



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
PERNAMBUCO

Campus Garanhuns

Bacharelado em Engenharia Elétrica

JOÃO HENRIQUE DE ARAÚJO RODRIGUES

**APLICAÇÃO DE REDE NEURAL MLP NA IDENTIFICAÇÃO DE FALHAS EM
MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO BASE DE DADOS GERADA
POR MODELO COMPUTACIONAL.**

Garanhuns

2024

JOÃO HENRIQUE DE ARAÚJO RODRIGUES

**APLICAÇÃO DE REDE NEURAL MLP NA IDENTIFICAÇÃO DE FALHAS EM
MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO BASE DE DADOS GERADA
POR MODELO COMPUTACIONAL.**

Trabalho de conclusão de curso apresentado à
Coordenação do Curso de Bacharelado em
Engenharia Elétrica do Instituto Federal de
Educação, Ciência e Tecnologia de
Pernambuco, como requisito para obtenção do
título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Diego Soares Lopes.

Garanhuns

2024

R696a Rodrigues, João Henrique de Araújo.
 Aplicação de rede neural MLP na identificação de falhas em
motores de indução trifásicos utilizando base de dados gerada por
modelo computacional / João Henrique de Araújo Rodrigues ; orientador
Diego Soares Lopes, 2024.
 54 f. : il.

Orientador: Diego Soares Lopes.

Trabalho de Conclusão de Curso (Graduação) – Instituto Federal de
Pernambuco. Pró-Reitoria de Ensino. Diretoria de Ensino. Campus
Garanhuns. Coordenação do Curso Superior em Engenharia. Curso de
Bacharelado em Engenharia Elétrica, 2024.

1. Motores elétricos de indução. 2. Redes neurais (Computação). 3.
Motores elétricos – Análise - Modelos matemáticos. I.Título.

CDD 621.46

Andréa Maria Lidington Lins –CRB4/868

JOÃO HENRIQUE DE ARAÚJO RODRIGUES

**APLICAÇÃO DE REDE NEURAL MLP NA IDENTIFICAÇÃO DE FALHAS EM
MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO BASE DE DADOS GERADA
POR MODELO COMPUTACIONAL.**

Trabalho aprovado. Garanhuns, 29 de fevereiro de 2024.

Prof. Dr. Diego Soares Lopes - IFPE – Orientador

Prof. Esp. Manoel Alves Cordeiro Neto – IFPE – Avaliador Interno

Prof. Dr. João Marcus Pereira Lima e Silva – UNIFIS – Avaliador Externo

Garanhuns

2024

Dedico este trabalho a minha família.

AGRADECIMENTOS

Agradeço a Deus por toda a força dada para conseguir trilhar este longo e sinuoso caminho.

À minha família, em especial minha mãe, Valdiene, por me incentivar a dedicação aos estudos, pelo apoio e suporte nas dificuldades encontradas.

Aos meus avós, José Martins (*in memoriam*) e Maria Alves (*in memoriam*), por serem pessoas exemplares e batalhadoras, principais pilares da família.

Agradeço também a todas as amizades adquiridas durante todos esses anos de graduação. Sou muito grato por todos que conheci, especialmente Adônis, André, Eduardo, Gleydson, Pedro, e também, Josias, o qual tenho uma amizade de longa data que se estende desde o ensino médio. Não poderia deixar de incluir meus amigos da ênfase de controle e automação, pessoas únicas que tiveram o prazer de conhecer. Devo dizer que se o verdadeiro tesouro são os amigos que fazemos pelo caminho, posso afirmar que tenho em minhas mãos o One Piece.

Agradeço a minha namorada, Karine, por todo o amor, apoio e compreensão nesta reta final da graduação, sempre me mantendo motivado.

A meu orientador, prof. Dr. Diego Soares Lopes, pela amizade, pelo auxílio e paciência durante todo o desenvolvimento desse trabalho.

Agradeço a todos os profissionais do IFPE *campus* Garanhuns por me oferecerem um ensino de qualidade, e por contribuírem para essa trajetória de aprendizado e desenvolvimento, levarei sempre comigo os valores e ensinamentos recebidos nesta instituição.

Finalmente, gostaria de agradecer a todos que de alguma forma contribuíram com meu desenvolvimento.

“Eu não tenho ídolos. Tenho admiração por trabalho, dedicação e competência.”

Ayrton Senna

RESUMO

Este estudo aborda a aplicação de Redes Neurais Multilayer Perceptron (MLP) na identificação de falhas em motores de indução trifásicos. Utilizando uma base de dados gerada por um modelo computacional, explorou-se o desempenho da rede neural em classificar diferentes condições operacionais. A metodologia adotada incluiu a geração da base de dados por meio de um modelo computacional que simulou diversas condições operacionais e potenciais falhas em motores de indução trifásicos. A escolha das Redes Neurais MLP foi motivada pela capacidade desses modelos de aprender padrões complexos e lidar com relações não-lineares nos dados. A análise detalhada das métricas de desempenho revelou uma aprendizagem eficaz da rede, com destaque para o desempenho notável em várias classes de falhas, sendo estas, subtensão, sobretensão e carga desbalanceada. No entanto, foram identificadas dificuldades na diferenciação entre as classes "Normal" e "Sobrecarga". Os testes de generalização confirmaram a eficácia da rede na detecção de diversas falhas, enquanto apontaram limitações na sensibilidade do modelo para sobrecargas. A matriz de confusão e a curva ROC reforçaram essa dificuldade, indicando padrões semelhantes entre essas classes. Destaca-se a aplicabilidade positiva das Redes Neurais MLP na identificação de falhas em motores de indução trifásicos, com potencial significativo para o monitoramento industrial. Este estudo contribui para o avanço no entendimento das capacidades e desafios associados à aplicação de redes neurais em sistemas elétricos industriais, com implicações práticas importantes.

Palavras-chave: Identificação de Falhas. Modelo Computacional. Motores Elétricos. Rede Neural MLP.

ABSTRACT

This study addresses the application of Multilayer Perceptron (MLP) Neural Networks in identifying faults in three-phase induction motors. Using a database generated by a computational model, the neural network's performance in classifying different operational conditions was explored. The adopted methodology included generating the database through a computational model that simulated various operational conditions and potential faults in three-phase induction motors. The choice of MLP Neural Networks was motivated by these models' ability to learn complex patterns and deal with nonlinear relationships in the data. Detailed analysis of performance metrics revealed effective learning by the network, particularly notable performance in various fault classes. However, difficulties were identified in differentiating between the "Normal" and "Overload" classes. Generalization tests confirmed the network's effectiveness in detecting various faults while highlighting limitations in the model's sensitivity to overloads. The confusion matrix and ROC curve reinforced this difficulty, indicating similar patterns between these classes. The positive applicability of MLP Neural Networks in identifying faults in three-phase induction motors is emphasized, with significant potential for industrial monitoring. This study contributes to advancing the understanding of the capabilities and challenges associated with the application of neural networks in industrial electrical systems, with important practical implications.

Keywords: Computational Model. Electric Motors. Fault Identification. MLP Neural Network.

LISTA DE FIGURAS

Figura 1 - MIT com rotor gaiola de esquilo.....	17
Figura 2 - Diagrama dos motores CA mais utilizados.....	17
Figura 3 – Representação do conceito de um campo girante de 2 polos.....	19
Figura 4 – Ilustração de rotor gaiola de esquilo expandido.....	20
Figura 5 - Representação das linhas de campo e da distribuição de forças nas barras.....	21
Figura 6 – Curto de espiras (à esquerda) e curto de bobinas (à direita).....	22
Figura 7 - Representação do desbalanceamento de carga.....	23
Figura 8 – Queima após falta de fase em estrela (à esquerda) e em delta (à direita).....	23
Figura 9 – Faixas de tensão em relação à referência.....	24
Figura 10 – Acesso à biblioteca Simscape Electrical no Simulink.....	27
Figura 11 – Famílias da Wavelet Daubechies de diferentes ordens.....	28
Figura 12 – Representação de uma Wavelet Haar.....	29
Figura 13 - Representação da estrutura de um neurônio humano.....	30
Figura 14 – Estrutura básica de uma rede neural artificial.....	31
Figura 15 – Fluxograma do processo de estruturação.....	32
Figura 16 – Configuração dos parâmetros do motor.....	33
Figura 17 – Modelo térmico do motor.....	35
Figura 18 - Gráfico da acurácia ao longo das épocas.....	42
Figura 19 - Gráfico das perdas ao longo das épocas.....	43
Figura 20 - Matriz de Confusão.....	45
Figura 21 - Nova Matriz de Confusão.....	46
Figura 22 - Área Sob a Curva ROC.....	47
Figura 23 - RPM e Torque na partida do motor em condições normais.....	48
Figura 24 - RPM e Torque na partida do motor em desbalanceamento de carga.....	48

LISTA DE TABELAS

Tabela 1 - Participação da força motriz no consumo em eletricidade na indústria.....	18
Tabela 2 – Pontos de conexão em Tensão Nominal inferior a 2,3 kV (380/220 V)	25
Tabela 3 – Teste do modelo com melhor custo benefício computacional.....	37
Tabela 4 - Dados de desempenho referentes ao modelo.....	44

LISTA DE ABREVIATURAS

MIT	Motor de Indução Trifásico
MLP	Multilayer Perceptron
EPE	Empresa de Pesquisa Energética
MME	Ministério de Minas e Energia
FEM	Força Eletromotriz
PRODIST	Procedimentos de Distribuição de Energia Elétrica
CSV	Comma-Separated Values
ANEEL	Agência Nacional de Energia Elétrica
CA	Corrente Alternada
ROC	Receiver Operating Characteristic
RPM	Rotações por Minuto

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Objetivos	14
1.1.1 Objetivo Geral	14
1.1.1 Objetivos Específicos	15
1.2 Estrutura do trabalho	15
2 FUNDAMENTAÇÃO TEÓRICA	16
2.1 Motor de indução trifásico	16
2.1.1 Estator	18
2.1.2 Rotor	19
2.2 Problemas comuns relacionados a MIT's	21
2.3 Modelagem Computacional	25
2.3.1 Simscape Electrical	26
2.4 Wavelet	27
2.4.1 Wavelet Daubechies	28
2.4.2 Wavelet Haar	29
2.5 Redes neurais artificiais	30
2.5.1 Multilayer Perceptron	30
3 METODOLOGIA	32
3.1 Modelagem computacional do MIT	33
3.1.1 Modelagem dos efeitos térmicos	34
3.2 Modelagem da rede neural MLP	36
3.2.1 Construção do Modelo da Rede Neural	36
3.3 Roteiro das simulações e dos testes	38
3.3.1 Simulações	38
3.3.2 Métricas de avaliação de desempenho da rede neural	39
3.3.3 Testes de identificação das falhas	40
4 RESULTADOS E ANÁLISES	42
4.1 Avaliação do desempenho da rede neural	42
4.2 Teste de identificação das falhas	47
5 CONSIDERAÇÕES FINAIS	50
REFERÊNCIAS	52

1 INTRODUÇÃO

A indústria vivenciou um enorme avanço no início do século XX, em parte devido ao advento dos motores elétricos, que são ferramentas essenciais nas mais diversas áreas e representam 68% do consumo de energia elétrica dentro das indústrias. Nesse contexto, os motores de indução trifásicos (MIT) com rotor gaiola de esquilo desempenham um papel significativo devido a sua versatilidade de aplicações, sendo o tipo de motor mais utilizado no meio industrial, especificamente por sua robustez e baixo custo (FERREIRA, 2019).

Dada tamanha relevância, análises são desenvolvidas para detecção de falhas nos motores de indução trifásicos, com o intuito de minimizar ou se possível evitar perdas econômicas e operacionais devidos a paradas não programadas. O diagnóstico de falhas geralmente é feito pelo acompanhamento das condições operacionais dos motores de indução. Isso envolve a análise de diversos parâmetros passíveis de monitoramento durante o funcionamento do motor, tais como tensão, corrente, temperatura, etc. Uma gama de falhas podem ser diagnosticadas através desses dados, porém este trabalho se atém à cinco: Falta de fase em algum dos terminais, subtensão, sobretensão, carga desbalanceada e sobrecarga (KOLLA; VARATHARASA, 2000).

O pré-processamento dos dados coletados, relativos ao comportamento do motor, se torna fundamental para a análise das falhas, uma vez que é possível extrair informações relevantes dos parâmetros. A transformada Wavelet se apresenta como ferramenta útil para essa tarefa, permitindo análise de dados com comportamentos irregulares e imprevisíveis. Isso permite detectar padrões e variações que indicam potenciais falhas no motor, possibilitando mais precisão e eficácia ao se deparar com comportamentos anômalos. Essa técnica matemática em específico, permite a análise em multiescala, ou seja, divide o sinal em diversas componentes, detalhando o sinal de dados em diferentes níveis de resolução (SHIRADO et al., 2015). A preparação dos dados é essencial para melhorar o desempenho de aprendizado de redes neurais, pois impacta diretamente na qualidade do modelo. Ao garantir que as categorias dos dados sejam linearmente separáveis, ou seja, que exista uma clara distinção entre diferentes classes ou categorias, o processo de treinamento das redes neurais é

facilitado, permitindo que elas identifiquem padrões com maior precisão e generalizem melhor para novos dados. A Multilayer Perceptron (MLP) é um tipo de rede neural artificial do tipo *feedforward* composta por múltiplas camadas de neurônios. Dentre as possibilidades de usos dessa rede neural, torna-se relevante utilizá-la para classificação de falhas nas mais diversas áreas, incluindo Medicina (SAVALIA; EMAMIAN, 2018), Ciência da Computação (DEL FRATE et al., 2007), Engenharia Civil (ZHONG et al., 2019), entre outras. A partir dessa classificação, o modelo da rede neural irá prever a falha com base nos padrões aprendidos com os dados de treinamento. Essas classes são atribuídas aos dados de entrada, que são rotulados de acordo com a falha.

Para obtenção dos dados referentes ao comportamento do motor em cada tipo de falha optou-se por utilizar o Simscape Electrical, uma ferramenta de simulação integrada ao MATLAB e Simulink que faz parte do conjunto Simscape, e possibilita a modelagem de sistemas elétricos em multidomínio. O Simscape apresenta uma extensa biblioteca de blocos elétricos que podem ser usados para construir modelos detalhados, incluindo MIT's e suas propriedades físicas e elétricas. A simulação permite inserir falhas intencionalmente sem a necessidade de um motor real, deste modo é possível extrair diversas variáveis importantes para a análise do comportamento do motor. Em muitos casos, uma falha em um motor pode ser acompanhada por sintomas adicionais, que podem ser igualmente importantes para a detecção e diagnóstico preciso do problema. Por meio da simulação, é possível explorar essa complexidade de maneira controlada. Ao reproduzir não apenas a falha principal, mas também os sintomas secundários que frequentemente a acompanham.

1.1 Objetivos

1.1.1 Objetivo Geral

Diagnosticar falhas elétricas e térmicas em motores de indução trifásicos através da extração de atributos dos sinais de corrente, tensão, temperatura, torque e RPM, aplicado à rede neural Multilayer Perceptron (MLP).

1.1.1 Objetivos Específicos

- Implementar um modelo computacional do motor de indução trifásico;
- Inserir falhas no modelo para geração de base de dados a ser analisada;
- Treinar e testar rede neural Multilayer Perceptron (MLP) com os dados coletados;
- Avaliar o desempenho da técnica utilizada na identificação de falhas do motor.

1.2 Estrutura do trabalho

O presente trabalho é estruturado em cinco capítulos, organizados da seguinte forma: No primeiro capítulo, apresenta-se uma contextualização do tema, abordando os objetivos da pesquisa. Em seguida, no segundo capítulo, é fornecida uma fundamentação teórica geral, iniciando pelo princípio de funcionamento dos motores de indução trifásicos, bem como problemas comuns associados. Tratando-se também da modelagem e simulação utilizando Simscape Electrical, explorando técnicas de processamento de sinais, como a análise wavelet, e o uso de redes neurais artificiais, com foco na arquitetura MLP.

No terceiro capítulo, é descrita a metodologia adotada, destacando a modelagem computacional do MIT e o desenvolvimento da rede neural MLP. Detalhes sobre as bibliotecas, a construção do modelo da rede neural, o roteiro das simulações e testes são apresentados de forma sistemática.

Os resultados e análises são expostos no quarto capítulo, onde se avalia o desempenho da rede neural e se realizam testes de identificação de falhas no modelo. Métricas de avaliação de desempenho são utilizadas, buscando oferecer uma visão abrangente do desempenho da abordagem proposta.

Por fim, as considerações finais são apresentadas no quinto capítulo, resumindo os principais pontos do estudo.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, será abordada a importância dos motores de indução trifásicos na indústria, destacando sua ampla aplicação e participação significativa no consumo de eletricidade industrial. Em seguida, será discutido seu princípio de funcionamento explicando sobre as partes constituintes. Além disso, serão explorados os problemas comuns enfrentados por motores de indução, como falhas no isolamento, sobrecarga, carga desbalanceada e problemas relacionados à alimentação de energia. Por fim, serão apresentadas modelagem e simulação com o uso do Simscape Electrical, análise de dados usando a transformada Wavelet e redes neurais artificiais para monitoramento da condição do motor.

2.1 Motor de indução trifásico

O motor trifásico com rotor de gaiola de esquilo é o tipo mais comum de motor elétrico e é amplamente utilizado na indústria em diversas aplicações. Esse motor pertence à categoria de motores de corrente alternada CA trifásicos assíncronos. São conhecidos por sua construção robusta e adequados para uma variedade de ambientes. A estrutura externa protege o motor contra poeira e umidade, e as aberturas permitem a ventilação para resfriamento. Na caixa de ligação lateral estão os terminais e conexões elétricas do estator. Esses motores geralmente possuem elementos de fixação para montagem em equipamentos ou estruturas (ABB, 2010). Na figura 1 está apresentado um motor de indução trifásico com rotor gaiola de esquilo, comercializado pela empresa WEG.

Na figura 2 está apresentado um diagrama que reúne os principais motores CA, com destaque em vermelho para a ramificação que abrange as características do motor com rotor gaiola de esquilo.

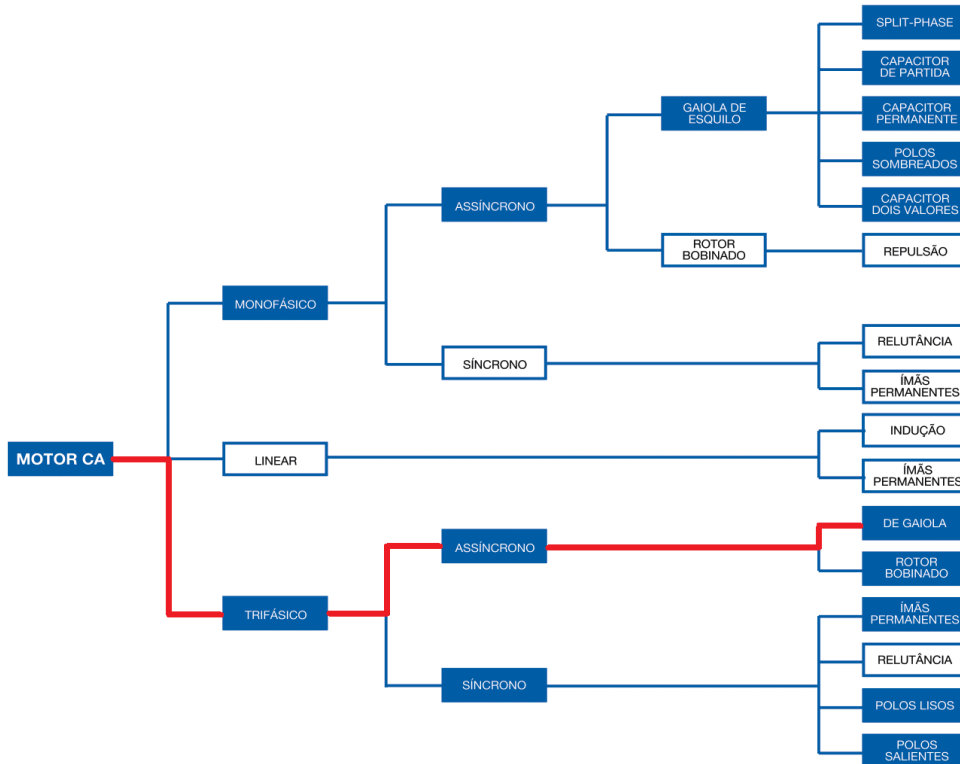
Os MIT's têm uma extensa participação na indústria dada sua simplicidade e alta confiabilidade operacional, uma vez que é uma tecnologia madura. São bastante utilizados para acionar equipamentos em diversos setores, como bombas, compressores, esteiras, etc, conforme apresentado na Tabela 1.

Figura 1 - MIT com rotor gaiola de esquilo.



Fonte: WEG. (2022).

Figura 2 - Diagrama dos motores CA mais utilizados.



Fonte: Adaptado de WEG. (2023)

Tabela 1 - Participação da força motriz no consumo em eletricidade na indústria.

Setor	Consumo (%)
Eletrólise	3,1
Iluminação	5,8
Eletrotermia	22,8
Força Motriz	68,3
Total	100

Fonte: ELETROBRÁS; PROCEL (2019).


Os dados mostrados na tabela 1 destacam a participação dos motores elétricos, definidos como “força motriz”, no consumo energético industrial. Devido a sua grande importância, torna-se ostensiva a detecção precoce de falhas, permitindo a implementação de ações corretivas antes que os problemas se agravem, a fim de evitar paradas não programadas, reduzindo os custos associados a reparos de emergência e perda de produção.

O motor consiste em duas partes principais: estator e rotor. O estator é a parte fixa do motor que contém os enrolamentos alimentados por corrente alternada trifásica, e produzem um campo magnético rotativo. Os enrolamentos são conjuntos de fios condutores enrolados em torno do estator, a parte fixa do motor elétrico. Esses enrolamentos são projetados para criar um campo magnético estacionário quando uma corrente elétrica é aplicada. Sua velocidade de rotação é chamada de velocidade síncrona. O rotor, por sua vez, é a parte móvel do motor e está localizado dentro do estator.

2.1.1 Estator

O motor de indução trifásico com rotor gaiola de esquilo, tem seu funcionamento baseado nos princípios da indução eletromagnética estudados por Michael Faraday, autor da Lei da Indução Eletromagnética, essa lei determina que uma mudança no fluxo magnético através de uma espira condutora gera uma força eletromotriz, induzindo uma corrente elétrica na espira. Quando uma corrente alternada é aplicada aos enrolamentos do estator de um motor de indução trifásico, ela cria um campo magnético girante (CHAPMAN, 2013).

Figura 3 – Representação do conceito de um campo girante de 2 polos.



Fonte: LESICS (2020)

A figura 3 é mostrado uma simplificação do enrolamento de um motor trifásico. As linhas magnéticas ilustradas apresentam os dois polos magnéticos que o estator gera. A quantidade de polos varia de acordo com as configurações dos enrolamentos do estator, essa variação na quantidade de polos influencia diretamente a velocidade síncrona do motor. Esse conceito é descrito conforme apresentado na equação 1.


$$N_s = \frac{120 \cdot f}{P} \quad (1)$$

Os enrolamentos são distribuídos simetricamente ao redor do estator, com a defasagem de 120° entre si. Esse arranjo espacial das bobinas é essencial para a formação do campo girante. À medida que a corrente alternada flui pelas bobinas, um campo magnético rotativo é gerado no estator (TORO; MARTINS, 1994).

2.1.2 Rotor

A parte móvel do motor é chamada de rotor. O motor com rotor gaiola de esquilo possui barras condutoras curto circuitadas que interagem com o campo girante gerado pelo estator, criando forças magnéticas que induzem o movimento de rotação do rotor, convertendo assim a energia elétrica em movimento mecânico (CHAPMAN, 2013).

Figura 4 – Ilustração de rotor gaiola de esquilo expandido.




Fonte: Adaptado de Liu et al.(2018).

Na Figura 4, é possível observar detalhes do rotor gaiola de esquilo, com suas partes principais representadas e separadas. O eixo é a peça central do rotor e se estende ao longo do comprimento do motor, sendo o elemento de transmissão do movimento gerado pelo motor. O eixo é apoiado por rolamentos ao longo de seu comprimento. As barras de alumínio formam a chamada gaiola de esquilo. Estas barras são curto circuitadas criando uma estrutura cilíndrica, geralmente feita de materiais condutores, como alumínio. O estator induz corrente nas barras conforme a Lei de Faraday, essa indução é chamada de força eletromotriz (FEM). As barras condutoras experimentam uma força eletromagnética que irá fazê-las girar, produzindo um movimento rotativo. Esse comportamento é descrito pela Lei de Lorentz (FITZGERALD; KINGSLEY; UMANS, 2014).

A figura 5 mostra vetores de forças eletromagnéticas (setas em verde) produzidas nas barras do rotor. Nota-se que a corrente induzida (setas em azul) e as forças eletromagnéticas estão mais intensas próximo aos polos, esse comportamento ocorre devido à corrente induzida nas barras do rotor ser mais acentuada quando a taxa de variação do fluxo magnético for maior, comportamento característico nas regiões mais próximas aos polos do campo magnético (TORO; MARTINS, 1994).

Figura 5 - Representação das linhas de campo e da distribuição de forças nas barras.



Fonte: LESICS. (2019).

O núcleo de aço silício é um componente presente tanto em motores elétricos, quanto em transformadores, sua principal função é reduzir as perdas magnéticas associadas à indução de corrente no rotor. Esse núcleo é composto por finas lâminas com intuito de melhorar a eficiência, reduzir as correntes parasitas e perdas por histerese.

2.2 Problemas comuns relacionados a MIT's

Os motores elétricos podem enfrentar uma série de problemas, desde falhas mecânicas até questões relacionadas ao fornecimento de energia, impactando diretamente a integridade do motor.

As falhas no isolamento entre as bobinas ou entre os fios do enrolamento podem ocasionar curtos-circuitos, fuga de corrente elétrica e até mesmo incêndios, além da queima dos demais componentes do motor. Essas falhas podem surgir devido ao desgaste ao longo do tempo, exposição a condições ambientais adversas, como umidade e altas temperaturas, ou mesmo defeitos no material isolante utilizado

(BRITO, 2002). Na figura 6 é apresentado os resultados da falha no isolamento do motor, que ocasionou curto-circuito entre espiras e entre bobinas.

Figura 6 – Curto de espiras (à esquerda) e curto de bobinas (à direita).



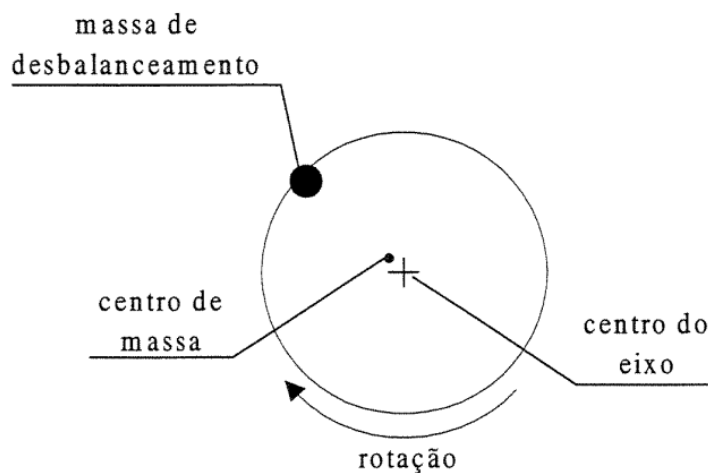
Fonte: WEG. (2019).

Diversos problemas estão correlacionados, a exemplo da sobrecarga. Quando um motor elétrico é submetido a uma sobrecarga no rotor, significa que está sendo exigido mais torque do que ele foi projetado para suportar em condições normais de operação. O aumento na carga resulta em um acréscimo proporcional na corrente, gerando mais calor, e os materiais isolantes podem eventualmente se deteriorar, resultando em curtos-circuitos entre as bobinas ou a queima.

Problemas relacionados à alimentação de energia também podem ocorrer, dentre eles, a falta de fase. A falta de fase se torna danosa já que com a ausência de uma fase, as correntes nas fases restantes tornam-se desiguais, causando sobreaquecimento. Esse problema decorre por mal contato em chave, contator ou disjuntor, queima de um fusível, rompimento de um cabo alimentador, entre outros (WEG, 2019).

Carga desbalanceada é um outro fator que impacta o funcionamento do motor, causando o desgaste desigual nos rolamentos e outros componentes mecânicos, além do aumento da corrente e queima de componentes. Na figura 7 é ilustrado o desvio do centro de massa em relação ao eixo de rotação, causado pela carga desbalanceada.


Figura 7 - Representação do desbalanceamento de carga.



Fonte: BRITO. (2002)

Os danos também dependem do arranjo das bobinas do estator. Em uma ligação em delta quando há falta de fase, a conexão se rearranja em série com dois enrolamentos de fase e em paralelo com a outra fase, isso leva ao superaquecimento rápido do enrolamento afetado, enquanto as correntes nos outros dois enrolamentos permanecem menores. Portanto, a queima de apenas uma fase é mais comum nesse arranjo. Enquanto na conexão em estrela, na falta de uma fase, os outros dois enrolamentos são conectados em série em relação à fonte de alimentação, resultando no superaquecimento e queima desses dois enrolamentos (DONGCHUN, 2022). Na figura 8 é apresentado a queima dos condutores do estator referentes a essa falha.

Figura 8 – Queima após falta de fase em estrela (à esquerda) e em delta (à direita).




Fonte: WEG. (2019).

A subtensão e sobretensão, comprometem a integridade da energia fornecida aos motores. A subtensão ocorre quando a tensão cai abaixo do valor esperado em condições normais, operar nessas condições aumenta a corrente elétrica, o que causa sobreaquecimento e reduz a vida útil dos motores. Na sobretensão, a tensão elétrica se eleva a valores acima do adequado, implicando novamente em sobreaquecimento e danos ao motor (SILVA, 2009).

Os Procedimentos de Distribuição de Energia Elétrica (PRODIST) é um conjunto de normas e procedimentos estabelecidos pela Agência Nacional de Energia Elétrica (ANEEL) no Brasil, que visam regular e padronizar a operação, planejamento, manutenção e expansão dos sistemas elétricos de distribuição no país. É composto por diversos módulos, cada um abordando aspectos específicos do sistema elétrico. Segundo o PRODIST, especificamente no Módulo 8, que aborda os requisitos e diretrizes relacionados à qualidade da energia nos sistemas elétricos de distribuição, é estabelecido valores de tensão de fornecimento adequado para cada nível de tensão nominal, sendo classificados em três categorias: adequada, precária e crítica.

Figura 9 – Faixas de tensão em relação à referência.



Fonte: PRODIST. (2021).

Na figura 9 é apresentado as faixas de tensão a partir da tensão de referência TR. A cor verde corresponde à faixa de tensão adequada, a amarela corresponde à faixa precária, e a vermelha à faixa crítica. As faixas são descritas como:

- TR: Tensão de Referência;
- Faixa Adequada de Tensão: intervalo entre $(TR - \Delta ADINF)$ e $(TR - \Delta ADSUP)$;
- Faixas Precárias de Tensão: intervalo entre $(TR + \Delta ADSUP)$ e $(TR + \Delta ADSUP + \Delta PRSUP)$ ou intervalo entre $(TR - \Delta ADINF - \Delta PRINF)$ e $(TR - \Delta ADINF)$; e
- Faixas Críticas de Tensão: valores acima de $(TR + \Delta ADSUP + \Delta PRSUP)$ ou abaixo de $(TR - \Delta ADINF - \Delta PRINF)$.

Tabela 2 – Pontos de conexão em Tensão Nominal inferior a 2,3 kV (380/220 V)

Tensão de Atendimento	Faixa de Variação da Tensão de Leitura (Volts)
Adequada	$(350 \leq TL \leq 399)/(202 \leq TL \leq 231)$
Precária	$(331 \leq TL < 350$ ou $399 < TL \leq 403)/(191 \leq TL < 202$ ou $231 < TL \leq 233)$
Crítica	$(TL < 331$ ou $TL > 403)/(TL < 191$ ou $TL > 233)$

Fonte: PRODIST (2021).

Na tabela 2 são apresentado os níveis de tensão adequada, precária e crítica para uma rede 380/220 V. A tensão adequada representa a faixa considerada normal de operação, assim os dispositivos elétricos operam eficientemente e sem riscos de danos. A faixa precária indica variações ligeiras em relação aos valores nominais, podendo impactar a eficiência e o desempenho de equipamentos sensíveis conectados a esses pontos. A faixa crítica trata-se de variações maiores que podem representar um risco considerável para a operação dos dispositivos elétricos. Nesse estágio, podem ocorrer danos severos aos equipamentos, exigindo ações corretivas imediatas.

2.3 Modelagem Computacional

A modelagem computacional oferece a capacidade de representar o motor de indução trifásico de maneira detalhada, incorporando características físicas e elétricas

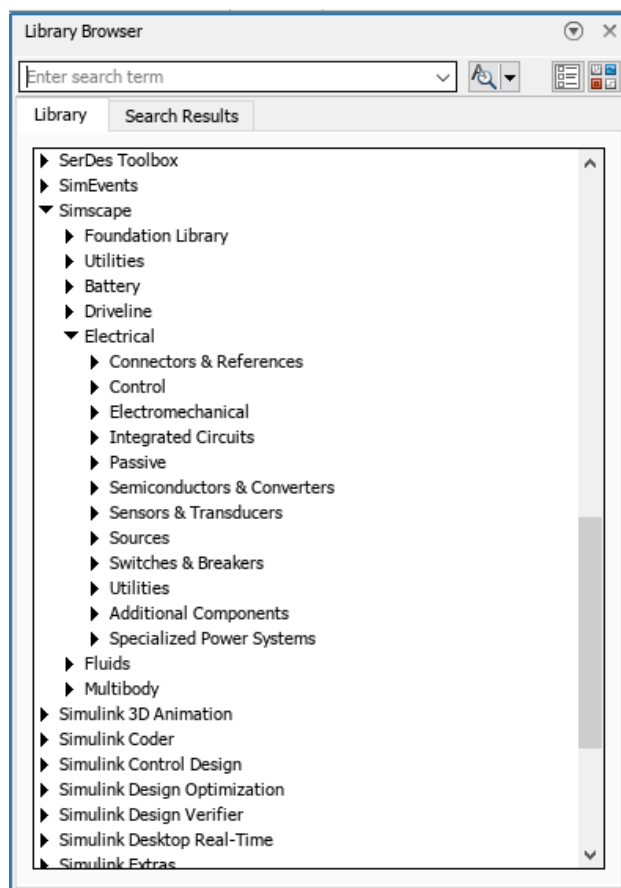
que influenciam seu funcionamento, podendo modelar diversas propriedades magnéticas, elétricas e mecânicas do motor. Essa possibilidade de explorar o comportamento do motor em diferentes cenários, sem a necessidade de experimentação física, se torna bastante atrativa, pois não apenas economiza tempo e recursos, mas também proporciona uma ótima flexibilidade para analisar uma ampla gama de condições operacionais e de falhas (GATI, 2015).

2.3.1 Simscape Electrical

O Simscape Electrical é uma ferramenta de simulação integrada ao ambiente MATLAB/Simulink, fazendo parte do conjunto Simscape. Essa ferramenta possibilita a modelagem de sistemas elétricos em multidomínio, portanto permite a representação de sistemas elétricos juntamente com sistemas mecânicos e térmicos em um único ambiente. Na figura 10 é apresentado a grande quantidade de recursos disponíveis na biblioteca Simscape, o que proporciona uma capacidade grande de cenários.

O Simscape Electrical oferece uma ampla biblioteca de blocos elétricos que podem ser utilizados para construir modelos detalhados de sistemas elétricos, como diversos tipos de motores, fontes de alimentação, chaves, disjuntores, etc. Além de haver a possibilidade de simular propriedades térmicas do motor, como os enrolamentos e o rotor, com parâmetros relacionados à condução e dissipação de calor.

Durante a simulação, os dados podem ser diretamente enviados para o espaço de trabalho do MATLAB, que posteriormente podem ser salvos em arquivos CSV (Comma-Separated Values), formato simples de ler e registrar, e eficiente em termos de armazenamento.

Figura 10 – Acesso à biblioteca Simscape Electrical no Simulink.

Fonte: Próprio Autor. (2023).

2.4 Wavelet

A análise de dados usando Wavelet envolve a decomposição de um sinal em componentes menores e em diferentes escalas. Essa decomposição permite uma representação mais eficiente de características do sinal em diferentes escalas de tempo e frequências, sendo particularmente útil para analisar dados cujas características variam (Rhif et al., 2019). A Wavelet oferece a capacidade de localizar eventos e mudanças abruptas, isso faz dela uma ótima ferramenta na identificação de padrões, anomalias e extração de características relevantes em conjuntos de dados.


No contexto de motores elétricos, Silva (2017) investigou o uso da Wavelet Packet, uma técnica baseada no conceito de transformadas Wavelet, porém mais flexível, em conjunto com medidas estatísticas dos sinais e redes neurais artificiais para monitorar a condição de motores de indução. A Wavelet neste trabalho foi

utilizada para realizar a decomposição do sinal de corrente de fase do motor em diferentes componentes de frequência. Essa decomposição ocorre por meio da construção de uma árvore de Wavelet Packet, onde cada nó representa uma subfaixa de frequência específica.

2.4.1 Wavelet Daubechies

Existem diversos tipos de Wavelets, duas das mais comuns são a Wavelet Haar e a Wavelet Daubechies, sendo que a Haar pode ser vista como um caso especial de uma Daubechies. A família Daubechies é definida por uma função mãe, que é responsável por gerar outras wavelets por meio de dilatações e translações, o que permite a construção de uma base ortonormal de funções. A escolha do número de coeficientes na wavelet de Daubechies determina a ordem da wavelet e influencia diretamente a capacidade de representação de diferentes características do sinal (SILVA, 2019).

Figura 11 – Famílias da Wavelet Daubechies de diferentes ordens.



Fonte: MATHWORKS. (2023).

Ordens mais elevadas podem capturar detalhes mais finos do sinal, enquanto ordens mais baixas são mais adequadas para representar características globais mais gerais.


2.4.2 Wavelet Haar

As Wavelets de Haar representam uma das primeiras abordagens na área das transformadas wavelet. A Transformada de Haar caracteriza-se por realizar a decomposição do sinal em aproximações e detalhes utilizando uma função mãe que possui apenas dois coeficientes: +1 e -1, formadas a partir de funções de passo simples que representam impulsos unitários. A ideia é que as Wavelets de Haar são capazes de capturar tanto a informação de tendência quanto a informação detalhada, ou seja, diferença ponderada de impulsos vizinhos em um sinal (ZERBINI, 2016). Ela pode ser representada de acordo com a equação (2).

$$\psi(x) = \begin{cases} 1, & \text{se } 0 \leq t < \frac{1}{2} \\ -1, & \text{se } \frac{1}{2} \leq t < 1 \\ 0, & \text{em outros casos} \end{cases} \quad (2)$$

A Wavelet Haar é considerada como um caso especial de uma Wavelet Daubechies devido à formulação geral proposta por Ingrid Daubechies para construir famílias de wavelets ortogonais. A construção dessas wavelets segue um método que envolve coeficientes específicos, e a escolha de certos valores para esses coeficientes leva à obtenção da wavelet Haar como um caso particular.

Figura 12 – Representação de uma Wavelet Haar.




Fonte: GALLIER. (2024)

2.5 Redes neurais artificiais

Uma rede neural artificial (RNA) é um modelo computacional inspirado no funcionamento do cérebro humano e projetado para realizar tarefas específicas de aprendizado e reconhecimento de padrões. Ela é uma subárea da inteligência artificial que busca simular o processo de aprendizado e tomada de decisões do cérebro humano. A estrutura básica de uma rede neural artificial consiste em camadas de unidades interconectadas, chamadas de neurônios, conforme representado na figura 13.

Figura 13 - Representação da estrutura de um neurônio humano.



Fonte: SANU N (2018).


Essas unidades são organizadas em camadas, geralmente divididas em três tipos: camada de entrada, camadas ocultas e camada de saída. A camada de entrada recebe os dados, as camadas ocultas processam esses dados e a camada de saída produz o resultado final (LIMA, 2022).

2.5.1 Multilayer Perceptron

A Multilayer Perceptron (MLP) é uma arquitetura de rede neural artificial, que se destaca pelo aprendizado em múltiplas camadas, sendo também chamada de rede neural densa. Na Figura 14, está a representação da estrutura da MLP, onde cada neurônio em uma camada está conectado a todos os neurônios da camada seguinte,

o que a caracteriza como uma rede *feedforward*. As informações fluem da camada de entrada à camada de saída, não havendo ciclos ou loops.

Figura 14 – Estrutura básica de uma rede neural artificial.



Fonte: Próprio autor (2023).

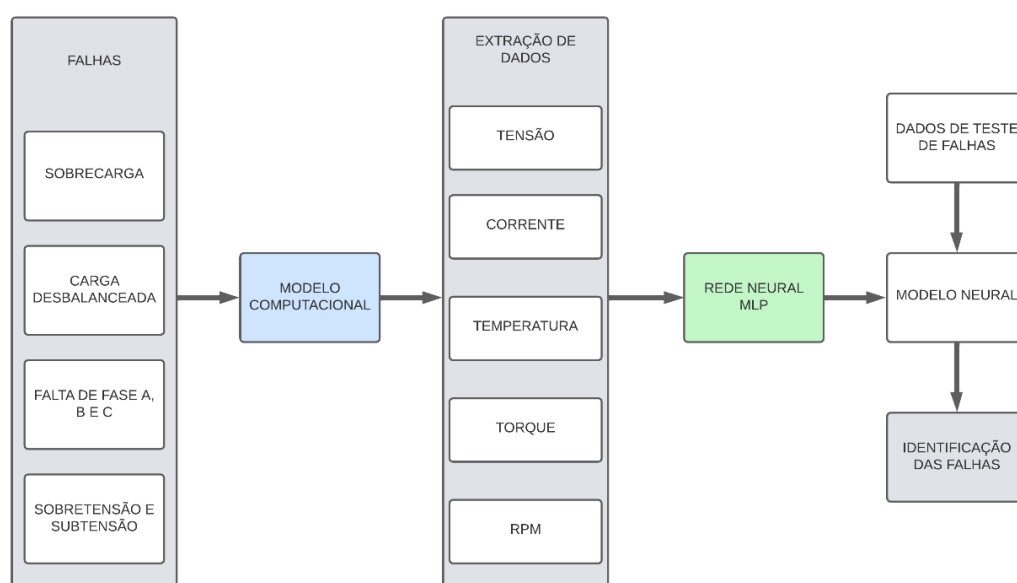
A MLP é um modelo que pode ser usado em aprendizado supervisionado, o que significa que é treinada com um conjunto de dados definidos e rotulados correspondentes às saídas esperadas, tornando-a apropriada para tarefas em que é necessário realizar uma previsão ou classificação com base em padrões aprendidos a partir de exemplos rotulados (OLIVEIRA, 2014). Isso permite que a MLP generalize para novos dados não vistos durante o treinamento para realizar previsões ou classificações em situações não encontradas anteriormente.

Neste capítulo, foram explorados os motores de indução trifásicos com rotor de gaiola de esquilo, sua estrutura e princípio de funcionamento, e a importância desses motores na indústria, destacando sua robustez e versatilidade. Foram discutidos também uma série de problemas comuns enfrentados pelos MITs. Além disso, comentou-se a importância da modelagem e simulação computacional, o uso de técnicas avançadas como análise de dados usando Wavelet e redes neurais artificiais para aprimorar o monitoramento e a manutenção desses motores. No próximo capítulo será explorada toda a metodologia utilizada na construção do modelo do MIT e da técnica de detecção de falhas com rede neural.

3 METODOLOGIA

O estudo se atrela a duas partes principais, montagem do modelo computacional do motor, e modelagem da rede neural MLP. O modelo do motor foi construído utilizando o Simscape Electrical, enquanto que a rede neural foi desenvolvida no Google Colab utilizando a linguagem Python. Na figura 15 é apresentado um fluxograma que reúne todo processo da estruturação do estudo.

Figura 15 – Fluxograma do processo de estruturação.



Fonte: Próprio autor (2023)

No roteiro das simulações foram definidos oito conjuntos de dados, um para cada tipo de falha, mais um para o funcionamento normal do motor. Após a inserção das falhas, e durante a simulação, utilizou-se o bloco “To Workspace”, enviando os dados da simulação para o espaço de trabalho do MATLAB, isso facilita a exportação dos dados para fora do programa.

Os parâmetros da simulação foram definidos com base na estimativa do tempo em que as falhas têm seu início e seu fim danoso ao motor, já que a simulação não tem um ponto de parada ou alguma forma de detectar quando está em momento crítico. Portanto definiu-se 150 segundos de simulação, estimando o tempo necessário para que todos os pontos temporais principais das falhas sejam

analisados. A taxa de amostragem foi definida em uma amostragem por milissegundo (ms), ou seja, 1000 amostras por segundo, o que gera ao total 150000 amostras por simulação. Considerando que são oito conjuntos de dados referentes a cada falha, com cinco variáveis, tem-se no total 750000 linhas para cada falha. Este alto volume de dados necessita de uma rede neural robusta e eficiente para processamento. A Wavelet Haar vem como uma técnica de pré-processamento para reduzir a complexidade dos dados, melhorando a eficiência do treinamento e a generalização do modelo.

3.1 Modelagem computacional do MIT

A modelagem se baseou nas características de um motor real, o modelo W22 IR3 Premium da WEG, de 1CV (745W) de potência, 220/380 V e 2 polos¹. Esses parâmetros foram levados ao Simulink, sendo a configuração do motor em delta, portanto operando em 220 V. A fonte de tensão é conectada diretamente ao motor, que tem sua partida iniciada no momento que inicia-se a simulação.

Figura 16 – Configuração dos parâmetros do motor.

NAME	VALUE
Modeling option	Show thermal port
Main	
Electrical connection	Expanded three-phase ports
> Rated apparent power	745 W
> Rated voltage	220 V
> Rated electrical frequency	60 Hz
> Number of pole pairs	1
Parameterization unit	Per unit
Squirrel cage	Single squirrel cage
Zero sequence	Include
Initialization option	Set targets for flux variables
> Impedances	
> Saturation	
> Thermal	
> Initial Targets	
> Nominal Values	

Fonte: Próprio autor (2023).

¹ Informações completas disponíveis em: <https://www.weg.net/catalog/weg/BR/pt/Motores-Elétricos/Trifásico---Baixa-Tensão/Usado-Geral/W22/W22-W22-IR3-Premium-1-cv-2P-71-3F-220-380-V-60-Hz-IC411---TFVE---B3D/p/11416814>

3.1.1 Modelagem dos efeitos térmicos

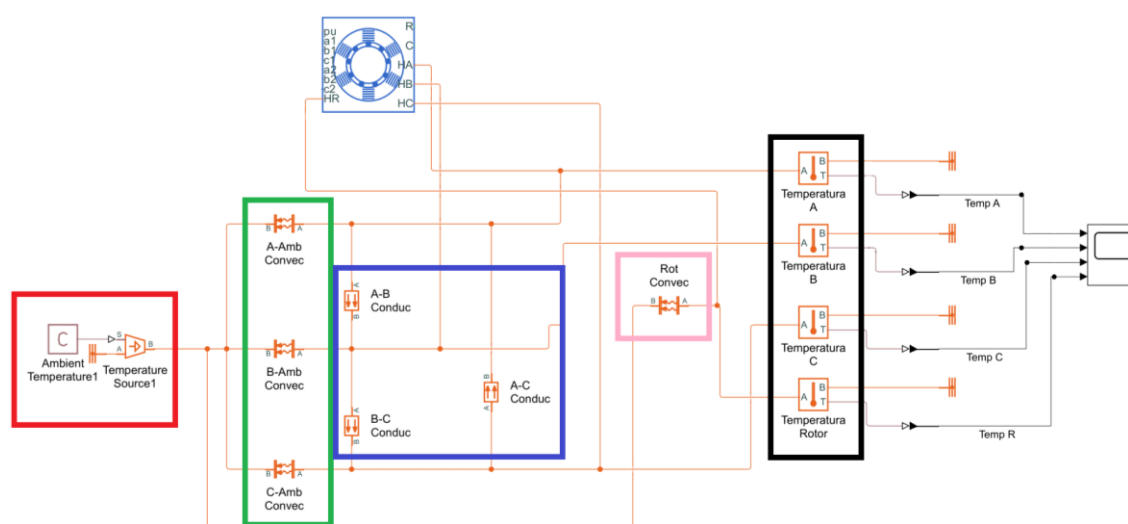
Para modelagem dos efeitos térmicos do motor, utilizou-se as “portas térmicas”, elas dão acesso às perdas que convertem energia elétrica em calor. Todos os blocos no Simscape que representam máquinas com enrolamentos elétricos podem, caso o usuário ache conveniente, exibir uma porta térmica para cada enrolamento, representando a transferência de calor associada ao funcionamento do motor. Importante salientar que essas portas térmicas apresentam valores dependentes do coeficiente de resistência à mudança de temperatura. Esse parâmetro é definido de acordo o material condutor. Os enrolamentos do estator são comumente feitos de cobre, e a gaiola do rotor, alumínio. Por padrão, o MATLAB estabelece os valores do coeficiente de resistência à mudança de temperatura como $3,93 \cdot 10^{-3} \text{ K}^{-1}$ (por Kelvin) para o cobre e $4,4 \cdot 10^{-3} \text{ K}^{-1}$ para o alumínio. Os valores podem variar, a depender da impureza do material, mas no geral estão em uma faixa semelhante (RESNICK; HALLIDAY, 2010a).

As portas térmicas por si só não apresentam o devido valor de temperatura dos enrolamentos, sendo necessário modelar as interações que ocorrem por condutividade térmica entre os enrolamentos, e a convecção que ocorre entre os enrolamentos e o ambiente, e entre o rotor e o ambiente. A temperatura correta será dada por essas interações.

- A **condutividade térmica** é uma propriedade física dos materiais que mede a capacidade de um material conduzir calor. descrevendo a facilidade com que o calor pode ser transmitido através de um material. Materiais com alta condutividade térmica permitem que o calor se propague rapidamente através deles, enquanto materiais com baixa condutividade térmica são isolantes térmicos mais eficazes (CALLISTER; RETHWISCH, 2016).
- A **convecção** é um modo de transferência de calor que ocorre em fluidos (líquidos e gases) quando há movimento do próprio fluido. Esse movimento geralmente é causado pela variação de temperatura no fluido (RESNICK; HALLIDAY, 2010b).

Com relação aos enrolamentos, por serem de cobre, tem seu valor de condutividade térmica como $401 \text{ W.m}^{-1}.\text{K}^{-1}$ (watt por metro-kelvin) (CALLISTER; RETHWISCH, 2016). O rotor é considerado como um sistema único, diferente dos enrolamentos do estator, portanto não é afetado pela condutividade térmica. O valor de convecção do ar é em torno de $20 \text{ W}/(\text{m}^2.\text{K})$ (PERRY; GREEN, 1999). Tanto os enrolamentos quanto o rotor estão em contato com ar, portanto são afetados. Com esses parâmetros definidos, obteve-se o arranjo térmico definido e ilustrado na figura 17.

Figura 17 – Modelo térmico do motor.



Fonte: Próprio autor (2023).

Cada uma das seções destacadas tem sua contribuição no sistema térmico:

- Em **vermelho** está a representação da temperatura ambiente, trata-se de uma fonte de energia térmica que mantém a temperatura especificada em sua saída, independentemente do fluxo de calor consumido pelo sistema. Está estabelecido em $27 \text{ }^\circ\text{C}$;
- Em **verde** estão os blocos referentes às perdas de calor por convecção dos enrolamentos com o ambiente;
- Em **azul** estão os blocos referentes a interação por condução entre os três enrolamentos. Destaca-se o arranjo em Δ dos três blocos, se adequando à conexão em delta do motor;

- Em **rosa** está o bloco referente à interação entre o rotor e o ambiente por convecção;
- Em **preto**, os blocos em destaque são sensores de temperatura que medem a temperatura absoluta em um nó ou a diferença de temperatura entre dois nós.

A partir dos procedimentos acima foi possível mensurar a temperatura do três enrolamentos e do rotor. As demais variáveis, sendo: tensão, corrente, torque e RPM, têm sensores diretamente atrelados ao motor, bastando uma simples conexão para a medição dos valores.

3.2 Modelagem da rede neural MLP

A modelagem da rede neural MLP se deu a partir da linguagem de programação Python, e foi desenvolvida no Google Colab, uma plataforma de código aberto baseada na nuvem oferecida pelo Google. O Python foi escolhido por possuir um ambiente rico em bibliotecas voltadas para ciência de dados, aprendizado de máquina e processamento de sinais facilitando o desenvolvimento. Por este motivo utilizou-se a biblioteca Keras, sendo bastante popular para modelagem de redes neurais em Python.

3.2.1 Construção do Modelo da Rede Neural

A criação da arquitetura do modelo foi feita por meio de testes, baseados na literatura e na quantidade e complexidade dos dados. Na Tabela 3 é mostrado todos os testes feitos para encontrar os valores mais próximos do ideal, considerando o menor custo operacional e computacional. Analisando a tabela, percebe-se que, apesar do teste 2 ter metade do número de neurônios do teste 1, a acurácia praticamente não se alterou, indicando que com esses valores a rede neural está superdimensionada. No teste 3, novamente dividindo pela metade o número de neurônios, nota-se um pequena queda no valor da acurácia, assinalando que a quantidade ideal está próxima. No teste 4 foi novamente dividido pela metade o

número de neurônios, porém pode-se verificar que houve uma queda maior no valor da acurácia, apontando estar subdimensionado.

Assim, a camada de entrada foi delineada em 48 neurônios, e esse hiperparâmetro foi ajustado com base no desempenho do modelo e os testes anteriores, sendo o valor mais adequado. Da mesma forma foram definidas as camadas ocultas, sendo um total de três camadas com 64 neurônios cada. Por fim, definiu-se a camada de saída com oito neurônios, referentes à quantidade de saídas esperadas, correspondendo ao número de classes. O treinamento foi feito em 50 épocas.

Tabela 3 – Teste do modelo com melhor custo benefício computacional.

Teste	Nº de neurônios			Acurácia
	Entrada	Ocultos	Saída	
1	128	256;256;256	8	0,922462
2	64	128;128;128	8	0,922270
3	32	64;64;64	8	0,917779
4	16	32;32;32	8	0,886422
5	48	64;64;64	8	0,921241

Fonte: Próprio Autor (2023).

Duas funções de ativação foram utilizadas nas camadas da rede neural, a função ReLU (Rectified Linear Unit) e a Softmax. Elas são importantes pois introduzem não-linearidade nas operações das camadas permitindo à rede neural aprender padrões complexos.

- A função **ReLU** retorna zero para todos os valores de entrada negativos e mantém os valores positivos inalterados. Foi utilizada na camada de entrada e camadas ocultas. Sua função matemática é descrita conforme apresentado na equação 3.

$$f(x) = \max(0, x) \quad (3)$$

- A função **Softmax** converte as saídas da camada de saída em uma distribuição de probabilidade sobre as diferentes classificações de falhas. Cada valor de saída é transformado em uma probabilidade, e a soma de todas as probabilidades é igual a 1. Foi utilizada na camada de saída, e sua função matemática é descrita conforme apresentado na equação 4.

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad (4)$$

Após definidos os parâmetros da rede neural, criou-se as rotulações, onde a entrada para treinamento está associado a uma classe específica. O código cria vetores de números inteiros, um para cada tipo de falha, assim o comprimento de cada vetor é igual ao número de amostras desse tipo de falha no conjunto de dados.

A divisão dos dados em conjuntos de treinamento e teste é necessária para uma melhor generalização dos dados, aumentando o desempenho da rede neural para dados não vistos. A escolha de 80% para treinamento e 20% para teste é uma convenção geral.

Ao final, foi criado um outro código em Python para os testes utilizando dados não vistos pela rede neural e analisar os acertos obtidos.

3.3 Roteiro das simulações e dos testes

É importante seguir um padrão nas simulações para evitar imprecisões ao longo do desenvolvimento e das análises, portanto, foi estabelecido um método para cada falha, e da mesma forma para os testes e avaliações de desempenho da rede neural. Os dados de tensão e corrente foram extraídos em valores RMS (Root Mean Square), portanto, os valores eficazes dessas duas variáveis, em Volts e Ampères, respectivamente. Os valores de temperatura foram obtidos em graus Celsius (°C), enquanto que os valores de torque obteve-se em N.m (Newton-metro). Todos esses dados foram extraídos no domínio do tempo, em arquivos do tipo CSV.

3.3.1 Simulações

Inicialmente foi feita a simulação para o comportamento normal, onde manteve-se a tensão nominal e a carga nominal, e extraiu-se os dados. Para as falhas elétricas, iniciou-se com a falta de fase, foram mantidas as características anteriores, porém uma das fases é desconectada e as demais permanecem conectadas. Repetiu-se o processo para as outras duas fases. Nas falhas de subtensão e sobretensão,

estabeleceu-se parâmetros baseados no PRODIST, que define valores de tensão aceitáveis. Para fatores mais realistas ajustou-se a tensão a 198 V no cenário de subtensão, e 231 V no cenário de sobretensão. Esses valores estão dentro da “faixa precária” segundo a norma.

Para a falha mecânica de sobrecarga, foi definido como valor de 2,5 vezes a carga nominal, considerando o motor base real que define o fator de serviço de 1,25, optou-se pelo dobro. Na carga desbalanceada o cenário é, o valor nominal da carga, porém com desvio de 5 cm do eixo do rotor.

Para cada uma das falhas descritas anteriormente, foram extraídos os valores de tensão e corrente nas três fases, as temperaturas dos três enrolamentos e do rotor, torque e RPM.

3.3.2 Métricas de avaliação de desempenho da rede neural

- A primeira forma de avaliar o modelo treinado é a **acurácia**, bastante popular por ser a métrica mais comum e simples. Ela representa a proporção de predições corretas em relação ao total de predições.
- A forma seguinte para análise de desempenho é a **F1-Score**, que leva em consideração tanto a precisão, ou seja, número de verdadeiros positivos dividido pelo número total de predições positivas, quanto o recall que é o número de verdadeiros positivos dividido pelo número total de instâncias positivas reais. Um F1-score equilibrado é uma indicação de que o modelo está lidando bem com ambas as tarefas: evitar falsos positivos e evitar falsos negativos.
- Uma das métricas mais importantes é a **matriz de confusão**, ela fornece uma visão mais detalhada do desempenho, permitindo analisar como o modelo se comporta em cada classe. A matriz de confusão é uma tabela que compara as predições do modelo com as classes reais.
- Por fim, utilizou-se a **Área Sob a Curva ROC (ROC AUC)**, A Curva ROC (Receiver Operating Characteristic) é uma representação gráfica da taxa de verdadeiros positivos pela a taxa de falsos positivos em diferentes pontos para

as probabilidades de classificação. Quanto maior a área sob a curva, melhor o desempenho do modelo.

Além das análises citadas anteriormente, explorou-se também a acurácia e as perdas ao longo das épocas.

3.3.3 Testes de identificação das falhas

Após a modelagem, treinamento e criação da rede neural com todas as falhas requeridas, verificou-se por meio de inserção de falhas semelhantes o quão preciso está o modelo. Essa verificação se deu pela geração de novos dados a partir de novas simulações, porém com parâmetros um pouco distintos dos usados no treinamento. Essa mudança dos parâmetros nos casos de subtensão e sobretensão se deu variando 2 V acima e abaixo dos valores do treinamento. Na subtensão, segundo o PRODIST, essa variação de ± 2 V permanece na faixa “precária”. Já na sobretensão esta variação abrange 229 V, que já está na faixa “adequada” e 233 V que está no limiar entre a faixa “precária” e “crítica”. Porém, isso será mantido por questões de padronização. Para carga desbalanceada, optou-se por dois valores distintos do treinamento, 4 cm e 1 cm de desvio do eixo. Esses valores foram estabelecidos como forma de verificar a diferenciação de um valor próximo da falha aprendida, e outro próximo do funcionamento normal.

Com isso, obtêm-se valores não vistos apesar de mesma falha, permitindo verificar se o modelo generalizou bem e se é capaz de lidar com variações nos dados. Essa abordagem é conhecida como teste de generalização. Ao introduzir falhas semelhantes, mas com parâmetros ligeiramente diferentes, simula-se condições do mundo real, onde as instâncias de uma mesma classe podem variar em detalhes.

Criou-se um novo código para receber o modelo treinado e os dados de teste. Utilizou-se a função ***predict*** para fazer previsões nos dados de entrada e gerar uma matriz de probabilidades para cada classe de falha. Após isso, o código calcula a classe de falha mais frequentemente prevista com base nas previsões do modelo. A ideia é contar quantas vezes cada classe é prevista e escolher a que tem a contagem mais alta como a classe final que será impressa como resultado.

No próximo capítulo será feita a análise dos resultados obtidos a partir dos métodos descritos neste capítulo. Nele será observado o comportamento da rede neural e o quanto ela se apresentou como uma técnica adequada para os cenários.

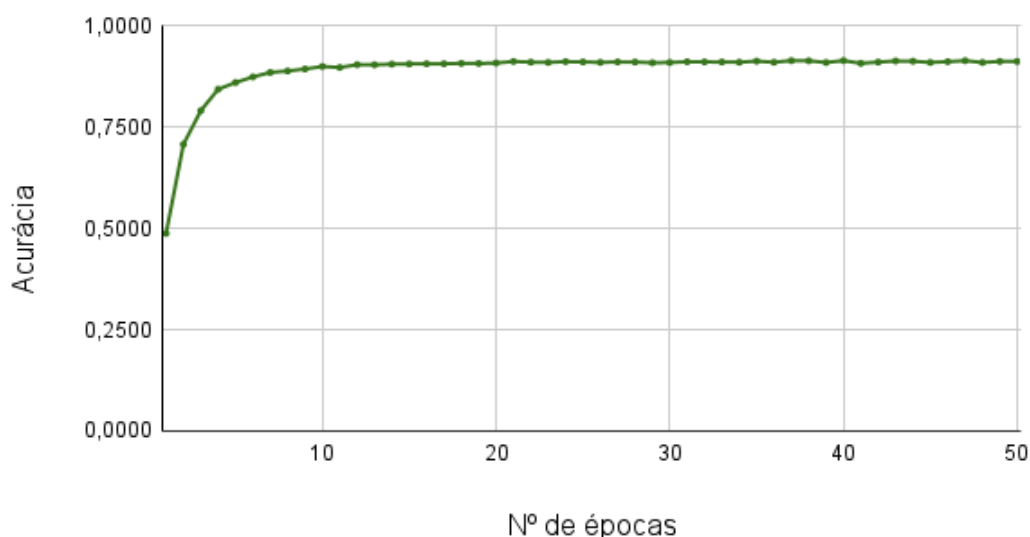
4 RESULTADOS E ANÁLISES

O capítulo apresenta as análises do desempenho da rede neural em classificar falhas em diferentes circunstâncias criadas. Explora-se as métricas de desempenho, destacando tanto os pontos fortes quanto as limitações do modelo, revelando tanto a eficácia da rede neural em interpretar diversas situações quanto suas dificuldades.

4.1 Avaliação do desempenho da rede neural

Na Figura 18 é apresentado o gráfico da acurácia ao longo das épocas durante o treinamento da rede neural. Observa-se uma tendência ascendente nos primeiros estágios, indicando um processo de aprendizado eficaz. À medida que as épocas progredem, a acurácia se estabiliza, sugerindo que a rede atingiu uma fase de convergência.

Figura 18 - Gráfico da acurácia ao longo das épocas.

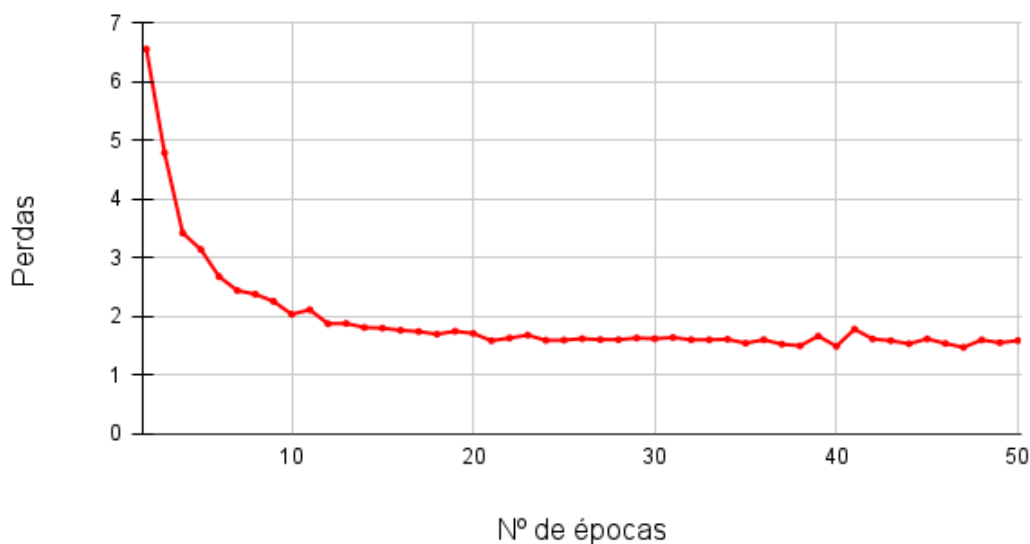


Fonte: Próprio autor (2023).

Ao alcançar as épocas intermediárias, a acurácia chega próximo a um platô, mostrando que o modelo está chegando a sua capacidade máxima de aprendizado com base nos dados fornecidos. A acurácia do modelo chegou ao valor de **0,921241**. A acurácia de 92,12% reflete a habilidade da rede em classificar corretamente a grande maioria das instâncias do conjunto de teste.

Além da análise da acurácia, na Figura 19 é exibido o gráfico das perdas ao longo das épocas durante o treinamento. As perdas são bons indicadores da performance do modelo, refletindo a discrepância entre as previsões do modelo e os rótulos reais.

Figura 19 - Gráfico das perdas ao longo das épocas.



Fonte: Próprio autor (2023).

Observa-se uma tendência decrescente nas perdas durante as primeiras épocas, indicando que o modelo está se ajustando aos padrões presentes nos dados de treinamento, onde a rede está minimizando a divergência entre suas previsões e os rótulos verdadeiros. Novamente, como visto no gráfico de acurácia é possível notar uma estabilização nas perdas, sugerindo que o modelo atingiu um ponto de convergência.

Os resultados apresentados na Tabela 4 revelam um desempenho notável da rede neural em diversas classes, notadamente nas categorias **Falta de fase A, Falta de fase B, Falta de fase C, Subtensão, Sobretensão e Carga Desbalanceada**. Nestas classes, a precisão, recall e F1-Score atingiram uma marca altíssima, indicando uma capacidade excepcional do modelo em realizar previsões precisas e completas. Entretanto, a classe **Normal e Sobrecarga** exibem uma precisão mediana, indicando que cerca de 69% das instâncias classificadas como "Normal" são verdadeiramente normais, enquanto para "Sobrecarga" esse valor é de 70%. O recall demonstra que o modelo captura corretamente 68% das instâncias reais da classe "Normal", e 71% para "Sobrecarga". O F1-Score de 0,69 para a classe "Normal" e 0,70

para “Sobrecarga” indicam uma média harmônica de precisão e recall, revelando um equilíbrio geral nessas classes.

Tabela 4 - Dados de desempenho referentes ao modelo.


Classe	Precisão	Recall	F1-Score
Normal	0,69	0,68	0,69
Falta de fase A	1,00	1,00	1,00
Falta de fase B	1,00	1,00	1,00
Falta de fase C	1,00	1,00	1,00
Subtensão	1,00	1,00	1,00
Sobretensão	1,00	1,00	1,00
Carga Desbalanceada	0,99	0,99	0,99
Sobrecarga	0,70	0,71	0,70

Fonte: Próprio Autor (2023).

A partir da matriz de confusão apresentada na figura 20, é possível ter uma visão detalhada do modelo em relação à sua precisão nas classes. Ao fazer o cruzamento das classes reais com as classes previstas pode-se avaliar o desempenho e comportamento da rede neural. A título de exemplo, considerando os valores reais da classe “Subtensão” na coordenada das ordenadas e cruzando com todos os valores previstos das classes na coordenada das abscissas, pode-se verificar o valor “0.00”, com exceção da classe “Subtensão”, no qual o valor está “1.00”, isso indica que a rede neural está demonstrando uma capacidade de distinguir corretamente instâncias da classe correta de outras classes.

Contudo, ao analisar os valores previstos e reais das classes “Normal” e “Sobrecarga”, percebe-se uma dificuldade de diferenciação, isso foi notado na tabela 3, porém o motivo ao certo não era facilmente definido. Com a matriz de confusão é possível notar que ao cruzar os valores previstos da classe “Normal” com os valores reais da classe “Sobrecarga”, há uma certa dificuldade de distinção, o oposto também ocorre. Esse comportamento aponta que as características tem alguns padrões semelhantes entre as classes “Normal” e “Sobrecarga”, dessa forma, o modelo pode ter dificuldade em encontrar fatores distintos que permitam a diferenciação.

Figura 20 - Matriz de Confusão.




Fonte: Próprio autor (2023)

Para verificar se essa afirmação está correta, foi feita uma nova simulação, porém o valor de sobrecarga foi ajustado exageradamente para 10 vezes o valor nominal, isso garante uma diferenciação maior dos dados. Repetiu-se todo o processo e criou-se um novo modelo, obtendo a nova matriz de confusão apresentada na Figura 21.

Justamente como esperado, os novos dados são bastante distintos, o que permitiu ao modelo de rede neural aprender os padrões mais facilmente. Essa distinção aperfeiçoou inclusive a acurácia do modelo, chegando a 0.991587. Porém, é importante salientar que este novo cenário de sobrecarga se caracteriza como algo muito além do valor inicial, ou seja, dificilmente o motor partiria, tornando essa análise desnecessária.


Figura 21 - Nova Matriz de Confusão



Fonte: Próprio autor (2023).

Na figura 22 é possível ver a curva ROC que é construída traçando a taxa de verdadeiros positivos (sensibilidade) no eixo das ordenadas contra a taxa de falsos positivos (1 - especificidade) no eixo das abscissas, para diferentes valores de limiares de probabilidade. Cada ponto na curva representa o desempenho do modelo em um limiar específico. Nota-se que a maioria das classes tem valores 1.00, isso indica que o modelo está fazendo ótimas previsões para essas classes. Entretanto, a classe 0 e classe 7, que correspondem à classe “Normal” e classe “Sobrecarga” respectivamente, apresentam valores de 0.97, ainda sendo um valor ótimo, porém destaca as condições verificadas nas análises anteriores.

Figura 22 - Área Sob a Curva ROC.



4.2 Teste de identificação das falhas


O teste de generalização é feito apresentando valores não vistos à rede neural com o objetivo de testar de forma prática o aprendizado. Os teste de falta de fase não foram refeitos pois o comportamento seria o mesmo, independente da fase.

Inicialmente foram testados a subtensão e sobretensão. Verificou-se que o modelo correspondeu adequadamente aos dois casos, interpretando corretamente os valores, e os rotulando corretamente. Apesar de 229 V estar na faixa adequada de tensão, o modelo interpretou como sobretensão, considerando que este valor está mais próximo dos níveis de tensões definidos inadequados, pode-se considerar como acerto.

O teste seguinte foi para carga desbalanceada, novamente a rede neural interpretou corretamente as duas situações, o que apesar de surpreendente, não é difícil de entender o motivo, isso justamente pelas características dessa situação. A carga ao estar desbalanceada, mesmo que pouco, tem aspectos específicos. Ao analisar e comparar as gráficos de torque e RPM do funcionamento normal e do desvio


de 1 cm, nota-se a distinção dos casos. A partir da análise das figuras 23 e 24, é possível verificar as ondulações nas curvas, características do desbalanceamento. Assim, não houve dificuldade da rede neural diferenciar um ou outro.

Figura 23 - RPM e Torque na partida do motor em condições normais.



Fonte: Próprio autor (2023).

Figura 24 - RPM e Torque na partida do motor em desbalanceamento de carga.



Fonte: Próprio autor (2023).

Por fim, testou-se a classificação de sobrecarga, optou-se por um valor de sobrecarga menor que o de 2,5 vezes a carga nominal utilizado, justamente para encontrar o limiar em que a rede neural o confunde com funcionamento normal. Devido às análises anteriores, esperou-se um certa dificuldade de acertos da rede neural. Optou-se pelo valor de duas vezes a carga nominal.

Ao utilizar duas vezes a carga nominal, a rede neural o interpretou como funcionamento normal. Considerando que o fator de serviço é de 1,25, pode-se afirmar que esse valor está de fato enquadrado como sobrecarga, porém a rede neural não foi capaz de identificar. Portanto, a diferenciação não ocorreu adequadamente, implicando na limitação ou falta de sensibilidade da rede neural para detectar situações de sobrecarga, a menos que sejam mais acentuadas.

5 CONSIDERAÇÕES FINAIS

O presente estudo explorou a aplicação de Redes Neurais Multilayer Perceptron (MLP) na identificação de falhas em motores de indução trifásicos, utilizando uma base de dados gerada por um modelo computacional. Os resultados obtidos indicam avanços significativos, mas também apontam para considerações importantes.

Os pontos fortes do método foram evidenciados pelos excelentes resultados em categorias específicas, como Falta de fase A, B, C, Subtensão, Sobreensão e Carga Desbalanceada. A curva de aprendizado da rede MLP durante as épocas de treinamento demonstrou uma convergência eficaz da acurácia e das perdas. Entretanto, a dificuldade encontrada na diferenciação entre as classes "Normal" e "Sobrecarga" indica limitações na sensibilidade do modelo, especialmente em situações de sobrecarga menos pronunciadas. Esse desafio destaca a importância de futuras investigações e ajustes na arquitetura da rede para aprimorar a capacidade de distinção nessas condições específicas.

Os testes de generalização, embora tenham demonstrado eficácia na detecção de várias condições de falha, destacaram a necessidade de considerar cuidadosamente a aplicabilidade prática do modelo. A dificuldade em identificar sobrecargas menos acentuadas demonstra a importância de ajustes adicionais e validações específicas para situações reais de operação.

Esses resultados ressaltam a relevância do estudo no contexto do monitoramento de motores elétricos, oferecendo uma base sólida para futuras pesquisas e melhorias na aplicação de Redes Neurais MLP. A compreensão das limitações identificadas contribui para direcionar esforços na busca por soluções mais e confiáveis, visando a implementação prática desses modelos em ambientes industriais.

Como sugestões de trabalhos futuros:

- Implementação das técnicas utilizadas em um motor real, para obtenção de resultados mais robustos, que reflitam melhor as condições reais de operação.

- Explorar outras arquiteturas de redes neurais, como Redes Neurais Convolucionais (CNNs) para analisar a capacidade de diferenciação entre as classes. Além de fazer uma comparação com a arquitetura MLP utilizada neste trabalho.
- Investigar outras técnicas de pré-processamento de dados além da wavelet, para melhorar a qualidade e a eficácia do treinamento da rede neural.

REFERÊNCIAS

ABB. **Industrial performance motors**. 2010. Disponível em: <https://library.e.abb.com>. Acesso em: 30 nov. 2023.

BRITO, Jorge Nei. **Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos**. 2002. Tese (Doutorado em Engenharia Mecânica) - Universidade Estadual de Campinas.

CALLISTER, William D.; RETHWISCH, David G. **Ciência e Engenharia de Materiais: Uma introdução**. 9ª. ed., 2016.

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

DEL FRATE, Fabio; PACIFICI, Fabio; SCHIAVON, Giovanni; SOLIMINI, Chiara. Use of Neural Networks for Automatic Classification From High-Resolution Images. **IEEE Transactions on Geoscience and Remote Sensing**, 2007.

FERREIRA, Felipe Matheus de Souza. **Estudo de parâmetros característicos de motores de indução trifásicos e análise dos distúrbios causados à rede elétrica em regime transitório**. 2018. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) - Instituto Federal De Educação, Ciência E Tecnologia Da Bahia, Paulo Afonso, BA.

FITZGERALD, A. E.; KINGSLEY, Charles; UMANS, Stephen. **Máquinas elétricas**. 7ª. ed., 2014.

GALLIER, Jean. Haar Bases, Haar Wavelets. *In: FUNDAMENTALS of Linear Algebra and Optimization*, 2024.

GATI, Rodrigo Rossetto. MODELAGEM COMPUTACIONAL NO SIMULINK PARA ANÁLISE NA PARTIDA DIRETA DE MOTORES DE INDUÇÃO TRIFÁSICOS. **Revista Sinergia**, 2015. Disponível em: <https://ojs.ifsp.edu.br/index.php/sinergia/article/view/67>. Acesso em: 20 nov. 2023.

HALLIDAY, David; RESNICK, Robert. **FUNDAMENTOS DE FÍSICA**. 9ª. ed., 2010a. v. 3.

HALLIDAY, David; RESNICK, Robert. **FUNDAMENTOS DE FÍSICA**. 9ª. ed., 2010b. v. 2.

KOLLA, Sri; VARATHARASA, Logan. Identifying three-phase induction motor faults using artificial neural networks. **ISA Transactions**, 2000.

LIMA, Robson Pacífico Guimarães. **Desenvolvimento de um soft sensor para estimação da vazão em sistemas de abastecimento de água utilizando redes neurais artificiais**. 2022. Tese (Bacharelado em Engenharia Mecânica) - Universidade Federal da Paraíba.

MATHWORKS. **Introduction to Wavelet Families**. 2023. Disponível em: <https://www.mathworks.com/help/wavelet/gs/introduction-to-the-wavelet-families.html>. Acesso em: 1 dez. 2023.

MINISTÉRIO DE MINAS E ENERGIA; EMPRESA DE PESQUISA ENERGÉTICA. **Plano Nacional de Energia 2030**. 2007. Disponível em: <https://www.epe.gov.br>. Acesso em: 16 nov. 2023.

OLIVEIRA, Átila Girão de. **Classificadores neurais aplicados na detecção de curto-circuito entre espiras estatóricas em motores de indução trifásicos acionados por conversores de frequência**. 2014. Dissertação (Mestre em Engenharia Elétrica) - Universidade Federal do Ceará.

PERRY, Robert H.; GREEN, Don W. **Perry's Chemical Engineers' Handbook**, 1999.

RHIF, Manel; ABBES, Ali Ben; FARAH, Imed Riadh; MARTÍNEZ, Beatriz; SANG, Yanfang. Wavelet Transform Application for/in Non-Stationary Time-Series Analysis: A Review. **Applied Sciences**, 2019.

SAVALIA, Shalin; EMAMIAN, Vahid. Cardiac Arrhythmia Classification by Multi-Layer Perceptron and Convolution Neural Networks. **Bioengineering**, 4 maio. 2018. Disponível em: <https://www.mdpi.com/2306-5354/5/2/35>. Acesso em: 16 nov. 2023.

SHIRADO, Wilson Hissamu; MOREIRA, Márcio de Abreu; PALMA, Jandira Guenka; JÚNIOR, Sylvio Barbon. Estudo comparativo entre algoritmos das transformadas discretas de Fourier e Wavelet. **Revista Brasileira de Computação Aplicada**, 2015.

SILVA, João Marcus Pereira Lima e. **Aplicação da transformada wavelet packet e redes neurais artificiais para monitoramento de condição de motores de indução**. 2017. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Pernambuco.

SILVA, Marcos Antônio da. **Avaliação De Parâmetros Técnicos E Econômicos Na Substituição De Motores De Indução Trifásicos De 1 CV A 10 CV**. 2009. Dissertação (Mestre em Engenharia Elétrica) - Universidade Federal de Minas Gerais.

SILVA, Paulo César Linhares da. **Aplicação das Wavelets de Daubechies em Conjunto com o Método de Propagação Vetorial de Feixes na Análise de Estruturas Fotônicas**. 2019. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Norte.

TORO, Vincent Del; MARTINS, Onofre de Andrade. **Fundamentos de máquinas elétricas**. 1994.

WEG (Brasil). GUIA DE ESPECIFICAÇÃO MOTORES ELÉTRICOS. Jaraguá do Sul, SC, 2023. 68 p.

WEG. **Danos em Enrolamentos: Motores Trifásicos**. 2019. Disponível em: <https://static.weg.net>. Acesso em: 30 nov. 2023.

ZERBINI, Cinara Brenda. **Estudo de modelos wavelets para auxiliar a gerência de redes**. 2016. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Universidade Estadual de Londrina.

ZHONG, Botao; XING, Xuejiao; LOVE, Peter; WANG, Xu; LUO, Hanbin. Convolutional neural network: Deep learning-based classification of building quality problems. **Advanced Engineering Informatics**, 2019.