espiras



Fonte: (Parra et al., 2013).


2.4.3 Defeitos em Rolamentos

Os rolamentos representam um dos componentes mais críticos em motores de indução, sendo responsáveis por uma parte significativa das falhas em motores de indução. Quando defeitos como trincas, desgaste ou abrasão de material ocorrem nas pistas interna, externa, elementos rolantes ou gaiola, o rolamento gera vibrações mecânicas periódicas que modulam o entreferro magnético e, conseqüentemente, a corrente do estator (Nasiri et al., 2025). Essas modulações manifestam-se como bandas laterais em torno da frequência fundamental e suas harmônicas, com espaçamentos determinados pelas frequências características de defeito.

2.4.3.1 Wavelet Packet Decomposition e Índices de Severidade

A principal limitação dos métodos baseados exclusivamente em FFT e PSD é a vulnerabilidade a ruídos externos, que dificulta a detecção de defeitos em estágios iniciais, quando as amplitudes das componentes características ainda são baixas (Nasiri et al., 2025). Para superar essa limitação, a metodologia proposta em (Nasiri et al., 2025) utiliza *Wavelet Packet Decomposition* (WPD) como etapa intermediária entre o sinal temporal bruto e a análise espectral. Após a aplicação da WPD, os coeficientes dos nós correspondentes às frequências de defeito são processados via FFT e PSD. Por fim, das três representações obtidas do sinal, extrai-se atributos como Energia, Variância e Desvio Padrão que são utilizados como entrada para diagnóstico do defeito de rolamento. A Figura 19 representa o fluxograma simplificado do método.

Figura 19 – Fluxograma Simplificado da Metodologia WPD



Fonte: Autoria Própria – Elaborado no Miro¹.

Para validação da metodologia, Nasiri et al. (2025) conduziram experimentos em um motor de 1,5 kW, demonstrando capacidade de discriminar três tipos de defeitos (pista externa, gaiola e esfera do rolamento) mesmo sob carregamento nulo e diferentes formas de alimentação do motor. Os autores definiram o índice de severidade como métrica principal para classificação entre motor saudável e motor com defeito de rolamento.

2.4.3.2 Amplitude Espectral via MCSA

Paralelamente à abordagem WPD, a extração de atributos espectrais diretamente via FFT aplicada ao sinal de corrente, seguida de classificação por redes neurais, constitui estratégia consolidada para diagnóstico de rolamentos (Sameh; Tarek; Yassine, 2020). Essa metodologia baseia-se na identificação das frequências características de defeito por MCSA e na extração das amplitudes espectrais correspondentes como atributos diagnósticos para o modelo de rede neural. As componentes de bandas laterais características para defeito de pista interna e externa de rolamento aparecem respectivamente nas frequências (Sameh; Tarek; Yassine, 2020):

$$f_{inner} = \frac{f_r}{2} N_b \left(1 - \frac{D_b}{D_c} \cos \varphi\right), \quad (23)$$

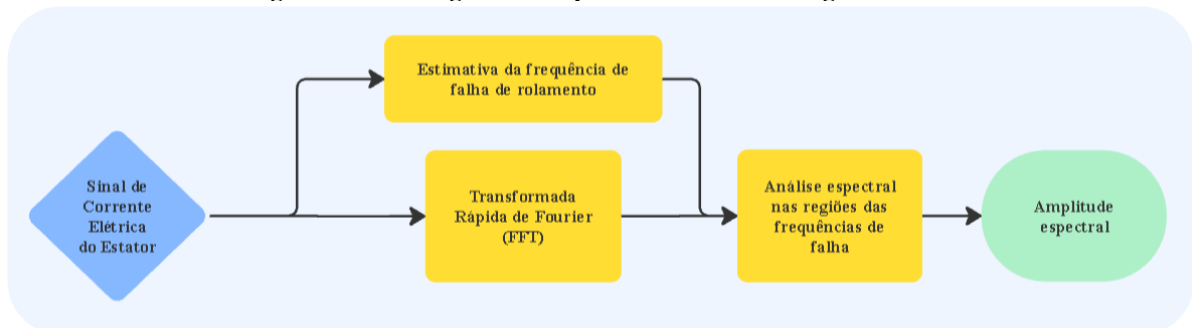
$$f_{outer} = \frac{f_r}{2} N_b \left(1 + \frac{D_b}{D_c} \cos \varphi\right), \quad (24)$$

onde f_r é a frequência mecânica do rotor, N_b o número de esferas do rolamento, D_b o diâmetro da esfera, D_c o diâmetro primitivo do rolamento, e φ o ângulo de contato com as esferas. Além das componentes diretas nas frequências características de defeito, assinaturas adicionais podem ser observadas no espectro da corrente do estator na forma de bandas laterais, dadas por (Kouadria et al., 2024):

$$f_{bear} = |f_s \pm k f_v|, \quad (25)$$

com $k = 1, 2, 3$, onde f_s é a frequência de alimentação e f_v é a frequência característica de defeito correspondente, dadas pelas equações 23 e 24. A Figura 20 representa o fluxograma simplificado do método.

Figura 20 – Fluxograma Simplificado da Metodologia MCSA.



Fonte: Autoria Própria – Elaborado no Miro¹.

Sameh, Tarek e Yassine (2020) validaram experimentalmente o método utilizando um motor de 4 kW alimentado por inversor de frequência a 50 Hz, com defeito induzido na pista externa do rolamento. Utilizando rede neural probabilística, a acurácia de classificação alcançada foi de 96,5%, evidenciando a discriminabilidade dos atributos espectrais diretos quando combinados com classificadores adequados.

2.5 Redes Neurais Artificiais

Redes neurais artificiais são modelos computacionais inspirados no funcionamento das redes neurais cerebrais, construídos a partir de circuitos formados por unidades de

processamento, neurônios artificiais, que, conectadas entre si, conseguem resolver problemas complexos (Russell; Norvig, 2021). O termo "rede neural" surgiu de trabalhos pioneiros que tentavam modelar redes de neurônios biológicos através de circuitos computacionais, mas é importante ressaltar que a semelhança com o cérebro está bem distante, trata-se de uma inspiração conceitual.

A grande vantagem desses modelos aparece no processamento de dados complexos e de alta dimensionalidade, como imagens, áudios e sinais. Enquanto modelos lineares simples tratam cada variável de entrada de forma independente, as redes neurais permitem que essas variáveis interajam ao longo de várias etapas de processamento, capturando relações não lineares entre elas. Essa característica as torna adequadas para problemas onde a relação entre entrada e saída não pode ser descrita por equações lineares (Russell; Norvig, 2021).

O conceito de neurônio artificial foi proposto por McCulloch e Pitts em 1943, onde cada neurônio podia estar "ligado" ou "desligado", mudando de estado quando recebia estímulos suficientes de neurônios vizinhos (Russell; Norvig, 2021). O neurônio artificial moderno funciona de forma um pouco diferente, ele recebe várias entradas, cada uma multiplicada por um peso, que foi definido durante seu treinamento, soma essas entradas ponderadas e passa o resultado por uma função de ativação que decide o valor final da saída. As funções de ativação evoluíram significativamente ao longo do tempo. Entre 1985 e 2010, predominaram a sigmóide e a tangente hiperbólica, mas a partir de 2010 a função ReLU (Unidade Linear Retificada) tornou-se mais popular por resolver melhor certos problemas de treinamento (Russell; Norvig, 2021).


Uma rede neural organiza seus neurônios em camadas sequenciais, onde cada camada recebe informações da camada anterior, processa essas informações e passa o resultado para a próxima camada. Durante o processamento, os dados de entrada passam por várias transformações intermediárias até chegarem à saída final, sendo que cada camada pode ser vista como criando uma representação diferente dos dados.

Uma explicação para o sucesso dessa abordagem é que problemas complexos são naturalmente decompostos em subproblemas mais simples, cada camada resolve uma parte pequena do problema, e a composição de todas essas soluções parciais resulta na solução completa (Russell; Norvig, 2021). Essas camadas intermediárias, chamadas de camadas ocultas, geralmente "aprendem" a detectar padrões relevantes nos dados de forma automática.

O *perceptron* de camada única, desenvolvido por Rosenblatt em 1957, tinha uma limitação séria documentada formalmente por Minsky e Papert em 1969, só conseguia resolver problemas linearmente separáveis (Russell; Norvig, 2021). A solução encontrada foi adicionar

camadas intermediárias, criando o *Multi-Layer Perceptron* (MLP), que possui três tipos de camadas: a camada de entrada, que recebe os dados brutos ou atributos previamente extraídos; uma ou mais camadas ocultas, que realizam transformações sucessivas dos dados e onde a rede rebalanceia os pesos; e a camada de saída, que produz o resultado usando uma camada para classificação, gerando probabilidades para cada classe possível (Russell; Norvig, 2021). A Figura 14 apresenta o fluxo de dados e estrutura de uma *Multi-layer Perceptron*.

Figura 21 – Fluxo de Dados em uma *Multi-layer Perceptron*



Fonte: (Moreira, 2018).

Foi demonstrado matematicamente que redes com múltiplas camadas podem aproximar qualquer função contínua, desde que tenham neurônios suficientes, tornando-as teoricamente capazes de resolver problemas muito diversos (Russell; Norvig, 2021). Experimentos práticos mostraram que redes mais profundas, com muitas camadas, e com menos neurônios por camada, frequentemente superam redes com muitos neurônios e poucas camadas, mantendo-se o número total de parâmetros.

O treinamento de uma rede neural consiste em ajustar os pesos das conexões entre neurônios para minimizar os erros nas previsões, utilizando o algoritmo de retropropagação (Russell; Norvig, 2021). O processo funciona em duas etapas, primeiro, a rede processa um bloco de treinamento e calcula o erro entre a saída prevista e a saída correta, depois, esse erro é propagado de volta através das camadas, da saída para a entrada, calculando quanto cada peso contribuiu para o erro total. Com essas informações, o algoritmo ajusta cada peso na direção que reduz o erro, sendo o tamanho do ajuste controlado por um parâmetro de taxa de aprendizado. Esse processo se repete milhares ou milhões de vezes até que a rede aprenda a fazer boas previsões.

No contexto deste trabalho, entende-se que as MLPs são adequadas para o diagnóstico de defeitos em motores de indução por duas razões principais. Primeiro, elas conseguem aprender relações complexas e não lineares entre os atributos extraídos dos sinais de corrente

elétrica e as diferentes classes de defeito, o que é fundamental porque as assinaturas de defeitos em motores não seguem padrões lineares, muitas das vezes ruídos podem interferir análises puramente matemáticas. Segundo, quando alimentadas com atributos interpretáveis fisicamente, atributos esses que foram introduzidos em seções anteriores, presume-se que as MLPs atuem como classificadores ainda mais robustos, utilizando atributos mais certos que generalizam o aprendizado para diferentes condições de operação.

3 REVISÃO SISTEMÁTICA DA LITERATURA

A revisão sistemática da literatura é um método formal e replicável de identificação, avaliação e interpretação de estudos relevantes sobre determinado tema. Essa metodologia busca minimizar vieses e garantir uma visão abrangente e atualizada do estado da arte, permitindo a formulação de conclusões fundamentadas e a identificação de lacunas de pesquisa (Maciejewski; Tremil; Flauzino, 2020).

Neste trabalho, a revisão sistemática da literatura foi conduzida com o objetivo de identificar os métodos de processamento de sinais e atributos extraídos de sinais de corrente elétrica do estator, nos domínios do tempo, da frequência e tempo-frequência que apresentam maior eficácia na detecção de defeitos em motores de indução trifásicos.

3.1 Definição da Pergunta de Pesquisa

A pergunta de pesquisa foi formulada da seguinte maneira:

“Quais métodos, cálculos ou atributos envolvendo sinais de corrente elétrica, nos domínios do tempo e da frequência, proporcionam maior eficácia na detecção de defeitos em motores de indução trifásicos?”

Essa questão delimita o escopo da pesquisa em abordagens baseadas em sinais elétricos, buscando relacionar propriedades físicas mensuráveis à presença de defeitos típicas como rolamento, estator, barras quebradas e excentricidade.

3.2 Identificação dos Bancos de Dados

A busca foi realizada nas bases *IEEE Xplore*² e *Scopus*³, reconhecidas por sua ampla cobertura de publicações científicas na área de engenharia elétrica e automação. Essas bases também foram indicadas por Maciejewski; Tremil; Flauzino, (2020) como bancos de dados importantes usados para pesquisa nas áreas de engenharia e ciências exatas.

3.3 Critérios de Seleção

Os critérios de seleção foram definidos com o objetivo de garantir que apenas estudos relevantes, metodologicamente consistentes e alinhados à pergunta de pesquisa fossem incluídos nesta revisão sistemática. A definição desses critérios é fundamental para assegurar rigor científico, reprodutibilidade e precisão na análise, conforme recomendado pelos

² <https://ieeexplore.ieee.org/Xplore/home.jsp>

³ <https://www.scopus.com>

protocolos de Kitchenham. (2007) e aplicados por Maciejewski; Tremł; Flauzino. (2020) em revisões similares sobre diagnóstico de defeito em motores de indução.

Foram incluídos apenas os estudos que atendiam aos critérios abaixo:

- 1) O trabalho tem embasamento físico teórico para formular atributos úteis na detecção de defeitos?
- 2) O trabalho apresenta dados experimentais reais com validação prática dos métodos propostos?
- 3) O trabalho aborda pelo menos um dos defeitos de interesse, rolamento, estator, barra quebrada, excentricidade?
- 4) O trabalho não é repetido nas bases de dados selecionadas?
- 5) O trabalho é escrito em Português ou Inglês?

3.4 *String* de Busca

A definição da *string* de busca é uma das etapas mais críticas da revisão sistemática, pois determina diretamente a abrangência, precisão e qualidade dos estudos recuperados. Uma *string* bem formulada garante que a busca retorne o maior número possível de trabalhos relevantes, ao mesmo tempo em que reduz a incidência de estudos irrelevantes, viés de seleção e perda de publicações importantes. Seguindo o protocolo apresentado por (Kitchenham, 2007) e alinhado à metodologia de (Maciejewski; Tremł; Flauzino, 2020) a *string* foi construída utilizando operadores booleanos (AND, OR) e caracteres curinga (*), permitindo capturar variações linguísticas, sufixos e formas plurais. O Quadro 1 apresenta as palavras-chave utilizadas na construção da estrutura, seguidas da *string* resultante.

Quadro 1 - Palavras-Chave Usadas na String de Busca

Objeto de estudo	Defeitos	Dados
Motor de indução Máquina Assíncrona	Rolamentos Barra Quebrada Excentricidade Estator	Experimental
Sinais	Regime de análise	Domínio de análise
Correntes elétricas	Permanente	Tempo Frequência Tempo – Frequência

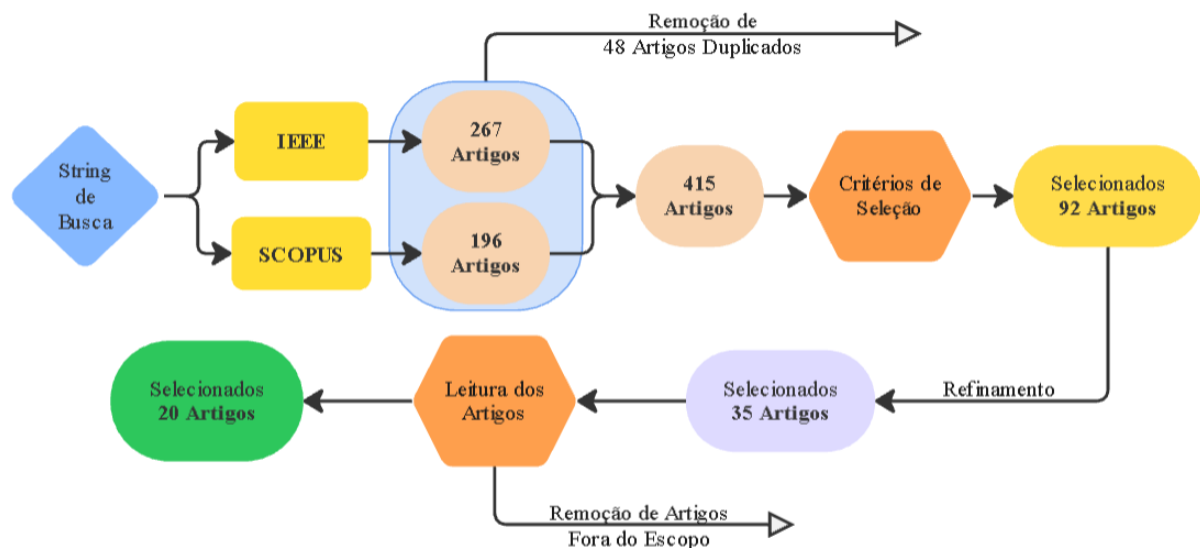
Fonte: Autoria Própria.

String de busca:

(machine* OR motor*) AND (induction OR async* OR squirrel) AND (bearin* OR stato* OR armature OR inter* OR bar* OR excentr* OR lubrif*) AND (fault* OR defect* OR failure*) AND (detect* OR diagno* OR maintenanc* OR prognost* OR predict*) AND (current* OR voltag*) AND (time domain OR frequency OR time-frequency)

Após a execução da busca utilizando a *string* definida, foram retornados 267 artigos na base *IEEE Xplore*² e 196 artigos no *Scopus*³, totalizando 463 registros. A remoção de 48 publicações duplicadas entre as bases resultou em 415 artigos únicos para triagem. A primeira etapa de seleção, baseada na análise de títulos e resumos conforme os critérios de inclusão estabelecidos, reduziu o conjunto para 92 artigos potencialmente relevantes. Esses trabalhos foram submetidos a um refinamento mais criterioso, considerando o alinhamento com a o escopo do trabalho, resultando em 35 artigos selecionados para leitura integral. Após a leitura completa, identificou-se que 15 trabalhos não atendiam integralmente aos requisitos do estudo. Dessa forma, 20 artigos foram selecionados para compor a base da revisão sistemática. O fluxo completo seleção dos artigos é apresentado na Figura 22.

Figura 22 – Fluxo de Seleção



Fonte: Autoria Própria – Elaborado no Miro¹.

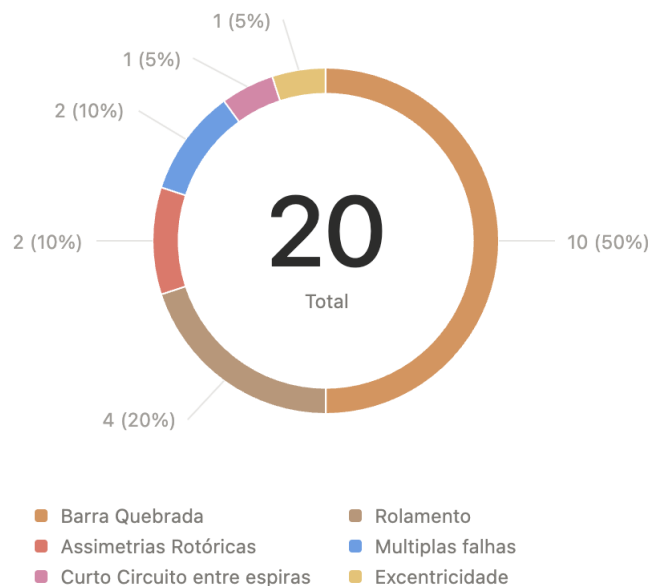
A aplicação dos critérios de seleção e das perguntas de qualificação resultou na inclusão de 20 artigos para análise aprofundada, de um total de 415 artigos inicialmente identificados nas bases *IEEE Xplore*² e *Scopus*³. Os artigos excluídos apresentavam métodos ou abordagens que não se alinhavam com o escopo deste trabalho, seja por utilizarem sinais

diferentes da corrente do estator, por empregarem técnicas de *Deep Learning* sem interpretabilidade física, ou por não contemplarem os tipos de defeito investigados.

3.5 Síntese dos Resultados

A distribuição dos artigos aceitos revelou predominância de estudos sobre barras quebradas, que totalizaram 10 artigos, representando aproximadamente 50% do conjunto selecionado. Em segundo lugar, aparecem os defeitos de rolamento com 4 artigos (20%), seguidas por curto-circuito entre espiras do estator com 1 artigo (5%), excentricidade com 1 artigo (5%) e assimetrias rotóricas com 1 artigo (5%). Adicionalmente, 2 artigos (10%) abordaram múltiplos defeitos simultâneas. A Figura 23 apresenta a distribuição da quantidade de artigos selecionados.

Figura 23 – Distribuição da Quantidade de Artigos por Tipos de Defeito



Fonte: Autoria Própria - Elaborado no Notion⁴.

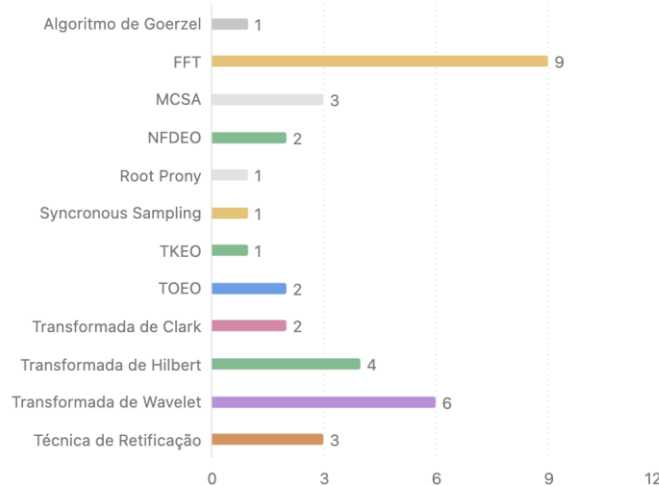
No que concerne aos métodos de processamento de sinais, a DWT destacou-se como uma das técnicas mais empregadas, presente em 6 dos 20 artigos aceitos. Essa prevalência justifica-se pela capacidade da DWT em fornecer representação tempo-frequência eficaz para sinais não estacionários, permitindo a decomposição do sinal de corrente em múltiplos níveis de resolução e a extração de atributos em bandas de frequência específicas. A análise FFT destacou-se como, a técnica a mais empregada e apareceu em 9 artigos, frequentemente combinada com técnicas de demodulação ou pré-processamento. Os operadores de energia

⁴ <https://www.notion.com>

baseados em *Teager-Kaiser* figuram em 5 artigos, constituindo abordagem promissora para a eliminação do vazamento espectral da componente fundamental e detecção de defeitos em condições de baixo escorregamento. A técnica de retificação da corrente do estator aparece em 3 artigos, apresentando-se como alternativa computacionalmente eficiente para demodulação do sinal.

Quanto aos atributos extraídos, observou-se diversidade de abordagens. Atributos estatísticos no domínio do tempo, como RMS (*Root Mean Square*), curtose, assimetria, desvio padrão e fator de crista, foram empregados em alguns artigos. Atributos no domínio da frequência, como a amplitude espectral em frequências características e a energia em bandas específicas, predominaram nos estudos focados em barras quebradas e assimetrias rotóricas. A energia *Wavelet* por nível de decomposição constitui classe de atributo recorrente nos trabalhos que empregam DWT. A Figura 24 apresenta a distribuição dos atributos mencionados nos artigos.

Figura 24 - Distribuição da Quantidade de Artigos por Métodos de Processamento



Fonte: Autoria Própria - Elaborado no Notion⁴.

3.6 Metanálise

Os artigos selecionados na revisão sistemática abordam métodos de detecção de defeitos em motores de indução trifásicos, com foco em quatro categorias principais de defeitos: barras quebradas do rotor, curto-circuito entre espiras do estator, defeito de rolamento e excentricidade do entreferro.

3.6.1.1 Barras Quebradas

A maior parte dos estudos sobre barras quebradas concentrou-se em superar a principal limitação da análise espectral convencional (MCSA) em cenários de baixo carregamento mecânico e baixo escorregamento.

Entre as abordagens identificadas, destacam-se o operador de energia TKEO (Agah et al., 2022), o operador de energia de terceira ordem TOEO (Bazghandi; Marzebali; Abolghasemi, 2024; Wang et al., 2022), a DWT (Agah et al., 2022; Ali; Liang, 2020; Sinha et al., 2021) e a retificação da corrente (Hajnayeb et al., 2024; Puche-Panadero et al., 2020). O operador de frequência normalizado (NFDEO) foi aplicado em (Bazghandi; Marzebali; Abolghasemi, 2022; Li et al., 2021), enquanto o algoritmo de Goertzel foi empregado em (Martinez-Roman et al., 2021) para detecção seletiva de frequências específicas. Abordagens alternativas incluem a transformada de Hilbert combinada com eixos ortogonais retificados (Hajnayeb et al., 2024) e a decomposição em componentes de eixo direto e quadratura (Drobnic et al., 2025). Todos esses métodos compartilham o objetivo comum de separar espectralmente a componente de defeito da fundamental, permitindo análise baseada em amplitude das bandas laterais características. Para barras quebradas, todos os métodos atingiram de forma satisfatória o objetivo de isolar a componente de defeito da fundamental, com destaque significativo das bandas laterais características mesmo em cenários de carga variável e baixo escorregamento.

3.6.1.2 Curto-circuito entre Espiras do Estator

Para o defeito de curto-circuito entre espiras, a revisão sistemática identificou inicialmente apenas um artigo, que utilizava a transformada *Wavelet* para classificar a severidade do defeito (Almounajjed; Sahoo; Kumar, 2021). Diante dessa limitação, foi conduzida uma busca complementar para ampliar a base de referências de análise. Em (Parra et al., 2013), a abordagem estendida do vetor de Park tornou as componentes espectrais de defeito mais evidentes. Em Alberto Pereira; Gazzana; F. A. Pereira. (2005) a MCSA combinada com lógica fuzzy permitiu detecção satisfatória em motores sem carga. O estudo de Cherif et al. (2020) extraiu atributos a partir da razão de energia entre coeficientes *Wavelet* de fases distintas, alcançando erro médio quadrático (MSE) de 10^{-8} com redes neurais Elman (ENN).

3.6.1.3 Defeito de Rolamento

As técnicas para diagnóstico de rolamentos concentraram-se em extrair características específicas relacionadas às frequências características de defeito. Em Nasiri et al. (2025)

trabalho aplicou FFT e densidade espectral de potência (PSD) aos coeficientes *Wavelet* para extrair atributos diagnósticos que permitiram distinguir e identificar o defeito em condições de carga nominal e a vazio. Em Ali et al. (2020) atributos matemáticos extraídos diretamente do sinal de corrente foram empregados como entrada para redes neurais artificiais (ANN) permitindo classificar a classe do defeito. O método *Root-Prony* foi utilizado em Kouadria et al. (2024) para aumentar a resolução espectral e viabilizar a detecção das frequências de defeito. Finalmente, Sameh; Tarek; Yassine. (2020) baseou-se na análise espectral da MCSA para extrair atributos destinados a redes neurais atingindo uma precisão de 96.5% nos testes.

3.6.1.4 Contribuições da Revisão Sistemática da Literatura

A revisão sistemática forneceu a base teórica e metodológica para a definição das técnicas de extração de atributos empregadas neste trabalho. Os estudos selecionados contribuíram diretamente para identificar os métodos mais relevantes e atuais no diagnóstico de falhas em motores de indução, especialmente no que se refere à análise de sinais. A partir deles, foram escolhidos os atributos utilizados na etapa de diagnóstico, abrangendo técnicas amplamente consolidadas, como a DWT, os operadores TKEO e TOEO e a análise espectral convencional MCSA.

Entretanto, constatou-se que as falhas de curto-circuito entre espiras foram pouco representadas na revisão. Por esse motivo, foi realizada uma pesquisa complementar direcionada, visando ampliar o conjunto de atributos disponíveis e selecionar referências específicas. Dessa forma, a revisão sistemática não apenas orientou a escolha inicial das técnicas, mas também evidenciou lacunas que direcionaram a busca adicional por métodos adequados à caracterização desse tipo de defeito.

4 MATERIAIS E MÉTODOS

Este capítulo descreve os recursos experimentais e os procedimentos metodológicos que foram empregados no desenvolvimento do sistema de diagnóstico de defeitos. Inicialmente, são apresentados os bancos de dados que foram utilizados durante o trabalho, detalhando as características do motor e as condições operacionais. Em seguida, foram descritos os métodos de pré-processamento de sinais, extração de atributos e a configuração da rede neural artificial que foi empregada.


4.1 Banco de Dados de Barra Quebrada

A base de dados de defeito de barra quebrada, disponível publicamente no *IEEE*² com o título “*Experimental database for detecting and diagnosing rotor broken bar in a three-phase induction motor*”, foi adquirida em uma bancada experimental nos Laboratórios LAIPS e LACIME da Escola de Engenharia de São Carlos (USP) (Treml et al., 2020). A Figura 25 mostra a bancada experimental utilizada. Ela é composta por motor de indução trifásico WEG W22 (1 cv, 220V/380V, 4 polos, 60 Hz, 1715 rpm, rotor gaiola de esquilo com 34 barras), gerador de corrente contínua de 2 kW operando como carga e torquímetro rotativo Transtec MT-103 baseado em ponte de Wheatstone (Treml et al., 2020). A bancada possibilita emular barras quebradas no rotor mediante perfuração com broca de 6 mm de diâmetro na metade do comprimento longitudinal do rotor, com profundidade de 20 mm, simulando condições progressivas de 1, 2, 3 e 4 barras adjacentes quebradas.

A aquisição dos sinais de corrente trifásica foi realizada através de sondas Yokogawa 96033, com capacidade de 50 A RMS, sensibilidade de 10 mV/A, conectadas às três fases do motor e registradas por oscilógrafo Yokogawa DL750 com taxa de amostragem de 50 kHz. O banco de dados é composto por 400 experimentos totais, organizados em cinco condições do rotor, motor saudável e quatro níveis de severidade de defeito, 1, 2, 3 e 4 barras quebradas adjacentes, denominados de rs, r1b, r2b, r3b e r4b, respectivamente, cada uma testada sob oito condições de carga mecânica (0,5 a 4,0 N·m em passos de 0,5 N·m) com dez repetições por condição (Treml et al., 2020).

Para este trabalho, foram utilizados exclusivamente os sinais de corrente trifásica em regime permanente, descartando-se os períodos transitórios de partida do motor. Todos os experimentos foram realizados mediante partida direta do motor, com tensão de alimentação trifásica e na frequência de 60 Hz. Os sinais foram segmentados em janelas temporais conforme metodologia, permitindo análise contínua do estado do motor.

Figura 25 - Disposição Geral da Bancada de Experimentos para Ensaio de Defeito de Barra Quebrada



Fonte: (Treml et al., 2020).

4.2 Banco de Dados de Curto-circuito Entre Espiras do Estator


A base de dados de defeito de curto-circuito foi adquirida em uma bancada experimental por Cunha; Junior; Medeiros (2020), disponibilizado no Kaggle⁵ com nome de “*Inter-turn Short-Circuit In Induction Motor*”. A bancada é composta por duas máquinas de indução trifásicas gaiola de esquilo (4 polos, 1 HP, configuração delta, 220V, 3A), conversores de frequência WEG CFW-08, painel de controle e banco de resistores. Uma máquina foi rebobinada para permitir a emulação controlada de curtos-circuitos entre espiras do estator, operando como motor, enquanto a outra emula a carga mecânica. Foram simulados seis tipos de defeitos combinando duas categorias, degradação inicial do isolante (HI) e curto-circuito completo entre espiras (LI), com três níveis de severidade crescente, correspondendo a 1,41%, 4,81% e 9,26% do enrolamento do estator em curto respectivamente, resultando na nomenclatura LI1, HI1, LI2, HI2, LI3 e HI3. O conjunto totaliza 350 amostras de operação normal e 2240 de condições faltosas, variando a carga mecânica (0%, 50% e 100% da nominal) e a frequência de acionamento (30 a 60 Hz, em passos de 5 Hz). A aquisição dos sinais de corrente elétrica foi realizada através de transformadores de corrente nas três fases (Cunha; Junior; Medeiros, 2021), para este trabalho foram utilizadas as medições referentes aos experimentos com frequência de acionamento de 60 Hz.

⁵ <https://www.kaggle.com/datasets/rebecacunha/mit-short-circuit-flux-and-current-signals>

4.3 Banco de Dados de Defeito em Rolamento

O banco de dados de defeito em rolamento foi adquirido do repositório público Mendeley Data⁶, desenvolvido no *Korea Advanced Institute of Science and Technology*, Coreia do Sul (Jung et al., 2023). A bancada experimental utilizada para aquisição dos dados é ilustrada na Figura 26, composta por motor de indução trifásico Siemens de 3 HP (2,2 kW, 380 V, 60 Hz), mancais de rolamento e caixa de engrenagens. Para aquisição dos sinais de corrente, foram instalados três transformadores de corrente (Hioki CT6700) nas fases do motor trifásico. Os dados foram coletados utilizando módulo NI9775 e armazenados em arquivos CSV e TDMS.

Figura 26 - Disposição Geral da Bancada de Experimentos para Ensaio de Defeito de Rolamento



Fonte: Adaptado de (Jung et al., 2023).

Três tipos de defeitos foram artificialmente induzidos em rolamentos NSK 6205: defeito na pista interna, defeito na pista externa e defeito nos elementos rolantes. Os defeitos nas pistas foram gerados mediante remoção de material superficial em três severidades: 0,3 mm, 1,0 mm e 3,0 mm (Jung et al., 2023). O eixo do motor é conectado a uma caixa de engrenagens que multiplica a velocidade do eixo do motor em 2,07 vezes para o eixo do rolamento.

O banco de dados disponibiliza sinais de corrente elétrica em duas condições operacionais distintas. A primeira condição em operação velocidade constante de 3010 RPM, no eixo do rolamento, com três níveis de carga mecânica (0 N·m, 2 N·m e 4 N·m), com 60 segundos de aquisição para cada combinação de tipo de defeito, severidade e carga. Na segunda condição o motor opera em velocidade variável entre 680 RPM e 2460 RPM sem aplicação de

⁶ <https://data.mendeley.com/datasets/ztmf3m7h5x/6>

carga, com 2100 segundos organizados em sete arquivos de 300 segundos para cada condição de saúde, motor saudável, defeito na pista interna (BPFI), defeito na pista externa (BPFO) e defeito nos elementos rolantes, totalizando 28 arquivos com taxa de amostragem de 100 kHz. Dados sincronizados de velocidade instantânea acompanham os sinais de corrente na condição de velocidade variável.

Este banco de dados permite a aplicação dos métodos de diagnóstico baseadas em corrente elétrica, tanto em condições de velocidade e carga constantes quanto em condições de velocidade variável, possibilitando testar os métodos de detecção de defeitos em rolamentos em diferentes cenários operacionais (Jung et al., 2023). Para este trabalho foi utilizada a primeira condição, onde a velocidade é constante, mas com torque variável e para defeito na pista interna e pista externa do rolamento.

4.4 Processamento de Dados de Corrente Elétrica Trifásica

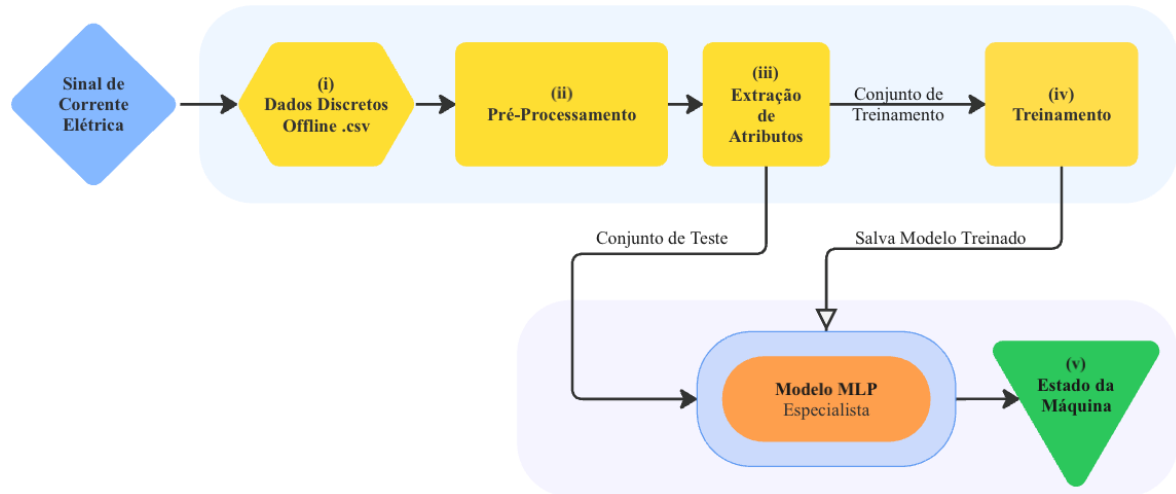
A metodologia proposta neste trabalho fundamenta-se na construção de classificadores baseados em redes neurais artificiais especializadas para diagnóstico de defeitos em motores de indução trifásicos. Diferente de abordagens que empregam um único classificador multiclasse, adota-se uma estratégia baseada em classificadores binários independentes, cada um especialista na detecção de um tipo específico de defeito, barras rotóricas quebradas, defeitos em rolamentos e curto-circuito entre espiras do estator.

Esta abordagem justifica-se pela natureza física distinta das manifestações de cada defeito no sinal de corrente elétrica do estator, conforme demonstrado no Capítulo 2. Cada tipo de defeito introduz perturbações eletromagnéticas caracterizadas por componentes espectrais específicas e comportamentos estatísticos particulares (Drobic et al., 2025; Hajnayeb et al., 2024; Puche-Panadero et al., 2020). O treinamento de classificadores individuais permite que cada rede neural seja otimizada para reconhecer padrões discriminativos de um único tipo de defeito, aumentando a capacidade de detecção e minimizando falsos positivos decorrentes da confusão entre diferentes categorias de defeito.

Adicionalmente, como os bancos de dados utilizados originam-se de bancadas experimentais distintas, com motores, instrumentação e condições operacionais heterogêneas, entende-se que um classificador único poderia enviesar o aprendizado, tendendo a distinguir entre as próprias bancadas em vez de discriminar o estado real da máquina, podendo modificar os resultados individuais de cada defeito. Para mitigar esse efeito, cada rede recebe exclusivamente atributos provenientes da bancada associada à sua especialidade, a rede dedicada a barras quebradas é treinada apenas com dados da respectiva bancada, distinguindo

entre o estado saudável e o defeituoso dentro do mesmo contexto experimental. O mesmo princípio aplica-se às redes especialistas em rolamentos e em curto-circuito entre espiras.

Figura 27 – Fluxo de Processamento para um Modelo Especialista



Fonte: Autoria Própria - Elaborado no Miro¹.

O fluxo de processamento, ilustrado na Figura 27, organiza-se nas seguintes etapas: (i) leitura dos sinais de corrente trifásica em formato .CSV, contendo a corrente de cada fase, com identificação automática de bancada de origem e saúde do motor, a partir da nomenclatura dos arquivos; (ii) detecção da frequência fundamental de alimentação e segmentação em janelas equivalentes a um número fixo de períodos elétricos; (iii) extração de atributos; (iv) treinamento das redes neurais MLP especialistas, com normalização (*StandardScaler*); e (v) diagnóstico da saúde da máquina, em que cada janela é submetida à rede neural correspondente à sua bancada.

Esta organização metodológica permite o diagnóstico de múltiplos tipos de defeito, preservando a especialização física dos atributos e evitando influência de bancadas distintas nos resultados obtidos.

4.5 Pré-Processamento

O processamento do sinal de corrente elétrica inicia-se com a segmentação temporal em janelas de análise definidas em função do número de períodos da frequência fundamental da rede elétrica. A frequência fundamental é detectada automaticamente a partir do sinal de corrente de uma fase, e o tamanho da janela em amostras é calculado pelo produto entre a frequência detectada e o número de períodos configurado para a bancada experimental, tornando a segmentação adaptativa a variações.

A escolha do número de períodos influencia a quantidade de informação contida em cada bloco. Janelas curtas, de 1 a 2 períodos, proporcionam resposta mais rápida do sistema,

possibilitando detecção em tempo quase real, porém com menor resolução espectral. Janelas mais longas oferecem mais amostras, permitindo maior resolução espectral e discriminação mais precisa de componentes harmônicas características de defeitos, ao custo de maior latência na resposta.

A estratégia de segmentação utiliza janelas consecutivas, processando blocos sequenciais do sinal de corrente. Esta abordagem permite análise contínua do motor em operação, gerando diagnósticos atualizados a cada nova janela processada.

4.6 Extração de Atributos

A extração de atributos constitui etapa responsável por transformar o sinal de corrente elétrica bruto em um conjunto de características numéricas representativas do estado operacional do motor, reduzindo a dimensionalidade dos dados. Diferentemente de abordagens que extraem atributos estatísticos variados, a metodologia proposta fundamenta-se em uma estratégia de extração direcionada pelo conhecimento. Os atributos extraídos são determinados com base na análise teórica apresentada no Capítulo 2, a qual estabelece correlações diretas entre manifestações específicas de cada tipo de defeito e características mensuráveis no sinal de corrente elétrica.

A intenção dessa abordagem orientada pelo conhecimento físico, em relação a métodos puramente estatísticos, é reduzir a quantidade de atributos desde o início do processamento, minimizando custos computacionais de extração e de memória, permitir entrada mais sólida no modelo de rede neural, e a compreensão clara dos fenômenos eletromagnéticos que estão sendo monitorados. A extração opera sobre a corrente elétrica das três fases, podendo processá-las individualmente ou de forma combinada, conforme a natureza física de cada atributo, por exemplo, o vetor de Park, que sintetiza as três fases em um único sinal. O conjunto total de atributos extraídos é determinado pela união dos atributos relevantes para cada um dos tipos de defeitos investigados, resultando em um vetor de características completo para todos os tipos de defeitos. A Tabela 1 lista os atributos preditivos que foram extraídos para o desenvolvimento do sistema.

Tabela 1 - Lista de Atributos Selecionados para o Sistema de Diagnóstico

Atributo Preditivo	Defeito
Amplitude Espectral da Corrente Via MCSA	Barras Quebradas
Amplitude Espectral da Corrente Pós-DWT e TKEO	Barras Quebradas
Amplitude Espectral da Corrente Pós-TOEO	Barras Quebradas
Amplitude Espectral da Corrente Via MCSA	Curto-Circuito entre espiras do estator
Razão de Energia <i>Wavelet</i> Discreta das Correntes	Curto-Circuito entre espiras do estator
Abordagem do Vetor de Park	Curto-Circuito entre espiras do estator
<i>Wavelet Packet Decomposition</i> e Índices de Severidade	Rolamento
Amplitude Espectral da Corrente via MCSA	Rolamento

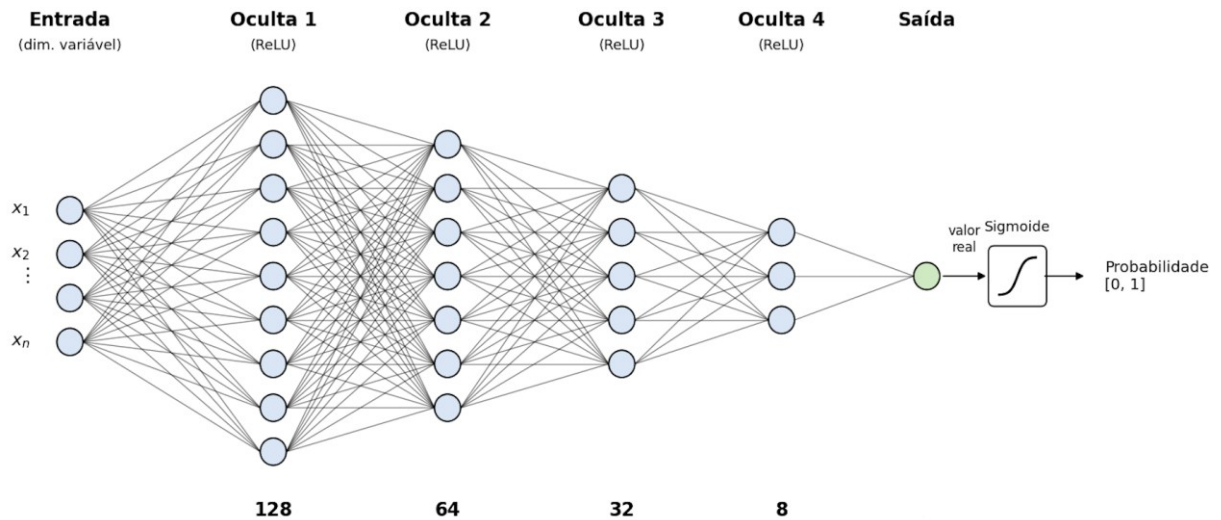
Fonte: Autoria Própria.

4.7 Rede Neural Artificial

O sistema de diagnóstico emprega três modelos de redes neurais artificiais do tipo MLP, cada uma especializada para a detecção de um tipo específico de defeito. Podem ser estabelecidas diferentes configurações de rede neural a depender do tipo de defeito. A arquitetura MLP foi selecionada devido à sua comprovada capacidade de aproximar funções não lineares complexas (Russell; Norvig, 2021) e ao desempenho superior a 99,8% demonstrado em trabalhos preliminares de detecção de barras quebradas (Queiroz; Maciejewski, 2025).

Cada rede neural estrutura-se em cinco camadas sequenciais. A camada de entrada possui dimensão variável, determinada pelo número de atributos selecionados para o tipo específico de defeito. Seguem-se quatro camadas ocultas totalmente conectadas, contendo respectivamente 128, 64, 32 e 8 neurônios, todas com função de ativação ReLU, representado na Figura 28. Essa configuração piramidal decrescente permite que as primeiras camadas aprendam representações generalizadas do sinal de entrada, enquanto as camadas subsequentes refinam progressivamente essas representações até a decisão final (Russell; Norvig, 2021).

Figura 28 – Representação de Arquitetura da Rede Neural



Fonte: Autoria Própria.

A camada de saída contém um único neurônio sem função de ativação, produzindo um valor real que é convertido em probabilidade pela função sigmoide durante o treinamento e a inferência. A saída resultante, no intervalo $[0, 1]$, representa a probabilidade estimada da presença do defeito para o qual a rede foi treinada: valores próximos a zero indicam alta probabilidade na ausência do defeito, enquanto valores próximos a 1 sinalizam alta probabilidade na sua presença. O desempenho de cada especialista é estimado por validação cruzada estratificada (*StratifiedGroupKFold*) com 5 *folds*, agrupados por arquivo de origem.

4.8 Estratégia de Treinamento

O treinamento de cada rede neural especializada é conduzido de forma independente, utilizando exclusivamente as amostras provenientes da bancada experimental correspondente à sua especialidade. Para a MLP especializada em um tipo de defeito i , o conjunto de dados utilizado é particionado em duas classes. A classe 1 contém amostras da bancada i com o defeito presente, enquanto a classe 0 contém amostras saudáveis dessa mesma bancada. Esta organização garante que cada rede aprenda a discriminar entre estado saudável e defeituoso dentro do mesmo contexto experimental, evitando que diferenças intrínsecas entre bancadas (motores, instrumentação e condições operacionais distintas) sejam interpretadas como assinatura de defeito.

Um desafio inerente a esta estrutura reside no desbalanceamento de classes, cuja intensidade varia conforme a quantidade de experimentos de motores saudáveis e de defeituosos disponíveis em cada bancada. O desbalanceamento pode induzir viés no classificador, levando-

o a favorecer a classe majoritária. Para mitigar este efeito, emprega-se a técnica de *oversampling* sintético chamado SMOTE (*Synthetic Minority Over sampling Technique*), que gera amostras artificiais da classe minoritária por interpolação entre amostras vizinhas no espaço de atributos, aproximando as proporções entre as classes no conjunto de treinamento. O SMOTE é aplicado exclusivamente sobre o subconjunto de treino, após a formação dos atributos.

O conjunto total de dados é dividido em três subconjuntos disjuntos: treinamento, validação e teste, nas proporções de 50%, 25% e 25%, respectivamente. A divisão emprega estratificação por classe, subtipo de defeito e condição de carga, mantendo a diversidade experimental em todas as partições. O subconjunto de treinamento é utilizado para ajuste dos pesos da rede neural mediante o algoritmo de retropropagação. O subconjunto de validação monitora a evolução do desempenho a cada época, orientando o critério de parada do treinamento. O subconjunto de teste, que não participa de nenhuma etapa do treinamento ou validação, é reservado exclusivamente para a avaliação final do desempenho do modelo treinado, fornecendo estimativa imparcial da acurácia em dados não utilizados.

Para prevenir sobreajuste e reduzir o tempo de treinamento, é implementada a técnica de parada antecipada (*early stopping*) baseada no monitoramento da perda de validação (*validation loss*). Enquanto a perda de validação apresentar tendência decrescente, o treinamento prossegue. Caso a perda de validação não apresente melhoria por 15 épocas consecutivas, o treinamento é interrompido antecipadamente, e os pesos correspondentes à época com menor perda de validação são restaurados (Queiroz; Maciejewski, 2025). Esta estratégia evita que a rede neural continue ajustando-se excessivamente aos dados de treinamento em detrimento da capacidade de generalização.

4.9 Desenvolvimento de *Software*

O fluxo metodológico descrito nas seções anteriores foi implementado em uma ferramenta computacional unificada, concebida como ambiente experimental para validação da abordagem proposta e como base para o desenvolvimento de um futuro sistema de diagnóstico aplicável em contexto industrial. O *software* centraliza todas as etapas do processo de diagnóstico, desde a extração de atributos dos sinais de corrente até a classificação, permitindo ao usuário configurar parâmetros, visualizar resultados e avaliar o desempenho dos modelos de forma integrada. Essa organização de todo o processo em uma única aplicação viabiliza a realização de testes, facilitando a identificação de limitações e o refinamento da ferramenta e dos atributos.

O sistema constitui uma atualização do *software* desenvolvido anteriormente (Queiroz; Maciejewski, 2025). A versão anterior, validada para detecção de barras quebradas, forneceu a base para o fluxo de dados e o design da interface, que foram expandidos e modificados para contemplar o diagnóstico de múltiplos defeitos. As duas principais modificações consistiram na substituição dos atributos estatísticos originais por atributos especializados por família de defeito, estudados no presente trabalho, e na introdução de dois modos de classificação alternativos: um modelo multiclasse global, com 6 saídas correspondentes às combinações de tipo de defeito e bancada, e um conjunto de três redes neurais binárias independentes no modo especialista, cada uma dedicada à detecção de um tipo específico de defeito, barras rotóricas quebradas, curto-circuito entre espiras do estator e defeitos de rolamento. As tecnologias empregadas foram mantidas: a linguagem Python⁷ para implementação do núcleo de processamento, a biblioteca PySide6⁸ para construção da interface gráfica e o *framework* TensorFlow⁹ para definição e treinamento dos modelos de aprendizado de máquina.

A interface gráfica tem papel fundamental como ferramenta experimental, facilitando o manejo e a escolha dos atributos, além da visualização do comportamento dos modelos durante o treinamento e os testes. O sistema organiza suas funcionalidades em quatro abas. A aba de dados e extração é responsável pela validação dos arquivos CSV de entrada e pela geração do conjunto de atributos, permitindo ao usuário selecionar, dentre os atributos disponíveis, quais são calculados e armazenados. A aba de treinamento permite carregar o conjunto de atributos extraído, definir o subconjunto utilizado para o ajuste dos pesos e treinar os modelos no modo multiclasse global ou no modo especialista, exibindo curvas de aprendizado, matriz de confusão e métricas por classe ao final. A aba de teste é destinada à avaliação dos modelos treinados sobre bancos de dados selecionados, possibilitando a execução de baterias de testes e a análise estatística de desempenho, incluindo matriz de confusão e métricas por classe nos níveis de bloco e de arquivo em uma tabela. A aba de diagnóstico, voltada ao uso final de todo o processo, permite a importação de arquivos CSV contendo dados de corrente elétrica e retorna o diagnóstico simulando aquisição em tempo real, processando o sinal em blocos com velocidade de simulação configurável.

Nesta última, os resultados são apresentados por meio de um painel de visualização composto pela forma de onda da janela em análise, pelo espectro de frequências via transformada de Fourier e pelas probabilidades por classe exibidas em barras horizontais. O

⁷ <https://www.python.org>

⁸ <https://pypi.org/project/PySide6/>

⁹ <https://www.tensorflow.org>

diagnóstico consolidado é apresentado em uma janela com indicação textual da condição detectada, motor saudável ou o tipo de defeito identificado, acompanhado de um indicador de confiança. Um limiar de confiança configurável permite filtrar resultados incertos, e uma média móvel sobre os blocos mais recentes reduz oscilações visuais durante a simulação. Essa organização visa separar o ambiente de desenvolvimento e refinamento dos modelos do ambiente de uso operacional simulado. As abas do *software* desenvolvido são apresentadas na seção 5.2.1 de resultados.

4.10 Método de Refinamento de Atributos

A natureza exploratória deste trabalho exige uma abordagem metodológica flexível, que permite incorporar ajustes ao longo do processo experimental. Diferentemente de metodologias que definem um conjunto fixo de atributos, o presente estudo adota um refinamento que permite a adaptação do conjunto de características com base nos resultados obtidos. Esta abordagem se dá devido a possibilidade de a eficácia de cada atributo não ser a esperada entre os tipos de defeitos investigados para os bancos de dados escolhidos, justificando a necessidade de um processo sistemático de validação e ajuste.

Antes da implementação no *software*, cada atributo selecionado passou por uma etapa de validação no MATLAB¹⁰. Esta análise preliminar tem como objetivo verificar se os atributos extraídos reproduzem os padrões descritos na literatura quando aplicados aos bancos de dados utilizados. Por exemplo, se determinado artigo indica que a amplitude de uma banda lateral específica aumenta na presença de barras quebradas, a validação deve confirmar que este comportamento se manifesta nos dados experimentais utilizados neste trabalho.

Esta etapa permite identificar precocemente atributos problemáticos, seja por não apresentarem o padrão esperado, seja por gerarem resultados inconsistentes em diferentes condições de operação. A detecção antecipada de tais problemas evita que atributos inadequados sejam incorporados ao *software*, onde a identificação da causa de baixo desempenho seria mais complexa de se identificar.

O processo de integração ao *software* estrutura-se em ciclos compostos por quatro etapas sequenciais: configuração, treinamento, avaliação e decisão. Na etapa de configuração, define-se o conjunto de atributos a ser testado, com base nos resultados preliminares dos atributos característicos validados no MATLAB¹⁰. A etapa de treinamento executa o procedimento descrito na seção 4.8, utilizando a arquitetura MLP e a estratégia de divisão dos

¹⁰ <https://www.mathworks.com/products/matlab.html>

dados em conjuntos de treino, validação e teste. A etapa de avaliação quantifica o desempenho do classificador mediante métricas como acurácia e distribuição na matriz de confusão. A etapa de decisão determina se os resultados são satisfatórios ou se modificações no conjunto de atributos são necessárias.

A avaliação do desempenho de cada classificador especializado fundamenta-se em métricas que permitem avaliar capacidade classificatória do sistema. A perda de validação, analisada durante o treinamento, a acurácia geral e por classe que quantifica a proporção de classificações corretas em relação ao total de amostras avaliadas, fornecendo uma visão global do desempenho e a utilização de matriz confusão para verificar a distribuição de classificação entre os diferentes tipos de defeitos.

A matriz de confusão constitui o instrumento central de análise, permitindo visualizar como as classificações se distribuem entre acertos e erros para cada classe. A partir desta matriz, quantificam-se os falsos positivos, situações em que o sistema indica defeito quando o motor está saudável, e os falsos negativos, situações em que o sistema não detecta um defeito existente. No contexto de manutenção preditiva, os falsos negativos representam maior risco, pois defeitos não detectados podem evoluir para falhas. Por outro lado, taxas elevadas de falsos positivos geram intervenções desnecessárias e custos operacionais adicionais. O equilíbrio entre estes dois tipos de erro orienta as decisões de refinamento do conjunto de atributos.

Quando a acurácia obtida se encontra abaixo do limiar de 90%, procede-se à investigação do conjunto de atributos. As seguintes questões orientam esta análise:

- Algum atributo, que não representa adequadamente o defeito, está confundindo o classificador?
- O conjunto de atributos é insuficiente para caracterizar adequadamente o defeito?

Com base nas respostas ações podem ser tomadas. A remoção de atributos aplica-se quando determinado atributo não apresenta padrão discriminativo consistente na validação. A adição de atributos é necessária quando o conjunto existente não é suficiente para capturar adequadamente as manifestações do defeito, exigindo retorno à literatura para identificação de características complementares.

5 RESULTADOS E DISCUSSÕES

5.1 Resultados do Refinamento de Atributos

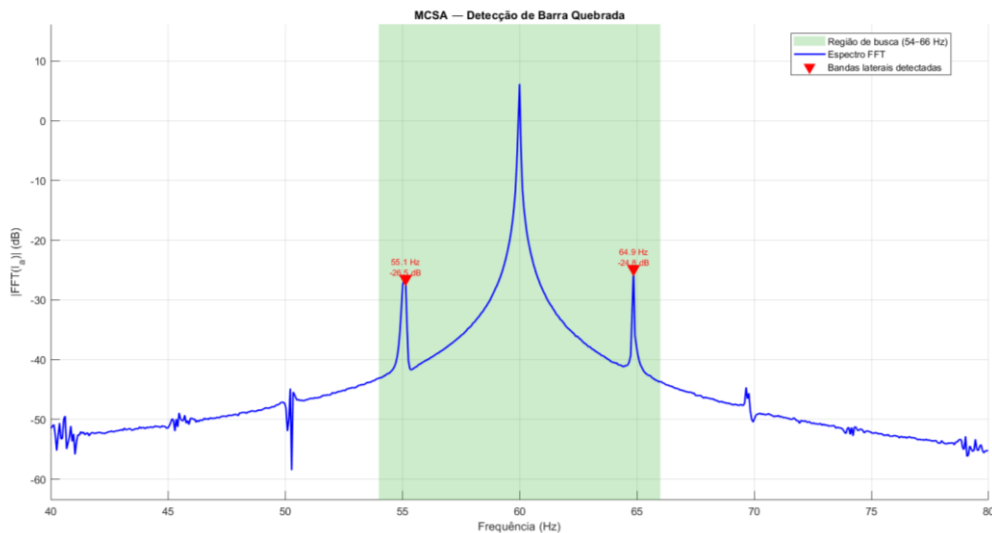
5.1.1 Detecção de Barras Quebradas

Os resultados apresentados nesta seção foram obtidos a partir do banco de dados público disponibilizado por Trembl et al., (2020) adquirido nos laboratórios LAIPS e LACIME da USP São Carlos, detalhados na seção 4.1. Foram utilizados exclusivamente sinais em regime permanente, segmentados em janelas temporais.

5.1.1.1 MCSA

A técnica MCSA foi aplicada no MATLAB considerando as bandas laterais de primeira ordem ($k = 1$) e uma janela de mil períodos para busca espectral em torno da frequência fundamental da corrente do estator, dadas pela equação 17. O algoritmo implementado realiza a busca espectral considerando a faixa de escorregamento de 0% a 5%, o que resulta em frequências no intervalo de 54 a 66 Hz. A Figura 29 ilustra o espectro obtido e a região de busca com a aplicação do algoritmo à corrente do estator do motor de um experimento pertencente ao banco de dados.

Figura 29 – Espectro da Corrente do Estator do Motor com 4 Barras Quebradas e Torque Nominal.



Fonte: Autoria Própria.

Observa-se que as bandas laterais se encontram afastadas da frequência fundamental. O efeito inverso ocorre quando o escorregamento diminui, quanto menor o carregamento do motor, menor o escorregamento e, conseqüentemente, mais próximas da frequência fundamental as bandas laterais de barra quebrada se situam (Agah et al., 2022). O algoritmo foi

aplicado em 10 experimentos para cada faixa de torque, a Tabela 2 apresenta as amplitudes médias das componentes de defeito identificadas para cada nível de severidade e condição de torque.

Tabela 2 - Amplitude Média das Bandas Laterais de Barra Quebrada com MCSA

Torque (N.m)	Rotor Saudável (dB)	1 Barra quebrada (dB)	2 Barra quebradas (dB)	3 Barras quebradas (dB)	4 Barra quebradas (dB)
0,5	-44,27	-47,57	ø ¹¹	-38,13	-29,37
1	-42,46	-38,30	-37,20	-35,01	-32,08
1,5	-42,69	-38,78	-35,34	-33,70	-31,26
2	-45,10	-39,17	-34,53	-32,18	-29,42
2,5	-41,32	-37,50	-34,48	-30,52	-28,70
3	-42,43	-37,91	-33,80	-30,09	-27,07
3,5	-43,09	-37,38	-32,08	-28,39	-25,84
4	-43,74	-37,01	-30,81	-27,79	-24,85

Fonte: Autoria Própria.

Os resultados indicam que a técnica demonstrou eficácia satisfatória em condições de carregamento próximo ao nominal, com diferenças de amplitudes médias entre rotor saudável e com defeito variando de 4,5 dB (cenário de menor severidade) até 18,9 dB (cenário de maior severidade). Entretanto, a discriminação torna-se problemática em baixo torque, particularmente nas condições de uma e duas barras quebradas, onde o algoritmo não foi capaz de detectar as bandas laterais com consistência, onde não havia proeminência suficiente e as frequências características de defeito ficaram muito próximas a da fundamental. Esse comportamento é evidenciado por dois casos na Tabela 2, na condição de duas barras quebradas sob torque de 0,5 N.m, nenhuma banda lateral foi detectada pelo algoritmo, e no cenário de uma barra quebrada, a amplitude média registrada de -47,57 dB ficou consideravelmente afastada dos demais valores, indicando detecção inconsistente. Esse comportamento é esperado, visto que o escorregamento reduzido aproxima as bandas laterais da componente fundamental, reduzindo a separação espectral e evidenciando a limitação da MCSA em regimes de baixa carga (Agah et al., 2022).

5.1.1.2 DWT + TKEO

O método proposto por Agah et al., (2022), foi implementado no MATLAB conforme descrito na Seção 2.4.1.2. A DWT com *Wavelet* db45 decompõe a corrente do estator, sendo selecionados os coeficientes cujas faixas de frequência englobam as frequências de defeito de barra quebrada. Em seguida, o TKEO é aplicado ao sinal e o resultado é normalizado. Por fim,

¹¹ O algoritmo não identificou amplitude espectral distinguível do ruído de fundo

a FFT do sinal é calculada e a faixa de busca espectral é definida considerando escorregamento de 0% a 5%, resultando em uma faixa 0 a 6 Hz para f_0 , frequência de defeito no espectro.

Tabela 3 – Amplitude Média das Bandas Laterais de Barra Quebrada com DWT + TKEO

Torque (N.m)	Rotor Saudável (dB)	1 Barra quebrada (dB)	2 Barra quebradas (dB)	3 Barras quebradas (dB)	4 Barra quebradas (dB)
0,5	-45,95	-42,10	-37,26	-33,77	-30,84
1	-46,43	-39,39	-33,12	-28,78	-26,96
1,5	-49,91	-39,17	-31,49	-29,14	-26,35
2	-53,63	-37,46	-32,35	-27,64	-25,25
2,5	-52,37	-38,39	-32,61	-27,97	-27,79
3	\emptyset^{11}	-40,10	-34,66	-31,98	-27,78
3,5	-53,75	-44,61	-38,23	-33,74	-32,32
4	-53,48	-50,34	-42,97	-40,64	-37,67

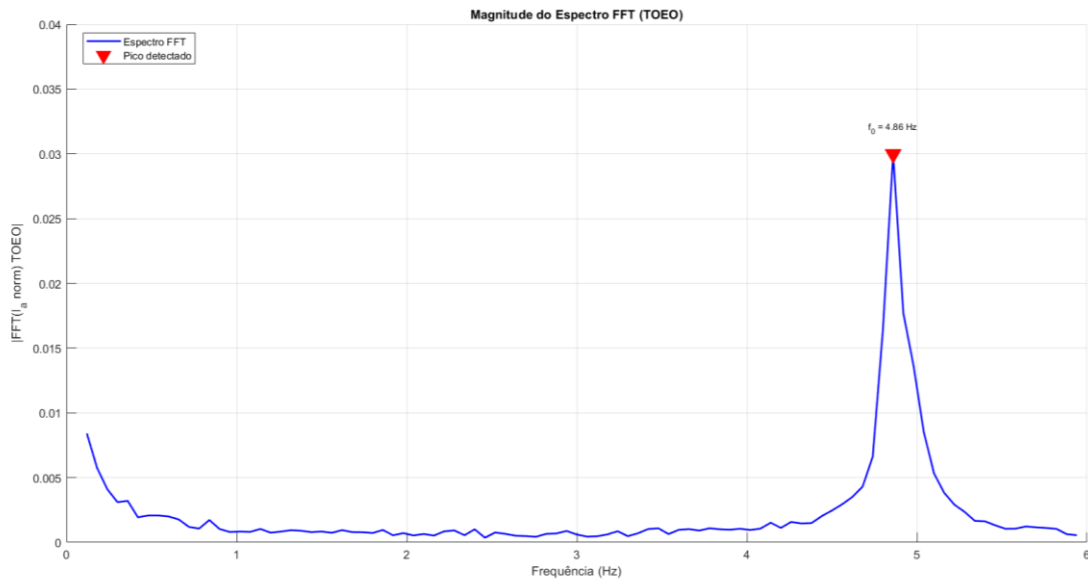
Fonte: Autoria Própria.

A Tabela 3 apresenta os resultados obtidos. Em condições de baixo torque (0,5 a 1,5 N.m), as diferenças de amplitude variam de 3,85 dB no cenário de menor severidade até 23,56 dB no de maior severidade. Além disso, o algoritmo demonstrou maior consistência na detecção espectral em baixo carregamento em comparação à MCSA, evidenciando a complementaridade entre os dois métodos, uma vez que a MCSA se demonstrou mais consistente em cenários de carregamento próximo ao nominal.

5.1.1.3 TOEO

O TOEO foi implementado no MATLAB e aplicado diretamente sobre a corrente do estator por meio da equação 16, sendo o sinal resultante normalizado. A amplitude espectral é extraída na faixa de 0 a 6 Hz, considerando 0 a 5% para o cálculo de f_0 . A Figura 30 ilustra o espectro obtido com a aplicação do algoritmo à corrente do estator de um motor do banco de dados.

Figura 30 - Espectro da Corrente do Estator do Motor com 3 Barras Quebradas após Aplicação do TOEO



Fonte: Autoria Própria.

Em seguida, os valores da FFT são calculados em dB para fins de comparação com os outros métodos.

Tabela 4 - Amplitude Média das Bandas Laterais de Barra Quebrada com TOEO

Torque (N.m)	Rotor Saudável (dB)	1 Barra quebrada (dB)	2 Barra quebradas (dB)	3 Barras quebradas (dB)	4 Barra quebradas (dB)
0,5	-37,19	-30,63	-34,66	-29,03	-24,53
1	-36,30	-28,51	-31,03	-25,74	-20,70
1,5	-36,79	-28,89	-28,46	-25,95	-20,58
2	-38,35	-27,94	-28,61	-24,04	-19,53
2,5	-37,59	-28,94	-28,16	-23,55	-21,93
3	-39,97	-30,16	-29,20	-26,55	-21,13
3,5	-41,02	-33,01	-31,51	-26,55	-23,54
4	-43,53	-34,16	-34,51	-30,02	-26,06

Fonte: Autoria Própria.

Na Tabela 4 são apresentados os resultados obtidos. A distinção entre rotor saudável e rotor com defeito de barra quebrada mostrou-se consistente na maioria dos cenários analisados. Em condições de baixo carregamento (0,5 N·m a 1,5 N·m), as diferenças de amplitude variaram de 6,56 dB (cenário de menor severidade) até 18,82 dB (cenário de maior severidade). Para carregamentos próximos ao nominal (3,0 N·m a 4,0 N·m), as diferenças situaram-se entre 9,81 dB e 18,84 dB, respectivamente.

Entretanto, a amplitude não aumentou em magnitude progressivamente em função do número de barras quebradas. Observou-se que a condição com duas barras quebradas apresentou amplitude inferior à de uma barra quebrada nas cargas de 0,5 N·m, 1,5 N·m e 4,0

N·m, indicando variabilidade na discriminação entre essas duas severidades. Ainda assim, o método TOEO foi o único capaz de detectar componentes espectrais em todos os cenários analisados, sem valores ausentes e mantendo diferenças consistentes de amplitude, o que reforça sua caracterização como a abordagem mais completa para a detecção de barras quebradas entre os três métodos avaliados.

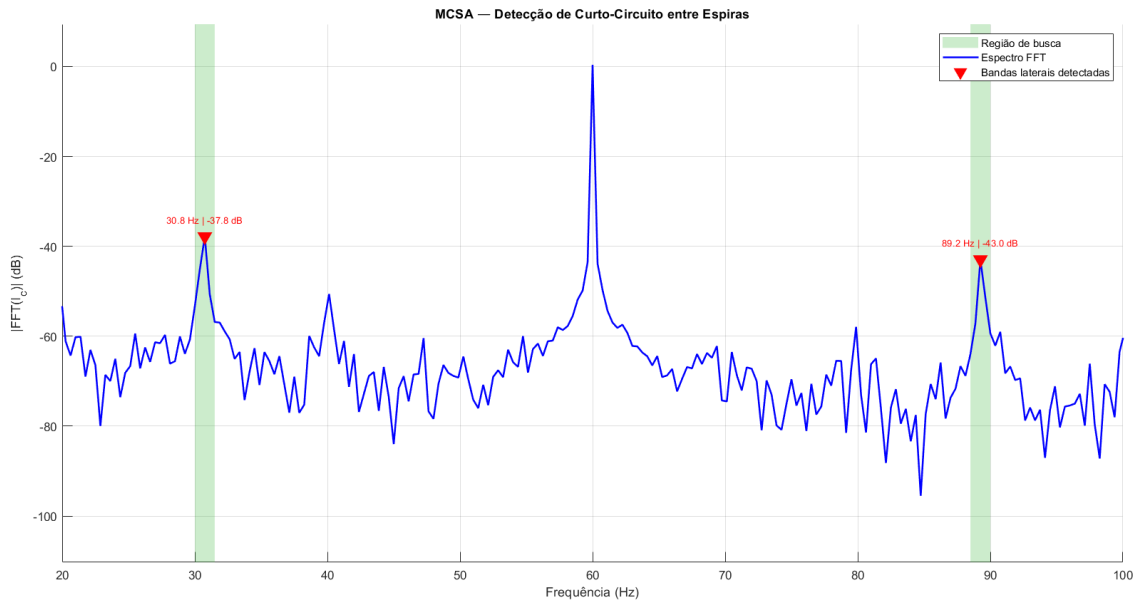
5.1.2 Detecção de Curto-Circuito Entre Espiras do Estator

Os resultados desta seção foram obtidos com o banco de dados disponibilizado por Cunha, Junior e Medeiros (2020), descrito na seção 4.2, composto por correntes trifásicas de um motor de indução de 1 HP rebobinado para emulação controlada de curtos-circuitos entre espiras. Foram analisadas quatro condições: motor saudável (H) e três severidades de defeito correspondentes a 1,41% (LI1), 4,81% (LI2) e 9,26% (LI3) das espiras em curto-circuito, sob carregamentos de 0%, 50% e 100% da carga nominal. Foram utilizados exclusivamente sinais em regime permanente, segmentados em janelas temporais.

5.1.2.1 MCSA

A técnica MCSA foi aplicada no MATLAB considerando as componentes espectrais características de curto-circuito entre espiras, dadas pela Equação 18. O algoritmo implementado realiza a busca espectral para $n = 1$, considerando a faixa de escorregamento de 0% a 5%, o que resulta em dois intervalos de busca: faixa superior entre 88,5 e 90 Hz e faixa inferior entre 30,0 e 31,5 Hz. A Figura 31 apresenta o espectro obtido nas análises do método.

Figura 31 - Espectro da Corrente do Estator do Motor com 9,26% das Espiras em Curto-Circuito e 50% de Carregamento



Fonte: Autoria Própria.

O algoritmo foi aplicado ao banco de dados completo, identificando o pico de maior amplitude dentro de cada faixa de busca para as três fases da corrente do estator. A Tabela 5 apresenta as amplitudes médias das componentes identificadas para cada nível de severidade e carregamento.

Tabela 5 - Amplitude Média das Bandas Laterais de Curto-Circuito com MCSA

Carregamento	Rotor			
	Saudável (dB)	LI1 (dB)	LI2 (dB)	LI3 (dB)
L000 (0%)	-40,24	-35,75	-37,03	-34,01
L050 (50%)	-39,39	-41,11	-39,76	-41,59
L100 (100%)	-45,65	-46,40	-44,93	-46,76

Fonte: Autoria Própria.

Em condição sem carga (L000), a técnica demonstrou capacidade de separação entre motor saudável e motor com defeito, com diferenças de amplitude variando de 3,2 dB (LI2) a 6,2 dB (LI3). Para a condição de meia carga (L050) e carga nominal (L100), o método demonstrou-se limitado, com as amplitudes espectrais entre motor saudável e motor com defeito se aproximando, tornando inviável a discriminação. Além disso, notou-se a ausência de assimetria entre fases. Em todos os experimentos analisados, as três fases da corrente do estator apresentaram amplitudes próximas nas faixas de busca, tanto para o motor saudável quanto para as condições de defeito. Esse comportamento indica que o MCSA individual por fase não


capturou o desequilíbrio entre as fases, característico do curto-circuito entre espiras nas faixas espectrais analisadas.

A ausência de distinção entre fases e a degradação do método sob carga evidenciam que o MCSA aplicado isoladamente é insuficiente para a detecção de curto-circuito entre espiras nas condições ensaiadas. Esses resultados motivam a investigação de técnicas complementares, como a EDWT, abordada nas próximas seções.

5.1.2.2 Análise do Vetor de Park (PVA)

Para a análise do vetor de Park, as componentes id e iq foram calculadas a partir das correntes trifásicas segmentadas em regime permanente, e a trajetória resultante foi plotada no plano $d - q$. As medidas dos semi-eixos menor e maior da elipse foram extraídas para o cálculo do fator de excentricidade, definido como a razão entre o semi-eixo menor e o semi-eixo maior da elipse formada pelo vetor de Park (Parra et al., 2013). A Figura 32 ilustra a trajetória da corrente de Park no plano $d - q$ para as diferentes severidades de defeito.

Figura 32 – Elipses Formadas pela Corrente de Park nos Eixos d e q .



Fonte: Autoria Própria.

Tabela 6 - Fatores de Excentricidade Médio Obtidos Analisando as Elipses Produzidas

Carregamento (%)	H	LI1	LI2	LI3
0	0,340	0,331	0,280	0,211
50	0,341	0,332	0,274	0,211
100	0,347	0,338	0,293	0,232

Fonte: Autoria Própria.

A Tabela 6 apresenta os fatores de excentricidade obtidos para as diferentes condições de carregamento e severidade de defeito. Observa-se uma tendência de redução do fator de excentricidade com o aumento da severidade em todos os níveis de carregamento. LI1 permanece consistentemente próximo ao motor saudável nos três carregamentos, indicando baixa sensibilidade do método para falhas incipientes. A separação entre condições torna-se mais pronunciada a partir de LI2, sugerindo que a PVA é adequada para detecção de severidades intermediárias e avançadas.

5.1.2.3 Razão de Energia de *Wavelet*

Para a extração dos atributos de razão energética dos coeficientes *Wavelet*, o sinal de corrente de cada fase foi analisado no regime permanente correspondente. A DWT foi aplicada com a *Wavelet* db44 e o coeficiente de detalhe cuja faixa de frequência contém a fundamental de 60 Hz foi selecionado para o cálculo de energia. A energia associada a esse coeficiente foi calculada para cada fase, e os três atributos foram obtidos pelas razões entre as energias das fases dois a dois, conforme definido na Equação 19. A Tabela 7 apresenta os valores médios das razões energéticas para cada condição e carregamento.

Tabela 7- Razões Energéticas Médias Entre os Coeficientes da Decomposição *Wavelet*

Carga (%)	H			L1			L2			L3		
	E1	E2	E3	E1	E2	E3	E1	E2	E3	E1	E2	E3
0	1,18	0,95	0,99	1,02	0,94	1,15	0,85	0,58	2,23	0,49	0,43	5,42
50	1,14	1,14	0,98	1,19	1,12	0,93	0,74	0,82	2,12	0,32	0,64	6,23
100	1,21	0,90	1,11	1,13	0,98	1,20	0,84	0,89	1,67	0,41	0,86	3,82

Fonte: Autoria Própria.

Por serem razões entre fases, esses atributos carregam informação não apenas sobre a presença do defeito, mas também sobre o desequilíbrio energético entre as fases, permitindo a localização do defeito.

Para o motor saudável, os três atributos mantiveram-se razoavelmente próximos à unidade em todos os níveis de carregamento, indicando equilíbrio energético entre as fases. Com o aumento da severidade, E3 elevou-se progressivamente, atingindo médias maiores em LI2 e LI3. Para LI1, os valores permaneceram próximos aos da condição saudável, indicando insensibilidade do método a essa severidade.

O método demonstrou eficácia na detecção e localização de defeito para as severidades LI2 e LI3, identificando a fase C como a fase cujas espiras apresentavam-se curto-circuitadas. A insensibilidade em LI1 é coerente com os demais métodos analisados e pode ser atribuída à natureza incipiente do defeito nessa severidade, cujas alterações energéticas no sinal de corrente são de pequena magnitude.

5.1.3 Detecção de Defeitos em Rolamentos

Os resultados desta seção apresentam a validação preliminar dos atributos diagnósticos para detecção de defeitos em rolamentos, obtidos a partir do banco de dados por (Jung et al., 2023), descrito na seção 4.3. Foram utilizados sinais de corrente trifásica adquiridos na condição de velocidade constante de 3010 RPM no eixo do rolamento NSK 6205 DDU, sob três níveis de torque (0, 2 e 4 N·m), contemplando as condições de defeito na pista interna e na pista externa.

5.1.3.1 MCSA

O MCSA foi aplicado mediante análise espectral via FFT em segmentos do sinal de corrente, distribuídos ao longo de cada arquivo para reduzir a influência de variações estacionárias locais sobre os atributos. As amplitudes das componentes espectrais de defeito foram normalizadas pela amplitude da fundamental, procedimento necessário para remover o efeito da variação de carga sobre o espectro e permitir comparação entre condições operacionais distintas.

Foram avaliados defeitos de pista interna (BPFI) e externa do rolamento (BPFO), conforme as equações 23 e 24, as frequências de interesse foram calculadas para $k = 1, 2$ e 3 para cada defeito. Para acomodar variações dimensionais do rolamento, aplicou-se tolerância de $\pm 8\%$ nos parâmetros geométricos D_b e D_c no cálculo das frequências teóricas, resultando em intervalos de busca adaptados para cada banda. A análise abrangeu as condições Normal, BPFI (3,0 mm) e BPFO (3,0 mm) nos três níveis de torque (0, 2 e 4 N·m).

A análise sistemática das bandas de interesse identificou separação diagnóstica em dois cenários. Em 0 N·m, a componente $|f_s - f_{inner}|$, correspondente à banda lateral inferior de defeito de pista interna do rolamento, dada pela Equação 25, normalizada pela fundamental, apresentou separação consistente entre as condições Normal e *Fault*. Em 4 N·m, a amplitude relativa do terceiro harmônico direto da frequência de defeito de pista externa, dada pela Equação 24, também normalizada pela fundamental, apresentou separação de

aproximadamente 7 dB entre Normal e *Fault*. Em 2 N·m nenhuma das bandas avaliadas produziu atributo diagnóstico confiável. Cabe destacar que a análise adotou distinção binária entre condição saudável e condição de defeito, sem discriminação entre defeito de pista interna e pista externa. Os resultados evidenciam que a MCSA por FFT apresenta separabilidade limitada para defeitos de rolamento na severidade avaliada, com eficácia restrita a faixas específicas de torque, o que reforça a necessidade de abordagens complementares como a WPD.

5.1.3.2 WPD

O método WPD foi aplicado seguindo a metodologia de Nasiri et al. (2025). Para cada segmento, foram identificados os nós da árvore de decomposição correspondentes às componentes espectrais de interesse dos defeitos de rolamento interno e externo. De cada nó foram extraídos oito atributos, sendo variância, desvio padrão e energia dos coeficientes WPD, variância e desvio padrão do espectro FFT, e variância, desvio padrão e energia da densidade espectral de potência (PSD). Com oito componentes espectrais avaliadas, o vetor de atributos totalizou 64 entradas por segmento. Em etapa posterior, os atributos foram normalizados e agregados para o cálculo do índice de severidade conforme proposto por Nasiri et al. (2025).

Tabela 8 - Índices de Severidade Calculados para cada Severidade e Torque

Defeito	Severidade (mm)	Saudável		Defeito		Saudável		Defeito	
		0N·m	0N·m	2N·m	2N·m	4N·m	4N·m	4N·m	4N·m
BPFI	3,0	58,06	53,87	55,57	61,62	56,73	60,83		
BPFI	10,0	61,49	57,35	57,47	56,96	48,04	63,29		
BPFI	30,0	56,00	54,97	55,96	58,20	55,19	61,73		
BPFO	3,0	55,94	58,93	51,69	63,53	58,59	53,46		
BPFO	10,0	47,11	62,89	51,18	63,17	51,66	62,54		
BPFO	30,0	43,88	63,66	48,49	63,84	51,79	63,30		

Fonte: Autoria Própria.

Conforme a Tabela 8, para BPFO, o índice de severidade da condição de defeito superou o da condição saudável em todas as combinações de severidade e torque avaliadas, indicando separação diagnóstica consistente. Para BPFI, esse comportamento se manteve em 2 e 4 N·m, porém em 0 N·m o índice da condição saudável superou sistematicamente o da condição de defeito nas três severidades, comportamento inverso ao esperado e que inviabiliza o uso do método nessa condição operacional. A principal limitação identificada é a dependência de uma referência do motor em operação normal para o cálculo do índice de normalização, o que restringe a aplicabilidade do método em cenários onde não há histórico prévio da condição saudável disponível.

5.2 Resultados do Desenvolvimento do Sistema

A metodologia foi consolidada em uma ferramenta computacional que centraliza a extração de atributos, o treinamento dos três especialistas em cada defeito e a avaliação do desempenho sobre os arquivos de cada bancada experimental. A partir dessa implementação, foi executada uma bateria de testes em massa, para cada especialista, sobre os arquivos selecionados para esta finalidade. Para cada arquivo, o sistema produz um diagnóstico por bloco e por arquivo, acompanhado das probabilidades, acurácias por classe e da matriz de confusão.

Este capítulo apresenta os resultados em duas frentes. A primeira descreve a versão final do *software* e percorre as quatro abas que compõem o fluxo de diagnóstico. A segunda traz a análise quantitativa de desempenho dos três modelos especialistas, organizada por classe, com base nas acurácias por janela experimental, nas matrizes de confusão e na comparação dos resultados entre cinco configurações distintas de atributos.

5.2.1 *Software* Desenvolvido

O *software* foi implementado em Python⁷, com interface gráfica em PySide6⁸ e modelos de aprendizado de máquina baseados no TensorFlow⁹. A ferramenta organiza o fluxo de diagnóstico em quatro abas sequenciais, cada uma associada a uma etapa do processo, da extração de atributos à simulação de diagnóstico em tempo real.

A aba de dados e extração, apresentada na Figura 33, é responsável pela validação dos arquivos CSV de entrada e pelo cálculo dos atributos. O usuário seleciona o diretório com os arquivos de corrente elétrica trifásica, associa as configurações iniciais da bancada experimental ao conjunto de dados e configura o número de períodos da corrente elétrica que define o tamanho da janela de análise, que forma um bloco experimental. A escolha dos atributos é feita por uma janela organizada em grupos separados por família de defeito, na qual cada grupo corresponde a um método de extração descrito no Capítulo 2, como MCSA, TKEO, TOEO, EDWT, PVA ou WPD. Ao iniciar a extração, o *software* detecta automaticamente a frequência fundamental de alimentação a partir de uma fase da corrente elétrica, segmenta o sinal em blocos consecutivos sem sobreposição, calcula a faixa de escorregamento associado e extrai os atributos. O resultado é registrado em uma matriz de atributos acompanhado de um arquivo que documenta toda a configuração utilizada.

Figura 33 – Aba de Dados e Extração

The screenshot shows the 'Dados e Extração' tab in the ASTERION RTD software. The interface is divided into several sections:

- Diretório de Dados:** Shows the current directory path as 'E DADOS/02-APPDATABASE/Treino' and a 'Selecionar Pasta' button.
- Bancada Experimental:** Includes dropdown menus for 'BB' (Barras Rotóricas Quebradas), 'CC' (Curto-Circuito), and 'RL' (Defeito em Rolamento), along with a 'Gerenciar Bancadas...' button.
- Saída:** Displays the file path for the output directory.
- Resumo do Diretório:** A table summarizing the data distribution:

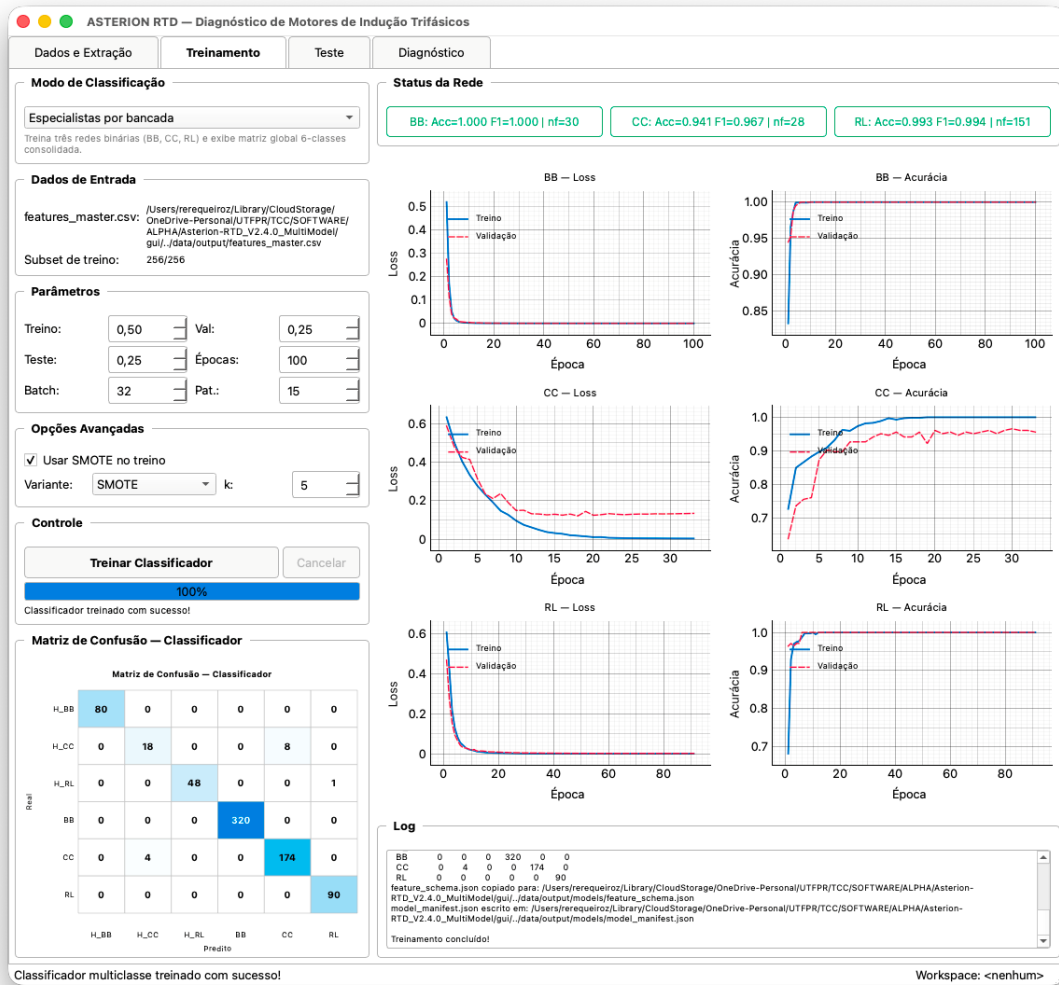
Dataset	Total	H	F	Blocos Est.
BB	280	56	224	1716
CC	273	35	238	919
RL	21	3	18	474
TOTAL	574	94	4...	3109
- Extração de Atributos:** A progress bar shows 100% completion. Below it, a 'Validação OK: 574 arquivo(s) válido(s)' message is displayed, along with 'Validar Dados', 'Extrair Atributos', and 'Cancelar' buttons.
- Seleção de Atributos:** The 'Modo' is set to 'Extração'. It lists 256 attributes to be extracted, categorized into:
 - BB Barra Quebrada:** MCSA (Bandas Laterais), TKEO + DWT, TOEO. Attributes include Sideband k=1 superior/inferior, Sideband k=2 superior/inferior, Sideband k=3 superior/inferior, TKEO-DWT k1 (2sf.), TKEO-DWT k2 (4sf.), TOEO amplitude pico, and TOEO frequência pico.
 - CC Curto-Circuitos:** MCSA (Bandas Laterais CC), EDWT, PVA (Relação b/a). Attributes include Sideband n=1 superior/inferior, Sideband n=2 superior/inferior, Sideband n=3 superior/inferior, Energia DWT (3 fases), RMS DWT (3 fases), and Razão cruzada (3 pares).
 - RL Rolamento:** MCSA (Bandas de Rolamento), WPD (BPFI + BPFO). Attributes include BPFI_INF k=1 (fa - BPFI, rel. fa), BPFI K1-, BPFI K2-, BPFI K1+, BPFI K2+, BPFO_NOM k=3 (3-BPFO, rel. fa), BPFO K1-, BPFO K2-, BPFO K1+, and BPFO K2+.
- Log:** A scrollable log window showing execution details:


```
pva_cc 1.87 s
wpd_r1 57.22 s
mcsa_r1 0.39 s
Extração concluída: 3072 blocos, 574 arquivos, 103.8s
feature_schema.json salvo: /Users/rerequeiroz/Library/CloudStorage/OneDrive-Personal/UTFPR/TCC/SOFTWARE/ALPHA/Asterion-RTD_V2.4.0_MultiModel/gui/.data/output/feature_schema.json
Arquivo salvo: /Users/rerequeiroz/Library/CloudStorage/OneDrive-Personal/UTFPR/TCC/SOFTWARE/ALPHA/Asterion-RTD_V2.4.0_MultiModel/gui/.data/output/features_master.csv
```

Fonte: Autoria Própria.

A aba de treinamento, mostrada na Figura 34, carrega a matriz de atributos gerada na etapa anterior e permite ao usuário definir o subconjunto de treinamento que é utilizado nas redes neurais. O usuário escolhe entre o modo especialista, em que três redes binárias independentes são treinadas, uma para cada tipo de defeito, e o modo multiclasse global, com 6 saídas. São configuráveis as proporções da divisão estratificada em treino, validação e teste, o número máximo de épocas de treinamento, e a paciência da parada antecipada, baseada na perda de validação. Para mitigar o desbalanceamento entre as classes saudável e defeituosa de cada bancada, o usuário pode habilitar o SMOTE e definir o número de vizinhos utilizados na interpolação, técnica que é aplicada exclusivamente sobre o subconjunto de treino. Durante o treinamento, a interface exibe em tempo real as curvas de perda de treino e validação e ao final, apresenta a matriz de confusão e as métricas por classe sobre o conjunto de teste.

Figura 34 – Aba de Treinamento



Fonte: Autoria Própria.

A aba de teste em massa, apresentada na Figura 35, utiliza o modelo treinado para classificar uma pasta completa de arquivos e consolida os resultados em métricas por janela temporal e por arquivo. O usuário indica o diretório da pasta com os arquivos de teste e, opcionalmente, um limiar de confiança abaixo do qual o diagnóstico é marcado como incerto. Para cada arquivo o diagnóstico é obtido pela média das probabilidades de cada bloco. A interface exibe a acurácia global, a acurácia por classe, a matriz de confusão e uma tabela detalhada que lista todos os arquivos com seu diagnóstico, número de janelas processadas e acurácia individual, os resultados podem ser exportados em formato .CSV para análise externa.

Figura 35 – Aba de Teste

The screenshot displays the 'ASTERION RTD - Diagnóstico de Motores de Indução Trifásicos' software interface. It is divided into several sections:

- Pasta de Teste:** Shows the selected folder 'NCO DE DADOS/02-APPDATABASE/Teste' and the number of files: 237.
- Parâmetros:** Includes a schema description and a 'Conf. Threshold' slider set to 0.00.
- Controle:** Features an 'Executar Teste' button, a progress bar at 100%, and 'Exportar CSV' and 'Resetar' buttons.
- Matriz de Confusão:** A heatmap showing classification results for classes 'Saudável', 'BB', 'CC', and 'RL'.

	Saudável	BB	CC	RL
Saudável	235	1	5	0
BB	0	576	0	0
CC	2	0	250	0
RL	0	0	0	126
- Resultados por Arquivo:** A table listing individual test results for various files, including predicted and actual diagnoses and accuracy percentages.

Arquivo	Dataset	Blocos	P_Saud.	P_BB	P_CC	P_RL	Diagnóstico	Real	Acur. Blocos	Correto?
RL_F_BPF1...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPF1...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPF3...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPF3...	RL	7	0.047	0.000	0.000	0.953	RL	RL	100.0%	Sim
RL_F_BPF3...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPF3...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.001	0.000	0.000	0.999	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_F_BPFO...	RL	7	0.000	0.000	0.000	1.000	RL	RL	100.0%	Sim
RL_H_N_0N...	RL	36	1.000	0.000	0.000	0.000	Saudável	Saudável	100.0%	Sim
RL_H_N_2N...	RL	14	0.991	0.000	0.000	0.009	Saudável	Saudável	100.0%	Sim
RL_H_N_4N...	RL	14	1.000	0.000	0.000	0.000	Saudável	Saudável	100.0%	Sim
- Estatísticas (Tempo Real):** Shows an overall accuracy of 99.33% and a breakdown by class:

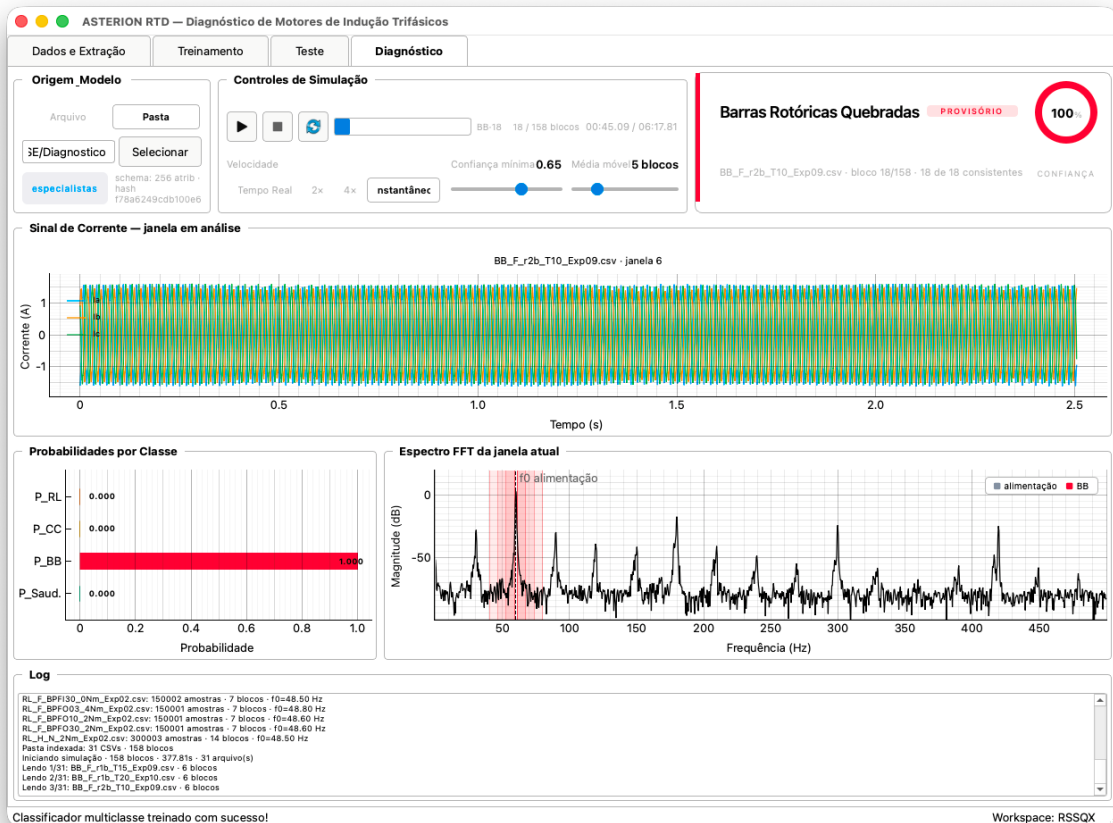
Classe	Acuidade
Saudável	97%
BB	100%
CC	99%
RL	100%
- Log de Teste:** A text log showing detailed accuracy for each file and block, and a summary: 'TESTE CONCLUÍDO! Acuidade por bloco: 99.33%. Total: 237 arquivos, 1195 blocos. Saudável: 97.5%, BB: 100.0%, CC: 99.2%, RL: 100.0%'.

At the bottom, it states 'Classificador multiclasse treinado com sucesso!' and 'Workspace: <nenhum>'.

Fonte: Autoria Própria.

A aba de diagnóstico, mostrada na Figura 36, simula a aquisição de corrente elétrica trifásica em tempo real a partir de um arquivo .CSV ou de uma pasta. O *software* carrega o modelo treinado, o usuário seleciona o diretório e define a velocidade de simulação, que pode reproduzir o tempo real do ensaio ou classificar instantaneamente os blocos experimentais. O sinal é lido em blocos sucessivos, e cada bloco completo é classificado pelo modelo de MLP. A interface apresenta a forma de onda das três fases da corrente elétrica, o espectro da corrente elétrica nas faixas associadas às frequências do defeito detectado e o diagnóstico acumulado pela média das probabilidades dos blocos já processados. Esta aba reproduz o comportamento esperado de uma futura aplicação de monitoramento contínuo, na qual o sistema receberia o sinal de corrente diretamente do motor em operação.

Figura 36 - Aba de Diagnóstico



Fonte: Autoria Própria.

5.2.2 Resultados Gerais dos Testes

Para avaliar a contribuição dos grupos de atributos no desempenho do sistema de diagnóstico, foi utilizado o modo especialista do *software*, onde define uma rede neural para cada tipo de defeito, foram definidas cinco configurações experimentais. Cada configuração consiste em um conjunto de atributos escolhidos entre os três especialistas, sendo eles o especialista em Barras Quebradas (BB), o especialista em Curto-Circuito entre Espiras (CC) e o especialista em Defeito em Rolamento (RL), cada uma opera apenas com seus próprios atributos, sem compartilhamento entre os três. A composição de cada configuração é detalhada na Tabela 9.

Tabela 9 - Grupos de Atributos por Especialista em Cada Configuração Experimental

Configuração	BB	CC	RL
A	MCSA-BB	MCSA-CC	MCSA-RL
B	TKEO-BB	EDWT-CC	WPD-RL
C	TOEO-BB	PVA-CC	WPD-RL
Selecionados	TOEO-BB	MCSA-CC + EDWT-CC	WPD-RL
Todos	MCSA-BB + TKEO - BB + TOEO-BB	MCSA-CC + EDWT-CC + PVA-CC	WPD-RL + MCSA- RL

Fonte: Autoria Própria.

As três primeiras configurações isolam o desempenho individual de cada método de extração. A configuração A utiliza apenas atributos baseados em análise espectral simples, com MCSA-BB para barras quebradas, MCSA-CC para curto-circuito e MCSA-RL para rolamento. A configuração B reúne os métodos fundamentados em decomposições *Wavelet*, com TKEO, EDWT e WPD nos respectivos especialistas. A configuração C agrupa os métodos baseados em operadores de energia e na transformada de Park, com TOEO, PVA e novamente WPD. A configuração de atributos selecionados combina, em cada especialista, os atributos que apresentaram melhor desempenho individual nas três configurações anteriores. A última configuração utiliza todos os atributos simultaneamente, oferecendo à rede neural a representação mais abrangente do sinal de corrente elétrica entre os métodos estudados.

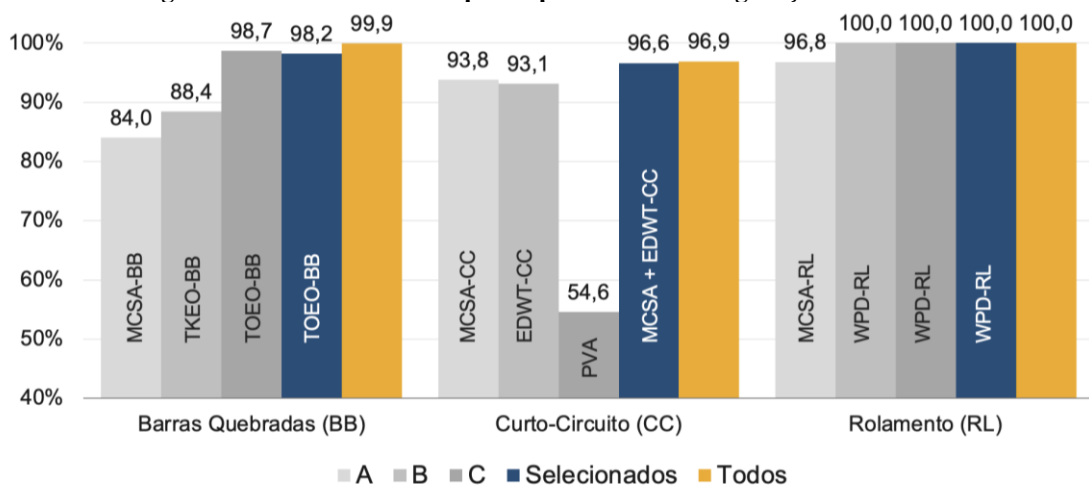
O desempenho de cada configuração foi avaliado por bloco experimental, definida como a proporção de janelas corretamente classificadas em relação ao total de janelas do conjunto de teste para cada classe. A avaliação foi conduzida sobre um conjunto de teste, não utilizado durante o treinamento, distribuídos entre as classes Saudável, Barras Quebradas (BB), Curto-Circuito entre Espiras (CC) e Defeito em Rolamento (RL), abrangendo diferentes condições de operação e severidades de defeito. A Tabela 10 apresenta a acurácia obtida por cada configuração, discriminada por classe e pelo conjunto total de teste. Adicionalmente, na Figura 37 organiza-se os resultados de acurácia geral de cada modelo de MLP especialista, nas três primeiras colunas de cada defeito são apresentados MLPs treinadas com cada atributo individualmente, na quarta barra os selecionados e a última com os atributos especialistas de cada defeito agrupados.

Tabela 10 - Acurácia Geral de Janelas Experimentais por Configuração e por Classe

Configuração	Global	Saudável	BB	CC	RL
A	88,45%	68,5%	91,1%	97,2%	96,8%
B	91,38%	87,6%	88,5%	97,2%	100,0%
C	88,20%	97,5%	98,6%	49,6%	100,0%
Selecionados	98,08%	97,1%	97,9%	98,4%	100,0%
Todos	99,16%	95,9%	100,0%	100,0%	100,0%

Fonte: Autoria Própria.

A análise por coluna da Tabela 10 permite avaliar o desempenho global individual de cada especialista nas diferentes configurações de atributos. Para o especialista em barra quebrada, o melhor desempenho ocorreu na configuração C, com 98,6% de acurácia obtidos pelo TOEO, superando de forma expressiva as configurações A e B e consolidando o TOEO como o atributo de maior destaque para essa classe. Analisando o especialista de curto-circuito, a configuração C apresentou o pior resultado, com acurácia de 49,6%, evidenciando a limitação dos atributos derivados da análise do vetor de Park (PVA), quando analisado de maneira isolada, em discriminar curtos-circuitos de baixa severidade, comportamento discutido em maior profundidade nas próximas seções. As configurações A e B alcançaram acurácia de 97,2%, demonstrando desempenho satisfatório em ambos os casos. Já para o especialista de defeitos em rolamento, a configuração B, utilizando o WPD, atingiu 100% de acurácia por bloco, valor que sugere proximidade do limite ideal para o conjunto de teste utilizado, embora uma base de teste mais ampla pudesse refinar essa estimativa. A configuração A, baseada exclusivamente em MCSA, resultou em 96,8% de acurácia, resultado relevante, porém inferior ao alcançado apenas com WPD.

Figura 37 - Acurácia Global por Especialista e Configuração de Atributos

Fonte: Autoria Própria.

A análise da classe saudável, que agrega amostras provenientes de todas as bancadas, fornece uma visão global desse desempenho. Observa-se uma deficiência marcante na

configuração A, 68,5%, cuja origem é investigada adiante. A configuração C apresentou o melhor resultado, 97,5%. Quanto à acurácia global, a configuração com todos os atributos alcançou o maior valor, 99,16%, porém em detrimento de pequena redução na acurácia da classe saudável, 95,9%. A configuração com atributos selecionados, por sua vez, apresentou acurácia global de 98,08% e maior equilíbrio entre todas as classes. Esse equilíbrio mostra-se especialmente relevante no contexto do diagnóstico em tempo real, no qual o sistema agrega resultados pela média das probabilidades dos blocos consecutivos, classificações incorretas isoladas têm impacto menos relevante sobre o diagnóstico final.

As matrizes de confusão resultantes da avaliação de cada configuração sobre o conjunto de teste analisado por janelas experimentais são apresentadas na Figura 38, permitindo visualizar a distribuição dos erros de classificação por classe.

Figura 38 (a) - Configuração A

Classificador (por Bloco)

Real \ Predito	Saudável	BB	CC	RL
Saudável	165	63	11	2
BB	51	525	0	0
CC	7	0	245	0
RL	4	0	0	122

Figura 38 (b) – Configuração B

Classificador (por Bloco)

Real \ Predito	Saudável	BB	CC	RL
Saudável	211	17	13	0
BB	66	510	0	0
CC	7	0	245	0
RL	0	0	0	126

Figura 38 (c) – Configuração C

Classificador (por Bloco)

Real \ Predito	Saudável	BB	CC	RL
Saudável	235	1	5	0
BB	8	568	0	0
CC	127	0	125	0
RL	0	0	0	126

Figura 38 (d) – Atributos Seleccionados

Classificador (por Bloco)

Real \ Predito	Saudável	BB	CC	RL
Saudável	234	1	6	0
BB	12	564	0	0
CC	4	0	248	0
RL	0	0	0	126

Fonte: Autoria Própria.

5.2.3 Especialista em Barras Quebradas

O especialista de barras quebradas apresenta evolução ao longo das cinco configurações, refletindo o poder discriminativo de cada atributo descrito no Capítulo 2. As acurácias por bloco para a classe de barras quebradas são 91,1% na configuração A, 88,5% na B, 98,6% na C, 97,9% com os atributos seleccionados e 100,0% com todos os atributos. A análise dos blocos saudáveis, denotados como BB-H, revela onde cada atributo gera falsos positivos. A Tabela 11 resume a acurácia por bloco em cada condição de torque, variando de 0,5 N·m, para os rotores saudáveis, e a Tabela 12 faz o mesmo para os rotores com barras quebradas.

Tabela 11 - Acurácia por Bloco dos Motores Saudáveis da Bancada de Barras Quebradas, por Condição de Torque


Configuração	T05	T10	T15	T20	T25	T30	T35	T40
A	50,0%	50,0%	50,0%	94,4%	77,8%	0,0%	61,1%	50,0%
B	58,3%	66,7%	72,2%	94,4%	100,0%	100,0%	100,0%	100,0%
C	100,0%	100,0%	94,4%	100,0%	100,0%	100,0%	100,0%	100,0%
Selecionados	100,0%	100,0%	94,4%	100,0%	100,0%	100,0%	100,0%	100,0%
Todos	100,0%	100,0%	94,4%	100,0%	100,0%	100,0%	100,0%	100,0%

Fonte: Autoria Própria.

Tabela 12 - Acurácia por Bloco dos Motores com Barras Quebradas, por Condição de Torque

Configuração	T05	T10	T15	T20	T25	T30	T35	T40
A	63,9%	97,2%	95,8%	84,7%	100,0%	97,2%	95,8%	94,4%
B	86,1%	100,0%	100,0%	100,0%	98,6%	83,3%	80,6%	59,7%
C	88,9%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%
Selecionados	83,3%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%
Todos	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Fonte: Autoria Própria.

Figura 39 – Matrizes de Confusão do Especialista em Barra Quebrada

Fonte: Autoria Própria.

A configuração A utiliza o MCSA e atinge 91,1% de acurácia, mas em motores saudáveis, atinge 54,3% de acurácia, observa-se os erros na matriz confusão da Figura 39. A classificação para motores saudáveis tem resultado inconsistente, com acurácia maior com torque 2 N·m, T20, evidenciando que o atributo isolado é insuficiente para discriminar o estado do rotor saudável em relação ao defeituoso na maioria das condições de carga. Na classe de motores com barras quebradas, Tabela 12, observa-se queda de acurácia no torque de 0,5 N·m para a classe de defeito de barra quebrada, com 63,9% de acertos, evidenciando baixa capacidade classificatória nessa faixa de carregamento. Esse comportamento já era esperado, em torques baixos o escorregamento é pequeno e as bandas laterais de barra quebrada se aproximam da fundamental, o que dificulta a distinção entre barra quebrada e saudável na análise da amplitude na frequência de defeito. O resultado obtido pela rede neural reflete a mesma limitação observada na etapa de refinamento de atributos sob torque de 0,5 N·m.

Outro ponto a se observar está na classificação dos motores saudáveis. A acurácia caiu para 0% em torque de 3,0 N·m e acertou metade dos testes nos torques de 3,5 e 4,0 N·m. À primeira vista, o resultado parece contraditório, já que a análise no MATLAB indicava diferenças entre rotor saudável e rotor com defeito nessa faixa de carga, conforme apresentado na Tabela 2. No MATLAB foram calculadas amplitudes médias para realizar estudo generalizado do atributo, já o *software* faz uma varredura janela a janela, e nessa abordagem ficam expostos trechos em que a amplitude das bandas laterais do motor saudável se aproxima da amplitude registrada em motores com defeito. Percebe-se, também, que a rede neural não aprendeu de maneira clara distinguir entre defeito e saudável com precisão.

A configuração B, TKEO, é mais conservadora na classificação como defeito, com a acurácia da classe de motores saudáveis subindo para 87,7%, mas perdendo desempenho em torques maiores, com queda acentuada em 4 N·m, 59,7%. Essa configuração apresentou um comportamento diferente ao da configuração A. Para a classe de defeito, a acurácia foi alta em torques baixos, 86,1% em 0,5 N·m, 100% entre 1,0 e 2,0 N·m, e caiu progressivamente conforme o torque aumentou, chegando a 59,7% em 4,0 N·m. Para os motores saudáveis, a tendência se inverteu, 58,3% em 0,5 N·m e 100% a partir de 2,5 N·m. Esse padrão é coerente com o comportamento das amplitudes registradas na Tabela 3, em que a diferença entre rotor saudável e rotor com defeito é maior em cargas intermediárias e diminui à medida que o torque cresce. O método foi proposto justamente como alternativa para condições de baixo escorregamento, e o resultado obtido reproduz essa especialização. A queda em torques altos é o custo de um atributo desenhado para o regime oposto.

A configuração C utiliza o atributo TOEO e representa um salto relevante. A classe de motores defeituosos atinge 98,6% de acurácia e motores saudáveis atingem 99,3%. O desempenho fica em 100% em 7 das 8 condições de torque para motores com barras quebradas e para motores saudáveis, confirmando que o TOEO oferece poder discriminativo superior aos demais atributos para este banco de dados. A Tabela 4 do refinamento de atributos mostra diferenças de amplitude entre saudável e defeito que chegam a quase 19 dB em alguns cenários, valores expressivos visto que a escala é logarítmica. A rede neural absorveu essa separação com facilidade e o TOEO se consolidou como o atributo de maior poder discriminativo isolado para barras quebradas neste banco de dados. Por esse motivo, ele foi escolhido como atributo selecionado para esse banco de dados.

A configuração onde os atributos foram selecionados mantém o atributo TOEO. Ao utilizar todos os atributos juntos a acurácia subiu para 100% também em 0,5 N·m na classe de defeito, indicando que MCSA e TKEO carregam informação complementar ao TOEO sob carga

reduzida. O TOEO sozinho já oferece desempenho próximo do limite para este banco de dados, e a combinação dos três métodos cobre o caso residual em que ele apresenta a maior incerteza.

A leitura prática desses resultados aponta para um critério de seleção de atributos guiado pelo regime operacional do motor a ser monitorado. Para aplicações em que o motor opera tipicamente próximo da carga nominal, o TOEO isolado entrega acurácia próxima da ideal a um custo computacional reduzido. Para aplicações em que a operação em baixa carga é frequente, a combinação dos três métodos passa a ser justificável, ao custo de maior exigência computacional na etapa de extração de atributos e durante o diagnóstico. Esse tipo de decisão passa a depender do perfil de uso do equipamento, o que está alinhado com a proposta de um sistema de diagnóstico aplicável em contexto industrial.

5.2.4 Especialista em Curto-Circuito

O especialista em curto-circuito apresenta a maior variabilidade de desempenho entre as cinco configurações. As acurácias por bloco para a classe de motores com curto-circuito são de 97,2% na configuração A, 97,2% na B, 49,6% na C, 98,4% com atributos selecionados e 100,0% utilizando todos os atributos, observa-se a Figura 40 para detalhes na matriz confusão. Para detalhar o comportamento de cada configuração, a análise considera duas perspectivas complementares dos blocos defeituosos, a condição de carga, L000, L050 e L100, apresentada na Tabela 13, mostrando casos sem carga, com 50% de carregamento e 100% de carregamento, e o nível de severidade do curto-circuito, apresentado na Tabela 15. A acurácia sobre os motores defeituosos é organizada na Tabela 13 e os motores saudáveis da bancada de curto-circuito é detalhada na Tabela 14. Os níveis de severidade vão de HI1 a LI3, em que HI (*high impedance*) corresponde aos estágios iniciais da degradação do isolamento entre as espiras do estator, com alta impedância no caminho do curto, e LI (*low impedance*) corresponde ao próprio curto-circuito com baixa impedância.

Tabela 13 - Acurácia por Bloco dos Motores com Curto-Circuito, por Condição de Carga

Configuração	L000	L050	L100	Geral
A	100,0%	93,8%	97,3%	97,2%
B	100,0%	97,5%	93,3%	97,2%
C	46,9%	54,3%	48,0%	49,6%
Selecionados	99,0%	97,5%	98,7%	98,4%
Todos	100,0%	100,0%	100,0%	100,0%

Fonte: Autoria Própria.

Tabela 14 - Acurácia por Bloco dos Motores Saudáveis da Bancada de Curto-Circuito, por Condição de Carga

Configuração	L000	L050	L100	Geral
A	86,7%	58,3%	66,7%	71,8%
B	100,0%	83,3%	8,3%	66,7%
C	100,0%	100,0%	58,3%	87,2%
Selecionados	93,3%	100,0%	58,3%	84,6%
Todos	86,7%	91,7%	50,0%	76,9%


Fonte: Autoria Própria.

Tabela 15 - Acurácia por Bloco do Especialista em Curto-Circuito, por Configuração e Severidade do Defeito

Configuração	HI1	HI2	HI3	LI1	LI2	LI3	Saudável
A	92,9%	100,0%	100,0%	95,6%	95,2%	100,0%	71,8%
B	97,6%	94,9%	94,5%	95,6%	100,0%	100,0%	66,7%
C	7,1%	18,0%	41,7%	31,1%	90,5%	100,0%	87,2%
Selecionados	97,6%	100,0%	100,0%	93,3%	100,0%	100,0%	84,6%
Todos	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	76,9%

Fonte: Autoria Própria.

Figura 40 – Matrizes de Confusão para os Atributos do Especialista em Curto-Circuito



Fonte: Autoria Própria.

A configuração A, para o MCSA de curto-circuito, apresentou desempenho estável na detecção da classe de defeito em todos os níveis de carregamento, com acurácia de 100% sem carga, 93,8% em meia carga e 97,3% em carga nominal, enquanto os falsos positivos sobre os motores saudáveis concentram-se em L050 e L100. A análise por severidade mostra que o método foi eficiente até nos estágios mais leves, com 92,9% de acertos em HI1, o nível menos severo, e 100% em HI2 e HI3. O resultado é coerente com a natureza do atributo, a presença de espiras em curto-circuito gera um desbalanceamento na corrente do estator que aparece como uma componente espectral próxima à frequência de alimentação, mas há certas limitações identificadas.


A classificação dos motores saudáveis foi o ponto crítico dessa configuração. A acurácia foi de 86,7% sem carga para 58,3% em meia carga e 66,7% em carga nominal, com

média geral de 71,8%. Esse comportamento foi antecipado na seção 2.4.2.1, em que se discute que, sob operação com carga, surgem dificuldades de diagnóstico devido à proximidade espectral entre as frequências de curto-circuito e excentricidade (Alberto Pereira; Gazzana; F. A. Pereira, 2005). Praticamente todos os motores de indução apresentam algum grau residual de excentricidade, mesmo quando saudável. Conforme o carregamento aumenta, o escorregamento cresce e a frequência da componente de excentricidade se aproxima da faixa em que o MCSA busca a assinatura de curto-circuito (Alberto Pereira; Gazzana; F. A. Pereira, 2005). A rede neural passa a interpretar essa componente residual como indício de defeito, o que produz falsos positivos justamente na condição operacional mais comum, a operação próxima à carga nominal. Então, observou-se que o modelo de rede neural, com MCSA, tende a classificar mais amostras como defeito, e acaba enviesando o resultado.

A configuração B, EDWT, apresentou um padrão semelhante na classe de defeito, com acurácia geral de 97,2%. Para os motores saudáveis, entretanto, o desempenho foi de 100% sem carga, 83,3% em meia carga e caiu para 8,3% em carga nominal. Em carregamento nominal, a rede neural classificou como defeito praticamente todos os arquivos saudáveis avaliados, e essa observação trouxe um alerta.

A origem desse comportamento ficou mais clara ao inspecionar o valor dos atributos. As razões de energia entre coeficientes *Wavelet* das três fases, definidas como E1, E2 e E3, devem se aproximar de 1 em motores saudáveis e se afastar conforme a severidade aumenta. Os valores coletados no refinamento de atributos mostram que, mesmo nos motores saudáveis sob carga nominal, as razões já estão deslocadas, categorizando como defeito, como observa-se na Tabela 7. Esse desbalanceamento é o motivo provável pelo qual o método EDWT, sensível ao desequilíbrio entre fases, classifica os arquivos saudáveis em plena carga como defeito, sendo o atributo que mais expôs essa característica e funcionou como um indicador útil para identificar a limitação do banco de dados.

Figura 41 – Razões de Energia entre Fases para Experimento Saudável da Bancada de Curto-circuito com Motor em Plena Carga



Fonte: Autoria Própria.

A configuração C, utilizando a abordagem do vetor de Park (PVA), apresentou o comportamento mais distinto dentre as três. Para a classe de defeito, a acurácia ficou em 49,6% no geral, a leitura pela intensidade de curto-circuito mostra que o resultado varia conforme a severidade diminui. O atributo acertou apenas 7,1% dos arquivos em HI1, 18,0% em HI2 e 41,7% em HI3, e só atingiu desempenho elevado a partir de LI2 (90,5%) e LI3 (100%). Esse padrão é coerente com a natureza física do atributo. O PVA mede o fator de excentricidade da elipse formada pela trajetória do vetor de Park no plano d-q, e essa excentricidade só se altera significativamente quando o curto-circuito atinge maior severidade. Em estágios incipientes da falha, em que a impedância do curto-circuito ainda é alta e o desbalanceamento é pequeno, a elipse permanece próxima da condição saudável e o atributo não consegue discriminar. Em contrapartida, o PVA foi o melhor atributo para os motores saudáveis, com 100% de acurácia sem carga, 100% de acurácia com meia carga e 58,3% de acurácia em plena carga. Esse desempenho, em comparação com a baixa acurácia nas classificações de motores defeituosos, confirma que o atributo tende a classificar motores como saudáveis na ausência de severidade suficiente, comportamento conservador que reduz falsos positivos de defeito, mas compromete a detecção de falhas incipientes. Além disso, quando utilizado com outros métodos, ele pode ser complementar, auxiliando na classificação.

Ao combinar MCSA e EDWT, buscou-se tirar proveito da complementaridade entre os dois métodos. A acurácia geral na classe de defeito ficou em 98,4%, com 100% em quatro das seis severidades. Para os motores saudáveis, o desempenho geral foi de 84,6%, com a deterioração em carga nominal (58,3%) permanecendo como ponto de atenção. A configuração onde os 3 atributos foram utilizados, atingiu 100% de acurácia em todas as severidades de defeito, mas a acurácia em motores saudáveis caiu para 76,9%, ainda com baixa precisão nos

experimentos saudáveis com carga nominal. A inclusão do PVA elevou a sensibilidade do conjunto a casos extremos, mas também ampliou a tendência de classificar como defeito experimentos com condições saudáveis sob carga nominal.

A leitura final dos resultados aponta para um cenário em que o conjunto de atributos disponíveis cobre bem a faixa de severidade do defeito, mas não resolve completamente o problema da classificação dos motores saudáveis em carregamento nominal. Parte dessa limitação tem origem física e está documentada na literatura, a proximidade espectral entre as componentes de curto-circuito e de excentricidade torna a discriminação mais difícil justamente na condição operacional mais comum. Outra parte tem origem nas próprias características do banco de dados utilizado, cujas correntes em motores saudáveis sob carga nominal já apresentam desbalanceamento. Em uma aplicação industrial, esse comportamento se traduziria em uma taxa de falsos positivos maior em motores operando próximo da carga nominal, o que motivaria o desenvolvimento de novos atributos complementares para diagnóstico.

5.2.5 Especialista em Defeitos em Rolamentos

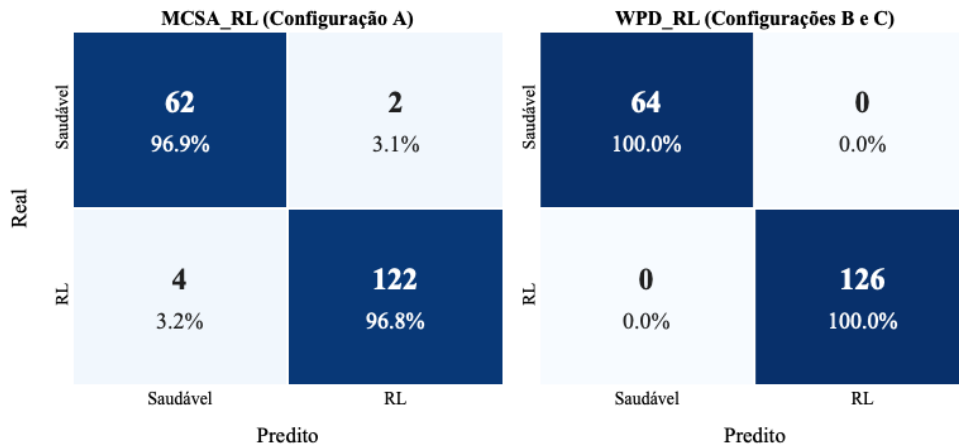
O especialista em defeitos de rolamento é o componente mais estável do sistema. As acurácias por bloco para a classe defeituosa são de 96,8% na configuração A, MCSA, e 100,0% na B e C (WPD), atributos selecionados e com todos os atributos. A diferença entre A e as demais configurações reflete a substituição do MCSA pelo WPD. A Tabela 16 apresenta a acurácia por bloco da classe de defeito em rolamento separada por tipo de defeito e severidade. Os defeitos são categorizados em BPF1 (Ball Pass Frequency Inner), associados a defeitos na pista interna do rolamento, e BPF0 (Ball Pass Frequency Outer), associados aos defeitos na pista externa, em três níveis de severidade indicados pelos sufixos 03, 10 e 30, onde 30 mm é o mais severo.

Tabela 16 - Acurácia por Bloco da Classe RL, por Tipo de Defeito e Severidade, com Saudáveis

Configuração	BPF103	BPF110	BPF130	BPFO03	BPFO10	BPFO30	Geral	Saudável
A	81,0%	100,0%	100,0%	100,0%	100,0%	100,0%	96,8%	96,9%
B	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%
C	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%
Selecionados	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%
Todos	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Fonte: Autoria Própria.

Figura 42 - Matrizes de Confusão para os Atributos do Especialista em Rolamento



Fonte: Autoria Própria.

A configuração A, utilizando MCSA, apresentou bom desempenho na maioria das condições, com acurácia geral de 96,8% na classe de defeito. O método acertou 100,0% dos arquivos em BPFO nas três severidades avaliadas e em BPF1 nas severidades de 10 e 30 mm. O único ponto de queda relevante foi em BPF1 3 mm, com 81,0% de acurácia, que corresponde ao defeito mais leve de pista interna no banco de dados. Em relação ao motor saudável, MCSA apresentou apenas 2 falsos positivos em arquivos distintos, mantendo 96,9% de acurácia. Analisando a matriz de confusão na Figura 42, observa-se que o desempenho é satisfatório, com apenas 6 classificações incorretas.

Entende-se que a queda no caso BPF1 3 mm é coerente com a natureza do MCSA aplicado a rolamentos, que extrai amplitudes nas faixas de frequências características de defeito diretamente do espectro da corrente. As componentes características de defeito de pista interna aparecem como bandas laterais em torno da fundamental, com amplitude que varia com a severidade do defeito. Em um defeito incipiente, a amplitude dessas componentes pode não se destacar, ficando próximo a um rolamento saudável, o que torna a discriminação mais difícil.

As demais configurações utilizam o WPD, que é calculado sobre a decomposição *Wavelet* da corrente do estator e isola as componentes espectrais em sub-bandas antes da extração dos atributos. Todas atingiram 100,0% de acurácia em todas as severidades e em ambos os tipos de defeito, além de 100,0% na classificação dos motores saudáveis, sem distinção entre cargas. O resultado mostra que o WPD elimina o erro residual do MCSA em BPF1 3 mm sem introduzir falsos positivos. A adição do MCSA na configuração com todos os atributos não altera o desempenho, indicando que o WPD é, por si só, suficiente para o diagnóstico de defeitos de rolamento neste banco de dados.

Esse resultado merece um comentário comparativo com os resultados parciais. A análise via índice de severidade calculado a partir dos atributos do WPD, apresentado anteriormente, é o método original de Nasiri et al. (2025), mas apresentou limitações para a lógica do sistema desenvolvido. O cálculo do índice de severidade é construído em relação a uma referência do motor saudável, o que dificulta a reprodutibilidade do método. No *software*, no entanto, os atributos extraídos antes do cálculo de severidade são entregues à rede neural sem redução de dimensionalidade a um índice único. A rede neural utiliza todos os atributos simultaneamente e identifica padrões discriminativos que não estavam acessíveis pela combinação fixa do índice de severidade. A MLP apresentou bons resultados de acurácia e supriu a limitação observada no cálculo manual do índice.

Em contrapartida, esse atributo exige maior quantidade de processamento. O WPD gera um volume de atributos muito maior por janela experimental, contra apenas algumas amplitudes espectrais no caso do MCSA. Essa diferença é relevante quando se considera o contexto de aplicação. Em um sistema com poder computacional limitado, o MCSA pode ser preferível, mesmo com a queda de desempenho na detecção de defeitos incipientes de pista interna. Em uma plataforma com mais recursos, como um servidor dedicado ao monitoramento, o WPD compensa o custo adicional pela uniformidade do desempenho em todas as condições avaliadas.

A leitura final desses resultados aponta para o WPD como o atributo mais robusto e uniforme entre os avaliados para o diagnóstico de defeitos de rolamento, sem necessidade de combinação com outros métodos para atingir o desempenho próximo do ideal observado no banco de dados utilizado. Vale lembrar que, ao se ampliar o conjunto de teste, a estimativa de acurácia tenderia a se aproximar de forma mais fiel do desempenho real do especialista. O resultado de 100,0% se reflete aos dados disponíveis, mas uma base maior poderia revelar limitações que o conjunto atual ainda não captura. A escolha entre MCSA e WPD em uma aplicação industrial depende menos da capacidade discriminativa dos atributos e mais da disponibilidade de recursos computacionais no projeto de implementação.

6 CONCLUSÃO

Este trabalho desenvolveu um sistema com base em conhecimento para diagnóstico de defeitos em motores de indução trifásicos, abrangendo barras rotóricas quebradas, curto-circuito entre espiras do estator e defeitos em rolamentos. A abordagem fundamentou-se em atributos fisicamente interpretáveis extraídos do sinal de corrente do estator e em classificadores MLP especialistas, treinados individualmente para cada tipo de defeito a partir de bancos de dados distintos. Os métodos de processamento estudados, MCSA, TKEO, TOEO, EDWT, PVA e WPD, foram validados no MATLAB antes da integração ao *software* desenvolvido, e foi organizado em quatro abas que cobrem a extração de atributos, o treinamento das redes neurais, os testes em massa e a simulação de diagnóstico em tempo real.

Os resultados validaram a abordagem de atributos fisicamente interpretáveis combinados com classificadores especialistas. Os três tipos de defeito investigados foram diagnosticados de forma satisfatória pelo conjunto de atributos selecionados, e as limitações identificadas foram discutidas, seja em características físicas do defeito sob determinadas condições de operação, seja em particularidades dos bancos de dados utilizados. A interpretabilidade física dos atributos mostrou-se útil também para a etapa de análise, permitindo que classificações incorretas fossem investigadas a partir do próprio comportamento dos sinais, e não somente pela saída da rede neural.

Os objetivos propostos neste trabalho foram alcançados. O objetivo geral, desenvolver um sistema inteligente baseado em conhecimento para diagnóstico de defeitos em motores de indução trifásicos, concretizou-se no *software* validado para os três tipos de defeito estudados. Em relação aos objetivos específicos, investigou-se como as barras quebradas, os defeitos em rolamentos e o curto-circuito entre espiras do estator se manifestam no sinal de corrente do estator. Revisaram-se e implementaram-se métodos consolidados de extração de atributos nos domínios do tempo, da frequência e do tempo-frequência. Selecionaram-se atributos com correlação entre o efeito físico e a representação numérica correspondente. Reuniram-se bases de dados públicas com registros de motores saudáveis e defeituosos. Desenvolveram-se redes neurais artificiais a partir desses atributos. Avaliou-se o desempenho dos modelos por métricas como acurácia e matriz de confusão. Construiu-se uma aplicação que cobre desde a extração de atributos até o diagnóstico de múltiplos defeitos. Assim, o objetivo geral e os específicos foram cumpridos, ainda que com desempenho parcial em condições específicas de operação, conforme discutido ao longo do trabalho.

A principal contribuição deste trabalho é a engenharia de atributos fisicamente interpretáveis para diagnóstico das três famílias de defeito investigadas, validada experimentalmente por meio de redes neurais artificiais no *software* desenvolvido. Em trabalhos futuros, sugere-se a ampliação dos bancos de dados utilizados, inserindo os 3 defeitos estudados neste trabalho no mesmo modelo de motor, a validação dos atributos em motores operando em ambiente industrial e a investigação de atributos complementares para as condições em que os métodos atuais apresentaram menor desempenho. Atualmente, o conjunto de atributos oferece resultado consistente para diagnóstico em ambiente controlado e estabelecem o ponto de partida para transição a uma ferramenta de monitoramento contínuo aplicável industrialmente.

REFERÊNCIAS

- AGAH, GHOLAM REZA *et al.* Broken Rotor Bar and Rotor Eccentricity Fault Detection in Induction Motors Using a Combination of Discrete Wavelet Transform and Teager-Kaiser Energy Operator. **IEEE Transactions on Energy Conversion**, v. 37, n. 3, p. 2199–2206, 1 set. 2022.
- ALBERTO PEREIRA, LUÍS; GAZZANA, DANIEL; F. A. PEREIRA, LUÍS. **Motor Current Signature Analysis and Fuzzy Logic Applied to the Diagnosis of Short-Circuit Faults in Induction Motors**. Porto Alegre: *[S.n.]*.
- ALI, MOHAMMAD ZAWAD; LIANG, XIAODONG. Threshold-Based Induction Motors Single-and Multifaults Diagnosis Using Discrete Wavelet Transform and Measured Stator Current Signal. **Canadian Journal of Electrical and Computer Engineering**, v. 43, n. 3, p. 136–145, 1 jun. 2020.
- ALI, THOALFAQQAR *et al.* Bearing Fault Diagnosis Using Motor Current Signature Analysis and the Artificial Neural Network. v. 10, n. 1, 2020.
- ALMOUNAJJED, ABDELELAH; SAHOO, ASHWIN KUMAR; KUMAR, MANI KANT. Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis. **Measurement: Journal of the International Measurement Confederation**, v. 182, 1 set. 2021.
- BAZGHANDI, REZA; MARZEBALI, MOHAMMAD HOSEINTABAR; ABOLGHASEMI, VAHID. Asymmetrical Fault Detection in Induction Motors Through Elimination of Load Torque Oscillations Effects in the Slight Speed Variations and Steady-State Conditions. **IEEE Journal of Emerging and Selected Topics in Industrial Electronics**, v. 4, n. 3, p. 725–733, 5 set. 2022.
- BAZGHANDI, REZA; MARZEBALI, MOHAMMAD HOSEINTABAR; ABOLGHASEMI, VAHID. Enhanced Multi-Synchro-Squeezing Transform for Fault Diagnosis in Induction Machine Based on Third-Order Energy Operator of Stator Current Signature. **IEEE Access**, v. 12, p. 41056–41065, 2024.
- BOUZIDA, AHCNE *et al.* Fault diagnosis in industrial induction machines through discrete wavelet transform. **IEEE Transactions on Industrial Electronics**, v. 58, n. 9, p. 4385–4395, set. 2011.
- BRIGHAM, E. ; MORROW, R. E. **The fast Fourier transform**. *[S.l.: S.n.]*.
- CHERIF, HAKIMA *et al.* Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor. **Energy**, v. 212, 1 dez. 2020.
- DROBNIC, KLEMEN *et al.* Detection of Broken Rotor Bars in Presence of Load Oscillations. **IEEE Access**, v. 13, p. 40012–40027, 2025.

FIRMINO, LUAN. **O que você precisa saber sobre blindagens e vedações.** Disponível em: <https://blog.dgbrolamentos.com.br/o-que-voce-precisa-saber-sobre-blindagens-vedacoes>. Acesso em: 27 nov. 2025.

FITZGERALD, A. E. ...; KINGSLEY, Charles.; UMANS, Stephen D. .. **Electric machinery.** [S.l.]: McGraw-Hill, 2003.

HAJNAYEB, SAEED *et al.* Broken Rotor Bar Fault Detection of Induction Machine Based on Rectified Orthogonal Axes of Stator Current. **IEEE Transactions on Instrumentation and Measurement**, v. 73, 2024.

JUNG, JEE HOON; LEE, JONG JAE; KWON, BONG HWAN. Online diagnosis of induction motors using MCSA. **IEEE Transactions on Industrial Electronics**, v. 53, n. 6, p. 1842–1852, 2006.

JUNG, WONHO *et al.* Vibration, acoustic, temperature, and motor current dataset of rotating machine under varying operating conditions for fault diagnosis. **Data in Brief**, v. 48, p. 109049, 1 jun. 2023.

KHALIQUE, UMAIR *et al.* A novel detection method for diagnosis of rotor eccentricity in three-phase induction motor. **Measurement Science and Technology**, v. 32, n. 11, 1 nov. 2021.

KITCHENHAM, BARBARA. **Guidelines for performing Systematic Literature Reviews in Software Engineering.** [S.l.: S.n.].

KOUADRIA, MOHAMED *et al.* A zoomed root-Prony technique for efficient bearing fault detection in induction motors. **Results in Engineering**, v. 24, 1 dez. 2024.

LESSMEIER, CHRISTIAN *et al.* **Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification.** [S.l.: S.n.].

LI, HAIYANG *et al.* A Normalized Frequency-Domain Energy Operator for Broken Rotor Bar Fault Diagnosis. **IEEE Transactions on Instrumentation and Measurement**, v. 70, 2021.

MACIEJEWSKI, NARCO; TREML, ALINE; FLAUZINO, ROGÉRIO; **A Systematic Review of Fault Detection and Diagnosis Methods for Induction Motors.** [S.l.]: IEEE, 2020.

MARAGOS, PETROS; POTAMIANOS, ALEXANDROS. **Higher Order Differential Energy Operators.** **IEEE Signal Processing Letters.** [S.l.: S.n.].

MARTINEZ-ROMAN, JAVIER *et al.* Low-Cost Diagnosis of Rotor Asymmetries of Induction Machines at Very Low Slip with the Goertzel Algorithm Applied to the Rectified Current. **IEEE Transactions on Instrumentation and Measurement**, v. 70, 2021.

MOREIRA, SANDRO. **Rede Neural Perceptron Multicamadas** | by Sandro Moreira | **Ensina.AI** | **Medium**. Disponível em: <https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>. Acesso em: 23 nov. 2025.

Motor Elétrico de Indução (Gaiola de Esquilo) - saVRee. Disponível em: <https://savree.com/pt/enciclopedia/motor-eletrico-de-inducao-gaiola-de-esquilo>. Acesso em: 27 nov. 2025.

NASIRI, AHMAD *et al.* Ball-Bearing Fault Detection of Squirrel-Cage Induction Motors Based on Single-Phase Stator Current Using Wavelet Packet Decomposition and Statistical Features. **IEEE Transactions on Energy Conversion**, v. 40, n. 2, p. 1529–1537, 2025.

PARRA, ALEJANDRO *et al.* **Stator Fault Diagnosis on Squirrel Cage Induction Motors by ESA and EPVA**. [S.l.]: IEEE, 2013.

PUCHE-PANADERO, RUBEN *et al.* Diagnosis of Rotor Asymmetries Faults in Induction Machines Using the Rectified Stator Current. **IEEE Transactions on Energy Conversion**, v. 35, n. 1, p. 213–221, 1 mar. 2020.

PUCHE-PANADERO, RUBEN *et al.* New Method for Spectral Leakage Reduction in the FFT of Stator Currents: Application to the Diagnosis of Bar Breakages in Cage Motors Working at Very Low Slip. **IEEE Transactions on Instrumentation and Measurement**, v. 70, 2021.

RUSSELL, STUART; NORVIG, PETER. **Artificial Intelligence A Modern Approach Fourth Edition**. Fourth edition ed. [S.l.: S.n.].

SAMEH, MARMOUCH; TAREK, AROUI; YASSINE, KOUBAA. Bearing and Rotor Faults detection and diagnosis of Induction Motors using Statistical Neural Networks. *In*: Institute of Electrical and Electronics Engineers Inc., 20 dez. 2020.

SINHA, ASHISH KUMAR *et al.* Ann-based pattern recognition for induction motor broken rotor bar monitoring under supply frequency regulation. **Machines**, v. 9, n. 5, 1 maio 2021.

STEPHEN J. CHAPMAN. **Fundamentos de máquinas elétricas**. 5. ed. [S.l.: S.n.].

TOMA, RAFIA NISHAT *et al.* Classification Framework of the Bearing Faults of an Induction Motor Using Wavelet Scattering Transform-Based Features. **Sensors**, v. 22, n. 22, 1 nov. 2022.

TREML, ALINE ELLY *et al.* **Experimental database for detecting and diagnosing rotor broken bar in a three-phase induction motor**. [S.l.: S.n.]. Disponível em: <https://dx.doi.org/10.21227/fmm-bn95>. Acesso em: 17 nov. 2025.

WANG, WANDING *et al.* Induction Motor Broken Rotor Bar Fault Diagnosis Based on Third-Order Energy Operator Demodulated Current Signal. **IEEE Transactions on Energy Conversion**, v. 37, n. 2, p. 1052–1059, 1 jun. 2022.

ZHANG, Y. *et al.* **Application of Discrete Wavelet Transform for Identification of Induction Motor Stator Inter-Turn Short Circuit**. [S.l.: S.n.].