



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Monitoramento e diagnóstico de falhas em motores de indução trifásicos utilizando rede neural NARX

Valbério Gonzaga de Araújo

Orientador: Prof. Dr. Andres Ortiz Salazar

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Automação e Sistemas) como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica e de Computação.

Número de ordem PPgEEC: D379
Natal, RN, dezembro de 2024

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Araújo, Valbério Gonzaga de.

Monitoramento e diagnóstico de falhas em motores de indução trifásicos utilizando rede neural NARX / Valbério Gonzaga de Araújo. - 2024.

107 f.: il.

Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Natal, RN, 2024.

Orientador: Prof. Dr. Andres Ortiz Salazar.

1. Inteligência Artificial - Tese. 2. Classificação de Falhas - Tese. 3. Motor de Indução - Tese. 4. Rede Neural NARX - Tese.

I. Salazar, Andres Ortiz. II. Título.

RN/UF/BCZM

CDU 004.8 (043.2)

Monitoramento e diagnóstico de falhas em motores de indução trifásicos utilizando rede neural NARX

Valbério Gonzaga de Araújo

Tese de Doutorado aprovada em 05 de dezembro de 2024 pela banca examinadora composta pelos seguintes membros:

Prof. Dr. Andres Ortiz Salazar (orientador) – DCA/UFRN

Prof. Dr. André Laurindo Maitelli
(Examinador Externo ao Programa) – DCA/UFRN

Prof^ª Dr^a Jossana Maria de Souza Ferreira
(Examinador Externo ao Programa) – DCA/UFRN

Prof. Dr. José Álvaro de Paiva
(Examinador Externo à Instituição) – DIAC/IFRN

Prof. Dr. Juan Moises Mauricio Villanueva
(Examinador Externo à Instituição) – CEAR/UFPB

*À minha esposa, Kilma, aos meus
filhos, Bruno, Késia, Gabriel e aos
meus netos, Benício e Melina pela
paciência durante a realização deste
trabalho.*

Agradecimentos

A Deus, fonte suprema de sabedoria e iluminação, expresso minha profunda gratidão. Nesta jornada de pesquisa e aprendizado, reconheço Sua presença constante, iluminando meu caminho e sustentando-me com força nos momentos de desafio. O conhecimento adquirido e as descobertas alcançadas foram possíveis graças à Sua graça e orientação.

Ao meu estimado professor orientador Dr. Andres Ortiz Salazar. Uma jornada de aprendizado enriquecedor como esta não seria completa sem expressar minha profunda gratidão a alguém cuja orientação, dedicação e sabedoria moldaram cada passo deste percurso.

Ao professor Dr. Juan Moises Mauricio Villanueva, pela inestimável cooperação ao longo deste trabalho. Seu profundo conhecimento em Redes Neurais NARX foi essencial para o desenvolvimento e sucesso desta pesquisa.

À minha querida família (esposa, filhos e netos). Nenhum feito na vida é verdadeiramente significativo sem aqueles que nos apoiam, nos inspiram e compartilham conosco cada passo desta jornada. Esta conquista não é apenas minha, mas nossa, pois cada vitória e desafio foram vividos em conjunto.

Aos meus amigos do Laboratório de Avaliação e Medição de Petróleo (LAMP/UFRN), que compartilharam suas próprias experiências acadêmicas e me ensinaram lições valiosas que não se encontram nos livros, saibam que a aprendizagem foi mútua e enriquecedora.

Resumo

Os motores de indução trifásicos desempenham um papel essencial nas operações industriais. Contudo, falhas nesses equipamentos podem ocasionar sérios problemas operacionais, afetando a produtividade e a segurança. Tradicionalmente, a identificação de falhas em motores de indução tem sido realizada por meio de técnicas convencionais, como análise no domínio do tempo e da frequência, utilizando assinaturas características de vibração e corrente. Essas abordagens, embora eficazes em alguns casos, enfrentam limitações em termos de precisão e capacidade de lidar com grandes volumes de dados complexos, especialmente em condições operacionais variáveis. Diante dessas dificuldades, este trabalho propõe a aplicação de uma técnica de Inteligência Artificial (IA) para diagnóstico e classificação de falhas, com o objetivo de identificar problemas nos estágios iniciais, de forma mais eficiente e robusta, superando as limitações das abordagens tradicionais. A análise foi conduzida com base em sinais de corrente, temperatura e vibração. Os experimentos foram realizados em uma bancada de testes, simulando condições reais de operação, incluindo desbalanceamento de fase no estator, danos nos rolamentos e desbalanceamento do eixo. Para a classificação das falhas, foi desenvolvida uma Rede Neural Auto-Regressiva com Entradas Exógenas (NARX), uma arquitetura preditiva ajustada para realizar tarefas de classificação. A configuração ideal da rede foi determinada por meio de um processo de seleção que utilizou o método de varredura com múltiplas iterações de treinamento, seguido da introdução de novos dados para validação de sua eficiência. Os testes realizados com os dados adicionais demonstraram o alto desempenho da rede neural, evidenciando sua capacidade de generalização em todas as condições avaliadas. As taxas de acurácia obtidas variaram entre 94,2% e 98%, dependendo do estado operacional da máquina.

Palavras-chave: Inteligência Artificial; Classificação de Falhas; Motor de Indução; Rede Neural NARX.

Abstract

Three-phase induction motors play a crucial role in industrial operations. However, failures in these machines can lead to significant operational issues, affecting both productivity and safety. Traditionally, fault detection in induction motors has been carried out using conventional techniques, such as time and frequency domain analysis, utilizing characteristic signatures from vibration and current. Although these approaches can be effective in some cases, they face limitations in terms of accuracy and their ability to handle large volumes of complex data, particularly under variable operational conditions. In light of these challenges, this study proposes the application of an Artificial Intelligence (AI) technique for fault diagnosis and classification, aiming to identify issues at early stages more efficiently and robustly, overcoming the limitations of traditional methods. The analysis was conducted using current, temperature, and vibration signals. Experiments were carried out on a test bench, simulating real operational conditions, including stator phase unbalance, bearing damage, and shaft misalignment. For fault classification, an Auto-Regressive Neural Network with Exogenous Inputs (NARX) was developed, a predictive architecture tailored for classification tasks. The optimal network configuration was determined through a selection process using a scanning method with multiple training iterations, followed by the introduction of new data to validate its efficiency. Tests conducted with the additional data demonstrated the high performance of the neural network, showcasing its ability to generalize across all evaluated conditions. The accuracy rates ranged from 94.2% to 98%, depending on the machine's operational state.

Keywords: Artificial Intelligence; Fault Classification; Induction Motor; NARX Neural Network.

Sumário

Lista de Figuras	iii
Lista de Tabelas	vi
Lista de Símbolos e Abreviaturas	vii
1 Introdução	1
1.1 Objetivo geral	4
1.2 Objetivos específicos	4
1.3 Justificativa	5
1.4 Contribuições	5
1.5 Organização da Tese	7
2 Trabalhos relacionados	8
2.1 Principais Trabalhos Relacionados ao Tema	8
2.2 Conclusão	12
3 Fundamentação Teórica	14
3.1 Motores de Indução Trifásicos	14
3.1.1 Componentes do motor de indução trifásico	15
3.1.2 Princípio de funcionamento	17
3.1.3 Falhas em motores de indução trifásicos	18
3.1.4 Tipos de falhas	19
3.2 Métodos de Detecção e Classificação de Falhas	20
3.2.1 Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo	20
3.2.2 Aplicação de Métodos de IA na Detecção de Falhas em MITs	21
3.2.3 Aprendizado de Máquina	22
3.2.4 Aprendizado Profundo	23
3.2.5 Tipos de função de ativação	25
3.2.6 Algoritmos de treinamento	28
3.2.7 Arquiteturas de RNAs	29
3.2.8 Rede Neural NARX	31
3.2.9 Aprendizado da rede neural	32
3.3 Métricas de avaliação	34
3.3.1 Métricas de avaliação para regressão	34

3.3.2	Métricas de avaliação para classificação	35
3.4	Conclusão	38
4	Materiais e métodos	39
4.1	Metodologia	39
4.2	Materiais - Bancada de Testes	40
4.3	Materiais - Sensores	42
4.3.1	Medição de Corrente	42
4.3.2	Medição de vibração	45
4.3.3	Medição de temperatura	46
4.4	Processamento de dados	47
4.4.1	Código e Diagrama de Blocos no LabVIEW	48
4.5	Construção do <i>dataset</i>	50
4.6	Ajustes da rede neural NARX	51
4.7	Conclusão	52
5	Experimentos e resultados	53
5.1	Cenários para coletas de dados	53
5.1.1	Cenário 1: Motor em boas condições de operação	53
5.1.2	Cenário 2: Motor com eixo desbalanceado	56
5.1.3	Cenário 3: Motor com rolamentos defeituosos	59
5.1.4	Cenário 4: Motor com desequilíbrio de corrente no estator	63
5.2	Treinamento, validação e teste da rede neural NARX	67
5.2.1	Aplicando ruído nos sinais do motor.	70
5.3	Validação da rede neural NARX para novos dados	72
5.3.1	Cenário 1 – Validação da rede – Motor sem defeito.	72
5.3.2	Cenário 2 – Validação da rede – Defeito Desbalanceamento.	75
5.3.3	Validação da rede NARX – Rolamentos com defeito.	77
5.3.4	Validação da rede NARX - Estator com defeito.	80
5.4	Resultados	82
5.5	Comparando os Resultados	83
5.6	Conclusão	84
6	Conclusão	85
6.1	Trabalhos futuros	86
	Referências bibliográficas	87

Lista de Figuras

1.1	Máquina elétrica.	1
1.2	Motores de indução.	2
2.1	Trabalhos relacionados ao tema.	13
3.1	Classificação de Motores.	15
3.2	Componentes de um MIT.	16
3.3	Sistema de corrente alternada trifásica.	17
3.4	Classificação das falhas em motores.	20
3.5	Fluxograma IA.	21
3.6	Estrutura do aprendizado de máquina.	23
3.7	Modelo matemático de um Neurônio Artificial.	24
3.8	Função de Ativação Linear.	25
3.9	Função de Ativação Sigmoides.	26
3.10	Função de Ativação Tangente hiperbólica.	27
3.11	Função de Ativação ReLu.	27
3.12	Rede <i>Feedforward</i> de uma camada.	29
3.13	Rede <i>Feedforward</i> de múltiplas camadas.	30
3.14	Rede recorrente ou realimentada.	30
3.15	Sistema dinâmico da rede neural NARX.	31
3.16	Aprendizado supervisionado.	33
3.17	Aprendizado não supervisionado.	33
3.18	Aprendizado por reforço.	34
3.19	Curva ROC.	37
3.20	Matriz de confusão multiclasse.	38
4.1	Fluxograma de aquisição de dados.	40
4.2	Bancada de testes.	41
4.3	Motor de indução trifásico.	41
4.4	Sensor de corrente.	42
4.5	Sinal na saída do sensor.	43
4.6	Circuito de Condicionamento de Corrente.	44
4.7	Placa condicionadora de Corrente.	44
4.8	Forma de onda senoidal com valor de <i>offset</i>	45
4.9	Sensor acelerômetro de vibração.	45
4.10	Sensor de temperatura.	47
4.11	NI USB 6008.	48

4.12	Diagrama de blocos <i>LabVIEW</i>	49
4.13	Rede neural NARX adaptada.	52
5.1	Sensores instalados no motor.	54
5.2	Sinal de vibração no domínio do tempo.	54
5.3	Sinal de vibração no domínio da frequência.	55
5.4	Sinal de corrente no domínio do tempo.	55
5.5	Sinal de corrente no domínio da frequência.	55
5.6	Sinal de temperatura do motor em boas condições de operação.	56
5.7	Instalação da massa para desbalanceamento do eixo.	57
5.8	Sinal de vibração no domínio do tempo.	57
5.9	Sinal de vibração no domínio da frequência.	58
5.10	Sinal de corrente no domínio do tempo.	58
5.11	Sinal de corrente no domínio da frequência.	58
5.12	Sinal de temperatura para motor desbalanceado.	59
5.13	Cálculo das frequências rotacional e sobrerolagem – 6203–2Z.	60
5.14	Cálculo das frequências rotacional e sobrerolagem – 6204–2Z.	60
5.15	Rolamentos defeituosos – 6203–2Z / 6204–2Z.	61
5.16	Sinal de vibração no domínio do tempo.	61
5.17	Sinal de vibração no domínio da frequência.	61
5.18	Sinal de corrente no domínio do tempo.	62
5.19	Sinal de corrente no domínio da frequência.	62
5.20	Sinal de temperatura motor rolamento com defeito.	62
5.21	Banco de resistores para desequilíbrio de corrente.	63
5.22	Sinal de vibração no domínio do tempo.	64
5.23	Sinal de vibração no domínio da frequência.	64
5.24	Sinal de corrente no domínio do tempo – Fase 1.	64
5.25	Sinal de corrente no domínio da frequência – Fase 1.	65
5.26	Sinal de corrente no domínio do tempo – Fase 2.	65
5.27	Sinal de corrente no domínio da frequência - Fase 2.	65
5.28	Sinal de corrente no domínio do tempo – Fase 3.	66
5.29	Sinal de corrente no domínio da frequência – Fase 3.	66
5.30	Sinal de temperatura motor – desequilíbrio de fase.	66
5.31	Curva limite de erro do conjunto de teste padrão.	68
5.32	Curva ROC do conjunto de teste padrão.	68
5.33	Matriz de confusão do conjunto de teste padrão.	69
5.34	Número de falhas classificadas no conjunto de teste padrão.	69
5.35	Curva de Acurácia x SNR.	71
5.36	Curva limite de erro – Motor sem defeito.	73
5.37	Curva ROC – Motor sem defeito.	73
5.38	Matriz de confusão – Motor sem defeito.	74
5.39	Falhas classificadas – Motor sem defeito.	74
5.40	Curva desempenho – defeito desbalanceamento.	75
5.41	Curva limite de erro – Defeito desbalanceamento.	76
5.42	Matriz de confusão – Defeito desbalanceamento.	76

5.43	Número de falhas classificadas – Defeito desbalanceamento.	77
5.44	Curva limite do erro – Rolamentos com defeito.	78
5.45	Curva ROC – Rolamentos com defeito.	78
5.46	Matriz de confusão – Rolamentos com defeito.	79
5.47	Número de falhas classificadas – Rolamentos com defeito.	79
5.48	Curva limite do erro – Estator com defeito.	80
5.49	Curva ROC – Estator com defeito.	81
5.50	Matriz de confusão – Estator com defeito.	81
5.51	Número de falhas classificadas – Estator com defeito.	82

Lista de Tabelas

1.1	Publicações em congressos e revistas.	6
1.2	Publicações em congressos e revistas.	7
4.1	Características do MIT.	42
4.2	Características do sensor de corrente.	43
4.3	Características do acelerômetro.	46
4.4	Características do sensor de temperatura.	47
4.5	Características do NI-USB-6008.	48
4.6	Melhores hiperparâmetros encontrados.	52
5.1	Desempenho da rede neural NARX treinada.	70
5.2	Desempenho da rede neural NARX – Motor sem defeito.	75
5.3	Desempenho da rede neural NARX – Defeito desbalanceamento.	77
5.4	Desempenho da rede neural NARX – Rolamentos com defeito.	80
5.5	Desempenho da rede neural NARX – Estator com defeito.	82
5.6	Desempenho da rede neural NARX para cada tipo de falha classificada.	82
5.7	Comparação com trabalhos publicados.	84

Lista de Símbolos e Abreviaturas

ϕ	phi
n	Velocidade nominal
n_s	Velocidade de campo magnético girante
S	Escorregamento
ARM	Acorn RISC Machine
CA	Corrente Alternada
CC	Corrente Contínua
CIGRE	Conseil International des Grands Réseaux Électriques
DCO	Componentes Ortogonais
DL	Deep Learning
DTC	Direct torque control
FFT	Fast Fourier Transform
FISs	Fuzzy Inference Systems
FN	Falso Negativo
FP	Falso Positivo
GAs	Genetic Algorithms
hertz	Unidade de frequência
HP	Horse Power
Hz	hertz
IA	Inteligência Artificial
IEEE	Institute of Electrical and Electronics Engineers
k-NN	k-Nearest Neighbors


LSTM	Long and Short Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MEMS	Micro-Electro-Mechanical Systems
MIT	Motor de Indução Trifásico
ML	Machine Learning
MLP	Multi-Layer Perceptron
MSE	Mean Squared Error
NARX	Nonlinear Autoregressive with Exogenous Inputs
NEMA	National Electrical Manufacturers Association
PMC	Perceptron Multicamadas
RBF	Radial Basis Function.
RF	Random Forest
RMS	Root Mean Square
RMSE	Root Mean Square Error
RNA	Rede Neural Artificial
RNR	Rede Neural Recorrente
ROC	Receiver Operating Characteristic
rpm	rotações por minuto
STFT	Short Time Fourier Transform
SVM	Support Vectors Machine
TFDA	Time-Frequency Domain Analysis
UFRN	Universidade Federal do Rio Grande do Norte
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Capítulo 1

Introdução

As máquinas elétricas são dispositivos que realizam a conversão da energia mecânica para a energia elétrica e vice-versa. Quando a conversão ocorre da energia mecânica para elétrica, essas máquinas são chamadas de geradores; já quando realizam a conversão da energia elétrica para a mecânica, são denominadas de motores (Chapman 2013). Elas desempenham um papel crucial em diversos setores, desde a indústria até o cotidiano, permitindo que diversas aplicações funcionem de maneira eficiente e confiável. Esses equipamentos podem ser classificados em duas categorias: as máquinas elétricas rotativas, que incluem motores e geradores, e as máquinas elétricas estacionárias, com aplicações específicas em sistemas de energia. A Figura 1.1 apresenta uma representação esquemática do modelo de máquina rotativa.

Figura 1.1: Máquina elétrica.



Fonte: Adaptado WEG (2023).

Dentro desse contexto, os motores elétricos, em especial os motores de indução, ilustrados pela Figura 1.2, destacam-se pela sua ampla aplicação na indústria moderna. O uso extensivo dos motores de indução pode ser atribuída a uma combinação de fatores,

incluindo sua relação custo-benefício favorável, que resulta em uma excelente relação entre tamanho e potência. Além disso, a ausência de contatos móveis e ímãs permanentes, aliada à simplicidade construtiva, não apenas facilita o processo de fabricação, mas também contribui para a confiabilidade e durabilidade desses dispositivos (Perin 2017).

Figura 1.2: Motores de indução.



Fonte: Adaptado WEG (2023).

Os motores elétricos são responsáveis por 95% de todos os acionamentos em países altamente industrializados (Nóbrega-Sobrinho 2015). No Brasil, por exemplo, o setor industrial demanda 31,6% do consumo de eletricidade, com os motores elétricos representando 68% desse consumo, evidenciando um potencial substancial para a implementação de medidas de eficiência energética (Santos et al. 2022). Em termos práticos, esses motores estão sujeitos a estresses inevitáveis, decorrentes de variações ambientais, térmicas, mecânicas, magnéticas e elétricas, que podem resultar em falhas operacionais. Se essas falhas não forem detectadas e mitigadas a tempo, podem ocasionar paradas inesperadas, impactando negativamente a eficiência industrial e gerando riscos tanto para os equipamentos quanto para os operadores (Ojaghi & Mohammadi 2016).

O cenário industrial contemporâneo caracteriza-se por um aumento significativo da competitividade, impulsionado pela crescente complexidade de máquinas e equipamentos, os quais são produtos de alta demanda. Além disso, os elevados custos associados às instalações industriais, juntamente com a crescente preocupação com a segurança industrial e a preservação do meio ambiente, têm levado as grandes indústrias globais a investir cada vez mais em dispositivos, tecnologias e ferramentas voltadas para a previsão e predição de falhas decorrentes de não conformidades e avarias em máquinas, equipamentos e instalações industriais (Silva-Júnior 2018). Nesse contexto, a manutenção de equipamentos emerge como um dos maiores gastos dentro de um processo de fabricação. A detecção precoce de falhas incipientes é crucial, pois, se essas falhas não forem

identificadas a tempo, podem evoluir para quebras totais, resultando em interrupções na produção e prejuízos substanciais (Lyra 2019).

Conforme discutido por Alsaedi (2015), aproximadamente 40-50% das falhas em motores de indução estão relacionadas a defeitos mecânicos. Essas falhas podem ser classificadas em duas categorias principais: i) danos nos rolamentos de elementos rolantes, e ii) excentricidade. Os rolamentos, sendo componentes críticos no sistema mecânico dos motores, podem sofrer danos na pista externa, pista interna, nas esferas ou nos rolos, comprometendo a integridade do motor. O desenvolvimento dessas falhas está intrinsecamente ligado a fatores como vibrações, tensões internas, excentricidade inerente e correntes de rolamento. Além disso, a temperatura de operação desempenha um papel crucial na vida útil dos rolamentos, sendo essencial que não ultrapasse os limites especificados para as condições de carga nominal. Sheikh et al. (2022) destacam que o desequilíbrio de tensão na fonte de alimentação é outro fator crítico que não deve ser negligenciado, pois resulta em um aumento significativo das correntes do estator, o que, por sua vez, eleva as perdas por efeito Joule no cobre e constitui uma das principais causas do aumento da temperatura do motor. Os motores de indução convencionais são projetados para operar em temperaturas ambientes de até 40°C; ultrapassar esse limite pode induzir estresse térmico, afetando a confiabilidade e a durabilidade do motor.

Considerando as limitações econômicas associadas à instalação de múltiplas unidades de motor reserva, monitoramento contínuo das máquinas de indução torna-se imperativo para garantir tanto a operação segura quanto a manutenção da qualidade do produto. Nessa perspectiva, a implementação de estratégias eficazes de monitoramento, detecção, classificação e diagnóstico de falhas é essencial para preservar o desempenho ideal do equipamento ao longo do tempo. Dentre as técnicas disponíveis, destacam-se tanto abordagens invasivas quanto não invasivas, sendo estas últimas amplamente utilizadas devido à sua natureza menos intrusiva. Recentemente, o uso de técnicas de Inteligência Artificial (IA) tem ganhado destaque como uma solução avançada para a detecção não invasiva de falhas em máquinas. Especificamente, métodos de diagnóstico de falhas baseados em inteligência computacional, como Redes Neurais Artificiais (RNAs), Sistemas de Inferência Fuzzy FISs (do inglês, *Fuzzy Inference Systems*) e Algoritmos Genéticos GAs (do inglês, *Genetic Algorithms*), têm demonstrado resultados promissores na identificação precisa e eficiente de falhas em motores de indução trifásicos (Okpo et al. 2023).

Embora as técnicas de IA tenham se destacado recentemente no monitoramento e diagnóstico de falhas em motores de indução, a literatura também apresenta diversos métodos convencionais não invasivos que continuam a desempenhar um papel importante, especialmente devido à sua simplicidade e rapidez de implementação. O diagnóstico de falhas utilizando técnicas convencionais, em sua maioria, envolve a análise de parâmetros como vibração, tensão, corrente, torque e velocidade (Broniera et al. 2013). Entre os métodos tradicionais amplamente adotados na literatura, destaca-se a Análise no Domínio do Tempo-Frequência TFDA (do inglês, *Time-Frequency Domain Analysis*) como uma abordagem eficiente para a detecção de falhas em motores de indução. Por exemplo, Narwade et al. (2013) relatam uma técnica baseada na Transformada Rápida de Fourier FFT (do inglês, *Fast Fourier Transform*) para analisar as assinaturas de vibração e corrente do motor, visando a detecção de falhas tanto mecânicas, como danos nos rolamentos, quanto

elétricas, como desequilíbrio na tensão de alimentação ou condições de fase única. A análise espectral de *Fourier* é empregada para extrair características específicas que indicam a presença de falhas, observando que falhas mecânicas e elétricas geram padrões de frequência distintivos no espectro de corrente e vibração, que podem ser identificados ao comparar as amplitudes de certos componentes de frequência em condições normais e de falha. Complementando essas técnicas, Almounajjed et al. (2021) utilizam a transformada *Wavelet* discreta para a detecção de falhas de curto-circuito entre espiras em estatores de motores de indução. Contudo, é importante notar que os métodos baseados no domínio Tempo-Frequência podem ser altamente sensíveis ao ruído nos sinais medidos, o que pode mascarar falhas reais e dificultar a detecção precisa.

Embora as técnicas convencionais ofereçam uma base sólida para o diagnóstico de falhas em motores de indução, suas limitações, como a sensibilidade ao ruído, destacam a necessidade de métodos mais robustos e precisos. Nesse contexto, o presente trabalho propõe a utilização de técnicas de IA para diagnosticar e classificar falhas relacionadas ao desequilíbrio do eixo, danos no estator e danos nos rolamentos em motores de indução trifásicos. O diagnóstico será realizado através do monitoramento de sinais de corrente, vibração e temperatura, com o objetivo de alcançar uma maior precisão na identificação dessas falhas mecânicas e elétricas. A proposta principal é explorar o poder da IA para analisar grandes volumes de dados, identificar padrões complexos e, assim, permitir intervenções mais precisas e eficazes na manutenção preventiva dos equipamentos. Para a classificação de falhas, foi desenvolvida uma Rede Neural Auto-Regressiva com Entradas Exógenas NARX (do inglês, *Nonlinear Autoregressive with Exogenous Inputs*), um tipo de rede preditiva que foi adaptada por meio de seus hiperparâmetros para realizar tarefas de classificação. Para validar o método proposto, este trabalho delinea quatro cenários de testes distintos, cada um projetado para representar diferentes condições operacionais do motor. Esses cenários são cruciais, pois permitem a coleta de leituras abrangentes dos sinais do motor em várias situações, o que é essencial para demonstrar a eficácia do diagnóstico baseado em IA.

1.1 Objetivo geral

O objetivo geral deste trabalho é desenvolver e aplicar uma rede neural NARX para o monitoramento e a classificação de falhas em motores de indução trifásicos, com a finalidade de detectar falhas em estágios iniciais, aprimorar a precisão do diagnóstico e garantir a continuidade das operações industriais, minimizando custos com manutenções não programadas e paradas inesperadas.

1.2 Objetivos específicos

Os objetivos específicos são:

1. **Coletar dados de operação de um Motor de Indução Trifásico (MIT)**, incluindo medições de corrente nas fases, temperatura e vibração, utilizando sensores apropriados e a interface DAQUSB-6008, para análise posterior de falhas;

2. **Desenvolver um sistema no LabVIEW**, para o processamento dos sinais coletados e geração de um arquivo estruturado, que será utilizado na construção do *dataset* para treinamento da rede neural;
3. **Projetar e implementar uma Rede Neural Auto-Regressiva com Entradas Exógenas (NARX)**, com o objetivo de diagnosticar e classificar falhas em motores de indução trifásicos, com base nos dados coletados;
4. **Treinar, validar e testar a rede neural NARX**, para otimizar sua precisão e desempenho na identificação e classificação das falhas propostas, ajustando parâmetros relevantes como número de camadas e neurônios;
5. **Validar a rede neural utilizando novos dados**, avaliando sua capacidade de generalização e robustez em condições operacionais diferentes daquelas utilizadas no treinamento;
6. **Comparar os resultados obtidos com a rede neural NARX**, com outras abordagens de diagnóstico utilizadas em pesquisas anteriores.

1.3 Justificativa

Os motores elétricos de indução trifásicos são componentes essenciais para o funcionamento de diversas indústrias, sendo responsáveis por grande parte das operações produtivas. A alta dependência desses motores nas linhas de produção torna sua manutenção preventiva e diagnóstico de falhas uma necessidade estratégica, visando minimizar paradas não programadas e maximizar a eficiência operacional. Embora técnicas tradicionais de monitoramento e diagnóstico tenham sido amplamente utilizadas, elas apresentam limitações em termos de precisão e capacidade de lidar com grandes volumes de dados gerados nas condições dinâmicas dos processos industriais.

A aplicação de tecnologias avançadas de inteligência artificial (IA), especialmente as redes neurais artificiais, oferece um potencial significativo para superar essas limitações, proporcionando diagnósticos mais rápidos, precisos e adaptáveis. No entanto, apesar dos avanços nas últimas décadas, ainda existem lacunas relevantes, particularmente no que diz respeito à integração de IA em ambientes industriais variados e à interpretação eficaz dos dados coletados. A presente pesquisa busca preencher essas lacunas ao explorar novas abordagens para o diagnóstico de falhas em motores de indução trifásicos, com o objetivo de desenvolver soluções mais confiáveis e eficientes, que atendam às exigências das indústrias modernas e contribuam para a melhoria contínua dos processos produtivos.

1.4 Contribuições

A principal contribuição deste trabalho consiste no desenvolvimento e adaptação de uma rede neural NARX, comumente empregada em tarefas de predição, para atuar como um algoritmo eficiente de classificação de falhas em motores de indução trifásicos. Essa abordagem explora as capacidades não-lineares e autoregressivas da rede NARX, integrando-as ao contexto industrial, a fim de aprimorar a detecção e categorização de falhas. Além

disso, a proposta busca oferecer maior precisão e aplicabilidade em cenários reais, onde dados de diferentes naturezas são frequentemente combinados.

Em relação às contribuições diretas deste trabalho, destacam-se dois artigos publicados em anais de congressos e revistas, listados na Tabela 1.1.

Evento	Título	Autores
17TH Brazilian Power Electronics Conference 8TH IEEE Southern Power Electronics Conference-COBEP-2023-Florianopolis, Brazil	Application of Artificial Intelligence Techniques for Monitoring and Fault Diagnosis in Three-Phase Induction Motors	Valbério Gonzaga de Araújo, Rodrigo de Andrade Teixeira, Thiago Figueiredo do Nascimento, Andres Ortiz Salazar, Diego Antonio de Moura Fonseca
Publicação de artigo na revista Energies 2024; https://doi.org/10.3390/17184609	Monitoring and diagnosing faults in induction motors three-phase systems using NARX neural network	Valbério Gonzaga De Araújo, Aziz Oloroun-Shola Bissiriu, Juan Moises Mauricio Villanueva, Elmer Rolando Llanos Villarreal, Andrés Ortiz Salazar, Rodrigo de Andrade Texeira, Diego Antonio de Moura Fonsêca

Tabela 1.1: Publicações em congressos e revistas.

Além das produções científicas detalhadas na Tabela 1.1, durante o período de doutorado também foram desenvolvidas outras duas publicações de forma indireta. Essas publicações, listadas na Tabela 1.2, representam uma extensão dos esforços investigativos e refletem a interdisciplinaridade e a aplicabilidade prática dos conhecimentos gerados ao longo do doutorado. Embora não estejam diretamente vinculadas aos objetivos principais da pesquisa, elas ilustram a contribuição acadêmica e científica adicional proporcionada pelo trabalho desenvolvido.

Evento	Título	Autores
2021 IEEE XXVIII International Conference on Electronics, Electrical Engineering and Computing (INTERCON)-Lima, Peru	Study and speed control of a Pipeline Inspection Gauge (PIG).	Salazar, Andrés and Araujo, Valberio and Lima, Gustavo and Freitas, Victor
Publicação de artigo na revista Sensors 2022, 22(23), 9162; https://doi.org/10.3390/s22239162	Velocity Prediction of a Pipeline Inspection Gauge (PIG) with Machine Learning	Victor Carvalho Galvão De Freitas, Valbério Gonzaga De Araujo, Daniel Carlos de Carvalho Crisóstomo, Gustavo Fernandes De Lima, Adrião Duarte Dória Neto and Andrés Ortiz Salazar

Tabela 1.2: Publicações em congressos e revistas.

1.5 Organização da Tese

Esta tese está organizada em seis capítulos. O Capítulo 1 oferece uma introdução abrangente, na qual são delineados os objetivos da pesquisa, as justificativas que a sustentam e as contribuições propostas. O Capítulo 2 apresenta uma discussão sobre os trabalhos correlatos, analisando estudos anteriores e situando a pesquisa no contexto acadêmico existente. No Capítulo 3, é apresentada a fundamentação teórica que embasa o trabalho, com uma abordagem dos conceitos e teorias essenciais sobre motores de indução trifásicos, as falhas mais frequentes nesses motores, além das técnicas de inteligência artificial, aprendizado de máquina e aprendizado profundo. O Capítulo 4 detalha os materiais e métodos empregados, descrevendo a abordagem metodológica adotada e os procedimentos experimentais realizados. O Capítulo 5 é dedicado à apresentação e análise dos resultados obtidos. Por fim, o Capítulo 6 traz as conclusões, sintetizando as principais contribuições do trabalho e sugerindo possíveis direções para estudos futuros.

Capítulo 2

Trabalhos relacionados

O monitoramento de falhas em motores de indução trifásicos tem sido objeto de intenso estudo devido à sua relevância para a eficiência operacional e a redução de custos em aplicações industriais. Diversos pesquisadores têm se dedicado ao desenvolvimento de métodos e tecnologias que aprimorem a identificação e o diagnóstico precoce de falhas nesses motores, dada sua ampla utilização em processos industriais críticos.

2.1 Principais Trabalhos Relacionados ao Tema

Ramalho et al. (2014), propuseram uma abordagem para o monitoramento de condições operacionais de motores de indução trifásicos baseada na extração das características de sinais de vibração utilizando um acelerômetro MEMS (do inglês, *micro electro mechanical system*). Os dados são extraídos da decomposição do sinal de vibração por transformada Haar e através da dimensão fractal, são utilizadas para treinar uma rede neural ELMAN. Embora essa abordagem tenha mostrado resultados promissores, o uso exclusivo de sinais de vibração pode limitar a generalização do método para outros tipos de falhas em motores de indução.

Vitor et al. (2014), apresentaram estratégias para diagnóstico e predição de defeitos e falhas em motores de indução como uma ferramenta alternativa aos modelos tradicionais para detecção de falhas de curto-circuito entre as espiras do estator, quebra das barras do rotor, rolamento em condições normais de funcionamento utilizando redes neurais artificiais com função de base radial. Os sinais de corrente de um motor de indução trifásico submetidos a diversas condições de falhas foram tratados e processados por meio de transformadas no eixo síncrono. Foram realizadas as classificações dos sinais com auxílio da Rede de Função de Base Radial RBF (do inglês, *Radial Base Function*), indicando as amostras referentes aos sinais sem falhas e com os 3 tipos de falhas. Verificou-se que a rede apresentou 1,33% de erro para carregamentos de 1Nm, 2Nm e 3Nm e erro nulo para carregamento de 4Nm e 5Nm. Os resultados experimentais demonstraram que a metodologia utilizada realizou a correta classificação dos sinais.

Jagadanand & Dias (2015), apresentaram uma proposta para implementação de uma técnica de análise de assinatura do motor de indução trifásico para diagnosticar a falha entre espiras do estator utilizando transformada de *Wavelet* e máquina de vetor de suporte como ferramenta de classificação. A técnica proposta foi baseada na análise da corrente

do estator sob condições saudáveis e defeituosas. A decomposição *Wavelet* baseada em algoritmo de levantamento foi implementada no sistema com um processador ARM para reduzir o custo de implementação.

Gongora et al. (2016), apresentaram uma proposta de um método alternativo aos tradicionais para detecção de falhas em rolamentos de motores de indução trifásicos ligados diretamente à rede elétrica utilizando as amplitudes das grandezas de tensão e corrente elétrica tratadas no domínio do tempo, sem a necessidade de manipulação e transformações dos sinais. Com os dados adquiridos em laboratório, foi possível estabelecer uma topologia de RNA capaz de interpretar melhor os sinais utilizados como entrada. Esta abordagem obteve resultados satisfatórios com mais de 99% de acerto para a validação cruzada e cerca de 97% para validação com dados adquiridos de máquinas não utilizadas nos processos de treinamento. A rede proposta foi a *Perceptron* Multicamadas (PMC), constituída de duas camadas ocultas com 7 neurônios cada, além da camada de saída com 2 neurônios para classificação. Aplicou-se também o treinamento supervisionado com o método *backpropagation* acrescido do algoritmo de ML *Levenberg-Maquardt*, estipulando-se como critério de parada o Erro Quadrático Médio (EQM).

Cruz et al. (2017), desenvolveram um sistema híbrido que utiliza dados obtidos de vibração e sensores de corrente para detectar falhas em um estágio inicial, uma vez que cada técnica apresenta limitações e desvantagens quando utilizada individualmente. O sistema realiza aquisições da corrente de armadura do estator e de vibração mecânica a partir de um acelerômetro estrategicamente posicionado e realiza o processamento prévio a partir de uma análise multi-resolução *Wavelet* e transformada de *Fourier* de curta duração STFT (*Short time Fourier Transform*). Os dados obtidos pelo pré-processamento são utilizados como entrada para um sistema *Fuzzy* que realiza o diagnóstico a partir de experiência prévia adquirida. Também foram realizados experimentos com barras quebradas, e o sistema também foi validado para este tipo de falha. O sinal em processamento, e a classificação da gravidade da falha, através da lógica *Fuzzy*, foram desenvolvidos usando Matlab.

Liboni (2017), desenvolveu um sistema automático de diagnóstico de falhas com base em uma nova ferramenta de processamento de sinais elétricos, denominada Decomposição em Componentes Ortogonais (DCO) e ferramentas de aprendizagem de máquina para diagnosticar barras quebradas no rotor de motores de indução trifásicos. Para classificação dos sinais advindos do motor utilizou-se RNAs e SVM. Esse sistema também identifica a severidade das falhas, através da representação do número de barras quebradas no rotor. Foram analisados motores acionados diretamente pela rede elétrica quanto os acionados por inversores de frequência. Os resultados alcançados demonstraram a eficácia das ferramentas matemáticas e computacionais.

Silva-Filho (2017), desenvolveu uma abordagem para diagnosticar defeitos em MIT, por meio de diafragmas piezelétricos de baixo custo e sistemas inteligentes do tipo RNA. Mais especificamente, defeitos elétricos do tipo curto-circuito entre espiras de uma mesma bobina nos estatores dessas máquinas. Através de uma bancada, ensaios com simulações de falhas relacionadas a curto-circuito entre espiras das bobinas do enrolamento do estator, dados foram obtidos de corrente elétrica e vibração do MIT, para o treinamento das arquiteturas de RNA. Após treinamento e validações, os resultados indicaram que a abordagem proposta mostrou-se precisa e robusta.

Kavana & Neethi (2018), apresentaram um sistema de análise de falhas e manutenção preditiva de motor de indução usando aprendizado de máquina. O sistema utilizou um modelo de Rede Neural *Feedforward* para detectar algumas das falhas elétricas mais comuns, como sobretensão, subtensão, fase única, tensão desequilibrada, sobrecarga, falta à terra. Os dados foram coletados em tempo real de um motor de indução trifásico de 1/3 HP, 208V, foram usados para treinar e testar a rede neural. A rede neural desenvolvida classificou todos os dados de teste em suas respectivas classes com quase 100% de precisão.

Kumar et al. (2018), desenvolveram uma modelagem matemática para monitorar a condição de acionamento do motor de indução DTC, utilizando lógica *Fuzzy*. As correntes trifásicas do estator são estimadas e aplicadas como entrada para o sistema *Fuzzy*. Neste modelo, o tempo atua como um parâmetro importante tanto na detecção de falhas quanto na tomada de decisão para ações corretivas adequadas de acordo com o tipo de falha que ocorre.

No estudo de Liu et al. (2018), é apresentada uma revisão abrangente dos algoritmos de Inteligência Artificial (IA) para diagnóstico de falhas em máquinas rotativas, abordando tanto a perspectiva teórica quanto a aplicação industrial. Os métodos discutidos incluem k-vizinhos mais próximos, *Naive Bayes*, máquina de vetor de suporte, redes neurais artificiais e aprendizado profundo, os quais são considerados abordagens potenciais para o diagnóstico de falhas. À medida que as técnicas de IA continuam a amadurecer, espera-se que elas permaneçam como uma ferramenta valiosa e poderosa para o diagnóstico de falhas em máquinas rotativas.

Dias (2019), desenvolveu um sistema de diagnóstico para detecção de falhas e anomalias em aplicações de acionamentos de motores elétricos. Esse sistema baseou-se na coleta e interpretação de dados de processos de redes *Profinet*, perfil *Profidrive*, e ferramentas de aprendizagem de máquina. Foram utilizadas técnicas de extração e redução de atributos nos dados de processo coletados. Utilizou-se algoritmos para reconhecimento de padrões K-NN, RNAs, SVM. Os resultados alcançados demonstraram a eficácia do sistema, sendo capaz de detectar as falhas e anomalias investigadas de maneira satisfatória.

Lyra (2019), desenvolveu um método totalmente não-invasivo para detecção e diagnóstico de falhas em rolamentos de motores de indução trifásicos através da análise do som emitido pelo motor em funcionamento, usando RNA e processamento *Wavelet*. As RNAs *Perceptron* Multicamadas (PMC) e RBF foram utilizadas para validar os dados. O método desenvolvido foi testado, validado e treinado experimentalmente utilizando uma bancada de testes. Nos resultados a PMC apresentou 97% de acerto na detecção, já a RBF apresentou uma média de 90%.

No trabalho de Kandukuri et al. (2019), foi apresentada uma abordagem em duas etapas para a detecção e classificação de falhas em sistemas de acionamento de motores elétricos utilizados em sistemas de *pitch* de turbinas eólicas. A metodologia proposta é adequada para aplicação em parques eólicos *offshore*, tanto para sistemas de *pitch* elétricos acionados por motores de indução quanto por motores síncronos de ímã permanente. A estratégia adotada envolveu a medição do sinal de corrente trifásica dos motores nos acionamentos de *pitch*, utilizando essas medições para detectar falhas e alimentar um classificador baseado em SVM. O método proposto foi validado em um ambiente de teste

interno do sistema de acionamento de *pitch*. O classificador SVM demonstrou uma precisão geral de 98% na previsão de classes de falhas no conjunto de treinamento e 96,5% na previsão de classes de falhas no conjunto de teste.

Em Khaled et al. (2020), um modelo NARX foi desenvolvido como um classificador binário para identificar se os sinais de fonocardiograma PCG (do inglês, *phonocardiogram*) eram normais ou anormais. A arquitetura paralela série NARX, em circuito aberto, foi utilizada para o treinamento, enquanto a arquitetura paralela NARX, em circuito fechado, foi empregada para os testes. Foram analisados o impacto de três métodos de otimização de treinamento: *Levenberg–Marquardt*, Regularização *Bayesiana* e Gradiente Conjugado Escalado. O classificador NARX apresentou melhor desempenho quando treinado com o algoritmo *Bayesiano* em comparação com os outros dois algoritmos. Os registros de desempenho ideal alcançados pelo modelo NARX foi (0,9382), (0,8924) e (0,9153) de sensibilidade, especificidade e precisão, respectivamente.

Araújo (2022) desenvolveu um modelo computacional dotado de um algoritmo classificador para processar sinais de vibração de motores elétricos e determinar se a máquina apresenta um comportamento de falha e, em caso positivo, qual falha. Foram comparados os desempenhos dos algoritmos K-NN, SVM, Rede Neural Artificial e *Random Forest*. Após avaliar a precisão de todos os quatro modelos, o *Random Forest* apresentou a melhor precisão para o conjunto de dados, com 97.18% de acerto. O segundo algoritmo com a melhor taxa de acerto foi o SVM, com 94.05% de acurácia. O terceiro algoritmo com a melhor taxa de acerto foi RNA, com 92,1%. O modelo K-NN apresentou 91.39% de acerto. O modelo proposto foi capaz de identificar corretamente diferentes tipos de falhas mecânicas em motores elétricos por meio de leituras de análise de vibração.

Bazan (2020), desenvolveu uma ferramenta de processamento de sinais e sistemas inteligentes no diagnóstico de falhas de rolamentos, rotor e estator em motores de indução, mesmo quando sujeitos a diversas condições de operação, como variações no torque de carga independente da alimentação da máquina. A extração das características de falha baseia-se em medidas de informação mútua atrasada entre os sinais das correntes de linha do estator, *ia* e *ib*, no domínio do tempo. Comparou-se o desempenho de três diferentes técnicas de reconhecimento de padrões para avaliar a acurácia da classificação sob vários níveis de severidade de falhas: RNA do tipo *Perceptron* Multicamadas, k-vizinhos mais próximos e SVMs. Os resultados experimentais *off-line* e *on-line* apresentados validaram a robustez e a eficácia da ferramenta.

Aquize et al. (2023), apresentaram um método sistemático para projetar e desenvolver modelos de caixa preta baseados em redes neurais NARX para identificar um modelo turbina a gás robusto, preciso e confiável. A proposta consistiu em 9 etapas bem definidas desde a identificação das variáveis até a obtenção de um modelo NARX satisfatório. Os valores das métricas MSE, RMSE e MAPE durante as fases de treinamento, validação e teste foram satisfatórios. Um modelo NARX foi obtido com MSE de $1,945 \times 10^{-5}$, RMSE de 0,4411% e MAPE de 0,0643.

dos Santos & de Araújo (2023) implementou uma Rede Neural Convolucional (CNN) para a Detecção e Diagnóstico de Falhas (DDF) em rolamentos, considerando diferentes cargas e velocidades do motor, bem como distintos tipos e profundidades de falhas nos rolamentos. O modelo treinado demonstrou eficácia ao realizar a detecção e o diagnóstico

das falhas sob grandes variações das condições operacionais, incluindo carga, velocidade do motor, localização e diâmetro das falhas nos rolamentos, atingindo uma precisão de 97,7% quando testado em cenários distintos das condições de treinamento.

2.2 Conclusão

Apesar da confiabilidade geralmente associada aos motores de indução trifásicos, eles são suscetíveis a uma variedade de falhas, tanto mecânicas quanto elétricas, durante a operação. Esse cenário representa um desafio significativo para a indústria, exigindo o desenvolvimento contínuo de técnicas capazes de monitorar e diagnosticar essas falhas em estágio inicial. Diversas abordagens foram propostas para a detecção desses problemas, todas com o objetivo claro de contribuir para uma manutenção mais eficaz e, consequentemente, reduzir as perdas de produção. Em muitas investigações, a inteligência artificial tem sido destacada por vários autores como uma ferramenta crucial na modelagem de sistemas. Entre as diversas técnicas de inteligência artificial, o aprendizado de máquina se destaca no desenvolvimento de sistemas de classificação de falhas, conforme corroborado pelos trabalhos citados.

Pode-se concluir que o tema ainda não alcançou sua plena maturidade, apresentando inúmeras oportunidades para exploração, especialmente no campo do aprendizado profundo por meio das RNAs. A pesquisa e o desenvolvimento contínuos nessa área são essenciais para aprimorar a confiabilidade e a eficiência dos motores de indução trifásicos, o que, por sua vez, contribuirá para uma operação mais segura e econômica desses sistemas essenciais em diversas aplicações industriais. A figura 2.1 sintetiza os trabalhos citados e que estão relacionados ao tema proposto.

Figura 2.1: Trabalhos relacionados ao tema.

Autores	Ano	Título	Técnica
Ramalho et al.	2014	Deteção de falhas em motores elétricos através da classificação de padrões de vibração utilizando uma rede neural Elman	Rede Neural ELMAN
Vitor et al.	2014	Deteção de falhas de estator em motores de indução trifásicos utilizando transformada <i>wavelet</i> , medida RMS e potência de previsão	Rede RBF
Jagadanand & Dias	2015	ARM based induction motor fault detection using <i>wavelet</i> , and support vector machine	<i>wavelet</i> SVM
Gangora et al.	2016	Identificação de Falhas Elétricas em Motores de Indução Trifásicos por Injeção de Sinal de Referência	Rede Perceptron Multicamadas
Cruz et al.	2017	A Hybrid System Based on Fuzzy Logic to Failure Diagnosis in Induction Motors	Lógica Fuzzy
Liboni	2017	Diagnóstico de Falhas em Motores de Indução Trifásicos Baseado em Decomposição em Componentes Ortogonais e Aprendizagem de Máquinas	Redes Neurais <i>feedforward</i> e SVM
Vitor et al.	2014	Deteção de Falhas de Estator em Motores de Indução Trifásicos Utilizando Transformada Wavelet, Medida RMS e Potência de Previsão	Rede RBF
Gongora et al.	2016	Identificação de Falhas Elétricas em Motores de Indução Trifásicos por Injeção de Sinal de Referência	Rede Perceptron Multicamadas
Cruz et al.	2017	A Hybrid System Based on Fuzzy Logic to Failure Diagnosis in Induction Motors	Lógica Fuzzy
Liboni	2017	Diagnóstico de Falhas em Motores de Indução Trifásicos Baseado em Decomposição em Componentes Ortogonais e Aprendizagem de Máquinas	Redes Neurais <i>feedforward</i> e SVM
Silva-Filho	2017	Diagnóstico de Defeitos em Estatores de Motores de Indução Trifásicos por Meio de Sensores Piezelétricos de Baixo Custo e Redes Neurais Artificiais	Redes Neurais <i>feedforward</i>
Kavana & Neethi	2018	Fault Analysis and Predictive Maintenance of Induction Motor Using Machine Learning	Redes Neurais <i>feedforward</i>
Kumar et al.	2018	Analysis of Fuzzy Logic Based Fault Detection for Three Phase Induction Motor Drive System	Lógica Fuzzy
Dias	2019	Diagnóstico de Anomalias em Aplicações de Acionamento de Motores Elétricos a Partir de Dados de Processo de Rede Profinet e Aprendizagem de Máquinas	k-vizinhos, SVM
Lyra	2019	Sistema Inteligente para Diagnóstico de Falhas em Rolamentos de Motores de Indução Trifásicos via Análise Sonora	Rede Perceptron Multicamadas, RBF
Bazan	2020	Identificação Inteligente de Falhas em Máquinas Elétricas Utilizando Informação Mútua	Rede Perceptron Multicamadas, k-vizinhos, SVM
Araújo	2022	Análise, avaliação e validação do uso de técnicas de inteligência artificial para o diagnóstico de falhas em motores de indução	<i>Random Forest</i> , SVM, RNA e K-NN
Aquize et al.	2023	System identification methodology of a gas turbine based on artificial recurrent neural networks	Rede Narx
dos Santos&de Araujo	2023	Deteção e diagnóstico de falhas em rolamentos, sob diferentes cargas e velocidades, utilizando Redes Neurais Convolucionais.	CNN

Fonte: Elaboração do autor (2024).

Capítulo 3

Fundamentação Teórica

Neste Capítulo, são apresentados alguns conceitos básicos e aspectos teóricos relacionados ao desenvolvimento do trabalho, incluindo: motores de indução trifásicos, falhas mais frequentes em motores, técnicas de inteligência artificial, aprendizado de máquina (do inglês, *Machine Learning* - ML), e aprendizado profundo (do inglês, *Deep Learning* - DL).


3.1 Motores de Indução Trifásicos

Grande parte do setor industrial depende de motores elétricos, incluindo motores de Corrente Contínua (CC) e motores de Corrente Alternada (CA), que são amplamente utilizados em diversas aplicações (Guedes et al. 2024). Entre os motores elétricos, destacam-se o motor síncrono e o motor de indução, cada um com características específicas que os tornam adequados para diferentes aplicações. O motor síncrono, operando a uma velocidade fixa, é especialmente utilizado em aplicações que requerem grandes potências ou onde a manutenção de uma velocidade constante é crucial, embora seu alto custo limite seu uso em tamanhos menores. Por outro lado, o motor de indução, conhecido por sua simplicidade, robustez e baixo custo, é amplamente utilizado em diversas aplicações. Este motor, que geralmente opera a uma velocidade constante com variações mínimas conforme a carga aplicada, pode ter sua velocidade controlada por meio de inversores de frequência (WEG 2023).

Os motores de indução podem ser divididos em dois tipos principais: monofásicos e trifásicos, cada um adequado para diferentes aplicações. Os motores de indução monofásicos são geralmente utilizados em situações de menor potência, como em eletrodomésticos e pequenos equipamentos industriais. Em contraste, os motores de indução trifásicos, mais comuns em ambientes industriais, se destacam pela maior eficiência e capacidade de operar em sistemas de alta potência. Dentre os motores trifásicos, os com rotor do tipo gaiola constituem a carga elétrica mais importante em sistemas industriais, tanto pelo consumo significativo de energia elétrica quanto pela sua contribuição na produção industrial (Lima 2016). Esses motores trifásicos oferecem várias vantagens no uso de energia elétrica, incluindo baixo custo, facilidade de transporte, limpeza e simplicidade de controle. Tais benefícios resultam de sua construção simples, versatilidade para se adaptar a diferentes tipos de cargas e eficiência energética aprimorada (WEG 2023). Na Figura 3.1,

é ilustrada a classificação dos motores elétricos.

Figura 3.1: Classificação de Motores.




Fonte: Adaptado WEG (2023).

3.1.1 Componentes do motor de indução trifásico

O motor de indução CA é composto por diversos componentes essenciais, sendo o estator e o rotor os elementos fundamentais. Esses elementos são ilustrados na Figura 3.2. A carcaça, que forma a estrutura externa do motor, possui uma superfície aletada para facilitar o arrefecimento. No interior da carcaça, encontra-se o núcleo do estator, onde está montado o enrolamento trifásico nas ranhuras do núcleo. Esse enrolamento é alimentado por um sistema trifásico a três fios, onde as tensões estão defasadas em 120° elétricos, conforme discutido por Silva & others (2021).

Figura 3.2: Componentes de um MIT.



Fonte: Adaptado WEG (2021).

Estatore:

- Carcaça (1) – é a estrutura suporte do conjunto; de construção robusta em ferro fundido, aço ou alumínio injetado, resistente à corrosão e com aletas.
- Núcleo de chapas (2) – as chapas são de aço magnético, tratadas termicamente para reduzir ao mínimo as perdas no ferro.
- Enrolamento trifásico (8) – três conjuntos iguais de bobinas, uma para cada fase, formando um sistema trifásico ligado à rede trifásica de alimentação.

Rotor:

- Eixo (7) – transmite a potência mecânica desenvolvida pelo motor. É tratado termicamente para evitar problemas como empenamento e fadiga.
- Núcleo de chapas (3) – as chapas possuem as mesmas características das chapas do estator.
- Barras e anéis de curto-circuito (12) – são de alumínio injetado sob pressão numa única peça.

Outras partes do MIT:


- Tampa (4).
- Ventilador (5).
- Tampa defletora (6).
- Caixa de ligação (9).
- Terminais (10).
- Rolamentos (11).

3.1.2 Princípio de funcionamento

Os motores de indução, são assim denominados devido ao princípio de transferência de potência do enrolamento primário do estator para o rotor. A transferência ocorre em função do movimento relativo entre o campo magnético gerado pelo enrolamento do estator e os condutores do rotor, o que induz uma tensão no rotor. Esse princípio fundamenta a dinâmica essencial por trás da operação eficiente e versátil dos motores de indução, que são cruciais em muitas aplicações industriais e comerciais (Silva et al. 2024).

A alimentação do motor de indução é realizada por um sistema trifásico, o qual é formado pela associação de três sistemas monofásicos de tensões, denominados U_1 , U_2 e U_3 , dispostos de tal forma que a defasagem entre eles seja de 120° , ou seja, os atrasos de U_2 em relação a U_1 , de U_3 em relação a U_2 e de U_1 em relação a U_3 são todos iguais a 120° , considerando um ciclo completo de 360° . O sistema é equilibrado se as três tensões possuem o mesmo valor eficaz, ou seja, $U_1 = U_2 = U_3$, conforme ilustrado na Figura 3.3.

Figura 3.3: Sistema de corrente alternada trifásica.



Fonte: Adaptado WEG (2021).

Velocidade síncrona

A velocidade síncrona do motor é definida pela velocidade de rotação do campo girante, a qual depende do número de polos (p) do motor e da frequência (f) da rede, expressa em *hertz*. Os enrolamentos podem ser construídos com um ou mais pares de polos, os quais se distribuem alternadamente (um polo "norte" e um "sul") ao longo da "norte" e um polo "sul" ao longo da periferia do núcleo magnético. O campo girante atravessa um par de polos (p) a cada ciclo. Portanto, considerando que o enrolamento possui polos ou " p " pares de polos, a velocidade de rotação do campo girante será:

$$n_s = \frac{120 \cdot f}{p}, \quad (3.1)$$

n_s – velocidade síncrona (rpm) em condições nominais;

f – representa a frequência da tensão elétrica de alimentação (Hz);

p – o número total de polos por fase.

Escorregamento

O motor de indução, comumente referido como motor assíncrono, apresenta uma velocidade de eixo que é ligeiramente inferior à velocidade síncrona. Essa discrepância resulta do fato de que a velocidade do rotor é um pouco menor do que a do campo magnético girante. A magnitude dessa diferença, conhecida como escorregamento, aumenta proporcionalmente com o incremento da carga mecânica aplicada ao eixo (Souza 2018).

O escorregamento é a diferença entre a velocidade do motor (n) e a velocidade síncrona (n_s), conforme descrita na Equação 3.2. Esse parâmetro pode ser expresso em rpm, como uma fração da velocidade síncrona ou em termos percentuais descrito na Equação 3.3.

$$S_{rpm} = (n_s - n), \quad (3.2)$$

$$S = \frac{n_s - n}{n_s} \times 100, \quad (3.3)$$

sendo que:

S é o Escorregamento;

n_s a Velocidade de campo magnético girante (rpm);

n representa a Velocidade nominal (rpm).

Velocidade nominal

A velocidade nominal do motor (n), quando operando com potência nominal e sob condições de tensão e frequência nominais, é influenciada pelo escorregamento e pela velocidade síncrona. Assim, a velocidade nominal, medida em (rpm), pode ser calculada da seguinte forma:

$$n_{rpm} = n_s \cdot \left(1 - \frac{S\%}{100} \right), \quad (3.4)$$

3.1.3 Falhas em motores de indução trifásicos

A presença de uma falha, mesmo que incipiente, pode afetar significativamente o desempenho de máquinas elétricas, resultando em perdas no processo de produção. As paradas não programadas configuram-se como um grande desafio no setor industrial, pois elevam tanto os custos de manutenção, quanto as perdas associadas à produção. O monitoramento e diagnóstico de Motores de Indução Trifásicos (MITs) baseiam-se na extração

e processamento de dados operacionais do próprio motor, como correntes, tensões, vibrações e temperaturas, garantindo que as informações obtidas permitam uma análise precisa e confiável (Guedes et al. 2024). A busca contínua pela otimização da eficiência e produtividade transcende a simples incorporação de novas tecnologias para substituir atividades manuais, abrangendo, também a geração e análise de grandes volumes de dados relacionados à manutenção e às condições operacionais dos componentes da linha de produção (Lucas 2020).

Segundo Vitor (2015), o prognóstico antecipado de falhas é importante para garantir condições operacionais seguras, possibilitar a manutenção programada, reduzir os custos operacionais e aumentar a confiabilidade da operação em que a condição do motor pode ser monitorada por meio de sensores específicos instalados no estator e no rotor.


Os custos de manutenção de equipamentos industriais estão entre os maiores gastos dentro de um processo de fabricação. Esses equipamentos podem apresentar falhas incipientes que, se não detectadas em tempo hábil, podem evoluir para falhas críticas, interrompendo a produção e causando prejuízos significativos. A tendência atual visa identificar falhas em seus estágios iniciais. O monitoramento contínuo dos sinais emitidos pela máquina permite a análise e correção dessas falhas, o que minimiza danos, evita paradas não programadas e, conseqüentemente, aumenta a disponibilidade, eficiência e vida útil do equipamento (Lyra 2019).

3.1.4 Tipos de falhas

Falhas em MITs podem se manifestar por diversos sintomas, incluindo alterações nos sinais de vibração, variações de temperatura, ruídos e alterações no campo eletromagnético. Essas falhas geralmente se categorizam em dois grupos principais: falhas elétricas e falhas mecânicas. As falhas elétricas frequentemente envolvem problemas com os enrolamentos do estator, além de possíveis defeitos em barras e anéis do rotor, assim como conexões elétricas. Por outro lado, falhas mecânicas são associadas a defeitos nos rolamentos, desalinhamentos e outros problemas relacionados ao componente mecânico (Vitor 2015).

Na Figura 3.4, é ilustrada a distribuição das falhas identificadas nos MITs. Segundo Alsaedi (2015), a distribuição percentual das falhas é a seguinte: 40% estão relacionadas a problemas nos rolamentos, 38% aos enrolamentos do estator, 10% ao rotor e 10% a 12% a outras causas diversas. Essa análise destaca a importância da manutenção preventiva, especialmente em rolamentos e enrolamentos do estator, que são responsáveis pela maioria das falhas. O desgaste nos rolamentos pode ser intensificado por condições operacionais adversas, enquanto as falhas nos enrolamentos frequentemente decorrem de superaquecimento e sobrecarga. Embora menos frequentes, as falhas no rotor podem ter um impacto significativo no desempenho do motor, particularmente em aplicações que demandam altos níveis de torque. Portanto, a detecção precoce e o monitoramento rigoroso dessas falhas são essenciais para manter a operação eficiente e prolongar a vida útil dos motores.

Figura 3.4: Classificação das falhas em motores.



Fonte: Adaptado WEG (2021).

3.2 Métodos de Detecção e Classificação de Falhas


Conforme abordado no Capítulo 1, a literatura apresenta uma ampla variedade de métodos para a detecção e classificação de falhas em motores de indução trifásicos. Esses métodos podem ser divididos em duas categorias principais: os métodos convencionais, que se baseiam em técnicas tradicionais de monitoramento e análise de sinais, e os métodos modernos, que utilizam técnicas de inteligência artificial (IA) para aprimorar a precisão e a eficiência no diagnóstico. Neste trabalho, será empregada uma abordagem baseada em redes neurais artificiais, mais especificamente a arquitetura NARX, que integra características autoregressivas e entradas exógenas para classificar falhas de forma mais robusta e adaptada às condições industriais.

3.2.1 Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo

A IA, como discutido anteriormente, refere-se à capacidade de sistemas computacionais de simular a inteligência humana, resolvendo problemas complexos por meio de algoritmos avançados. Dentro desse campo, o Aprendizado de Máquina ML (do inglês, *Machine Learning*) é uma subárea que se concentra no desenvolvimento de algoritmos que aprendem e melhoram de forma autônoma com base em dados. Uma camada ainda mais especializada dentro do ML é o Aprendizado Profundo DL (do inglês, *Deep Learning*), que utiliza redes neurais artificiais para processar grandes volumes de dados e reconhecer padrões altamente complexos.

O diagrama apresentado na Figura 3.5 ilustra a hierarquia desses conceitos, mostrando como DL está inserido dentro do ML, que por sua vez faz parte do campo mais amplo da IA.

Figura 3.5: Fluxograma IA.



Fonte: Elaboração do autor (2024).

3.2.2 Aplicação de Métodos de IA na Detecção de Falhas em MITs

A aplicação de métodos de IA na detecção de falhas permite o monitoramento em tempo real por meio de computadores, reduzindo a necessidade de intervenção direta dos usuários. Em diversas situações, essas tecnologias são capazes de diagnosticar falhas sem a necessidade de intervenção de especialistas em manutenção (Santos et al. 2018). O monitoramento de condições em MITs envolve diversas etapas, como a coleta de informações, análise preditiva, extração de características e identificação de falhas através de algoritmos de ML. Diversas estratégias de ML são amplamente utilizadas para a identificação e classificação de falhas. Algumas das técnicas mais comuns incluem:

- k-vizinhos mais próximos k-NN (do inglês, *k-Nearest Neighbors*);
- Redes Neurais Artificiais (RNAs);
- Máquinas de Vetor de Suporte SVM (do inglês, *Support Vectors Machine*);
- Florestas Aleatórias RF (do inglês, *Random Forest*);
- Classificadores *Bayesianos* e o *Naïve Bayes*.

Esses algoritmos têm mostrado grande eficácia na criação de sistemas inteligentes para o diagnóstico de falhas, especialmente em motores de indução trifásicos (MITs), conforme demonstrado por (Preethi et al. 2021).

Dentre as diversas técnicas de IA, as RNAs têm se destacado como ferramentas particularmente eficazes no diagnóstico de falhas em MITs. Essas redes possuem grande capacidade de reconhecimento de padrões complexos, permitindo a detecção de anomalias em variáveis cujas características são difíceis de prever ou descrever completamente, como é o caso das falhas em motores de indução. De acordo com Mohamed et al. (2020), o uso de RNAs para a classificação de padrões é uma abordagem promissora e essencial

para o diagnóstico preciso de falhas, oferecendo uma solução robusta para os desafios inerentes ao monitoramento de MITs.

3.2.3 Aprendizado de Máquina


O Aprendizado de Máquina, ML, representa um campo avançado da inteligência artificial que utiliza algoritmos computacionais capazes de identificar padrões em grandes volumes de dados e de aprimorar seu desempenho ao longo do tempo, sem a necessidade de reprogramação explícita. Conforme Nicolau et al. (2019), trata-se de uma técnica que possibilita ao sistema computacional melhorar seu desempenho de forma autônoma, por meio da experiência acumulada durante o processo de treinamento.

Corrêa (2020) define o aprendizado de máquina como a capacidade de modificar ou adaptar as ações de um computador, tornando-as progressivamente mais precisas. De acordo com o grau de supervisão aplicado durante o treinamento, o aprendizado de máquina foi classificado em dois tipos: supervisionado e não supervisionado. Em ambos os casos, a experiência passada é adquirida por meio do treinamento, sendo que as instâncias das bases de dados podem ou não estar rotuladas. No aprendizado supervisionado, os algoritmos recebem como entrada instâncias que contêm a informação de saída desejada, representando a classe a que cada instância pertence. Em contrapartida, no aprendizado não-supervisionado, as classes às quais as instâncias do conjunto de treinamento pertencem não são conhecidas a priori (Santos 2012).

De acordo com Santos (2012), no aprendizado supervisionado, cada exemplo do conjunto de treinamento é rotulado como pertencente a uma classe específica. Já no aprendizado não-supervisionado, os métodos recebem como entrada dados sem qualquer informação de saída, ou seja, a classe à qual as instâncias pertencem não é conhecida previamente. Dessa forma, o objetivo principal dos métodos de aprendizado não-supervisionado é agrupar exemplos não-rotulados através da identificação de padrões ou tendências, gerando agrupamentos ou *clusters* distintos, auxiliando no entendimento desses dados.

Posteriormente, a comunidade científica passou a investigar um terceiro grupo de aprendizado, conhecido como semi-supervisionado. Como o próprio nome sugere, o método está entre o aprendizado supervisionado e o não-supervisionado, pois trabalha com dados parcialmente rotulados (Vale 2019). A estrutura geral do aprendizado de máquina é apresentada na Figura 3.6.

Figura 3.6: Estrutura do aprendizado de máquina.



Fonte: Elaboração do autor (2023).

Modelos de Aprendizado de Máquina

Regressão – O modelo de regressão visa prever valores numéricos, ou, em outros termos, identificar uma categoria em uma escala contínua (pode ser até uma probabilidade). Neste contexto, o modelo é capaz de aprender uma função que permite estimar, por exemplo, o preço de um imóvel, uma demanda de venda, probabilidade de superlotação de um estoque, o tempo que levará para uma máquina apresentar defeito, uma nota de um cliente para aumentar seu limite de crédito, ou qualquer outro valor quantitativo (Seidor 2023).

Classificação – A classificação, por sua vez, baseia-se na previsão associada a categoria de uma observação dada. Nesse caso, procura-se estimar um “classificador” que gere como saída a classificação qualitativa de um dado não observado com base em dados de entrada (que abrangem observações com classificações já definidas) (Silva 2023).

3.2.4 Aprendizado Profundo

O aprendizado profundo é uma sub-área do aprendizado de máquina, caracterizada por uma estrutura de múltiplas camadas, permitindo que computadores realizem tarefas complexas, muitas vezes com desempenho semelhante ao humano. De forma mais específica, no aprendizado profundo, utilizam-se RNAs, que simulam o funcionamento do cérebro humano como uma máquina de aprendizado.


Braga et al. (2007) descrevem as RNAs como sistemas distribuídos e paralelos, formados por unidades de processamento simples, chamados nós, que realizam cálculos de funções matemáticas, geralmente não lineares. Essas unidades são organizadas em uma ou mais camadas e conectadas por diversas ligações, normalmente unidirecionais. Em grande parte dos modelos, essas conexões possuem pesos, que armazenam o conhecimento representado no sistema e ponderam os dados de entrada recebidos por cada neurônio da rede. O funcionamento das RNAs é inspirado na estrutura física do cérebro humano.

De acordo com Haykin (2001), uma rede neural pode ser definida como um processador distribuído de forma massivamente paralela, composto por unidades simples que possuem a capacidade natural de armazenar conhecimento obtido por meio da experiência e torná-lo disponível para uso posterior. Essa estrutura assemelha-se ao cérebro humano em

dois aspectos principais: primeiro, a rede adquire conhecimento a partir de seu ambiente por meio de um processo de aprendizagem; segundo, as conexões entre os neurônios, conhecidas como pesos sinápticos, são responsáveis por armazenar o conhecimento adquirido. Conforme Fleck et al. (2016), as RNAs são algoritmos computacionais que seguem um modelo matemático inspirado na estrutura de organismos inteligentes, possibilitando a simulação simplificada do funcionamento cerebral em computadores. Assim como o cérebro humano, as RNAs têm a capacidade de aprender e tomar decisões com base nesse aprendizado.

O modelo matemático das redes neurais artificiais remonta às teorias desenvolvidas na década de 1940 por *Walter Pitts*, matemático, e *Warren McCulloch*, neurofisiologista, que buscaram associar o funcionamento de um neurônio biológico a um circuito eletrônico. Assim como no sistema nervoso humano, onde cada neurônio armazena informações (processo conhecido como cognição), o modelo artificial também possui sua forma de guardar estas informações, com base em padrões históricos utilizados para treinar a rede (Barcelos & Toshimitsu 2018). Segundo Haykin (2001), nesse modelo visto na Figura 3.7, os sinais de entrada X_j ; são aplicados às sinapses j conectadas ao neurônio k , sendo multiplicados por um peso sináptico W_{kj} . O neurônio k então realiza a soma ponderada dos sinais recebidos, gerando um nível de atividade. Se este nível ultrapassar um certo limite, a unidade processadora emitirá uma determinada resposta na saída.

Figura 3.7: Modelo matemático de um Neurônio Artificial.



Fonte: Adaptado Haykin (2001).

O modelo k apresentado na Figura 3.7 inclui também um bias aplicado externamente, representado por b_k . Ele aumenta ou diminui a entrada líquida da função de ativação, dependendo se é positivo ou negativo. Matematicamente, esse modelo k pode ser descrito pelas seguintes Equações:

$$u_k = \sum_{j=1}^M W_{kj} \cdot X_j, \quad (3.5)$$

$$y_k = \phi \cdot (u_k + b_k), \quad (3.6)$$

onde:

X_j – representa os sinais de entrada;

W_{kj} – os pesos sinápticos;

y_k – sinais de saída;

$\phi(\cdot)$ – função de ativação; e

b_k – constante de valor 1.

3.2.5 Tipos de função de ativação

A função de ativação, representada por ϕ , define a saída de um neurônio, determinando essencialmente se ele será ativado ou não. Em outros termos, decide se a informação recebida pelo neurônio deve ser processada ou ignorada. Essa função combina os sinais de entrada com os pesos das sinapses e gera o sinal de saída do neurônio. É considerada uma função restritiva, pois limita o intervalo permissível de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo da amplitude de saída do neurônio é normalizado como o intervalo unitário fechado $[0,1]$, ou, alternativamente, $[-1,1]$ (Haykin 2001).


Principais funções de ativação:

Função Linear – A função linear aplica um fator de multiplicação à entrada, restringindo a saída da RNA a valores binários, geralmente no intervalo $[0,1]$. No entanto, devido à sua natureza linear, sua capacidade de modelar relações mais complexas entre os dados é restrita (Braga et al. 2007). Sua função é dada por:

$$f(x) = a \cdot x. \quad (3.7)$$

A função de ativação linear é ilustrada graficamente na Figura 3.8.

Figura 3.8: Função de Ativação Linear.




Fonte: Adaptado Braga et al. (2007).

Função Sigmoid – A função logística ou Sigmoid é uma função suave e continuamente diferenciável, amplamente reconhecida por suas propriedades localmente quadráticas. Ela produz valores no intervalo $[0, 1]$. Sua curva característica apresenta duas assíntotas paralelas, refletindo a tendência da função em se estabilizar em valores limite à medida que a variável independente se aproxima de extremos positivos ou negativos. Além de suas propriedades matemáticas, a função sigmoide é amplamente utilizada em algoritmos de aprendizado de máquina, especialmente em modelos de previsão probabilística, como a regressão logística (CAMARGOS & others 2021). Ela é ilustrada pela Figura 3.9 e sua função é definida por:

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (3.8)$$

Figura 3.9: Função de Ativação Sigmoid.




Fonte: Adaptado CAMARGOS & others (2021).

Função Tangente Hiperbólica – A função tangente hiperbólica é localmente quadrática e produz valores no intervalo $[-1, 1]$. Além de sua simetria, essa função se destaca por sua fácil implementação em arquiteturas de hardware, o que a torna uma escolha eficiente em diversas aplicações computacionais (CAMARGOS & others 2021). Ela é ilustrada pela Figura 3.10 e sua função é definida por:

$$\tanh(x) = \frac{2}{(1 + e^{-2x}) - 1}. \quad (3.9)$$

Figura 3.10: Função de Ativação Tangente hiperbólica.




Fonte: Adaptado CAMARGOS & others (2021).

Unidade de Retificação Linear (ReLU) - A função ReLU é uma função amplamente utilizada em problemas de aprendizado profundo. Com sua natureza linear, a ReLU se destaca por sua menor complexidade de implementação e superior desempenho no processo de convergência, quando comparada à função sigmoide (CAMARGOS & others 2021). Essa função é dada pela Equação 3.10 e ilustrada graficamente na Figura 3.11:

$$f(x) = \max(0, x). \quad (3.10)$$

Figura 3.11: Função de Ativação ReLu.



Fonte: Adaptado CAMARGOS & others (2021).

Função *Softmax* e Entropia cruzada - A função de ativação *Softmax* determina a probabilidade de um valor pertencer a uma classe específica. Amplamente utilizada em problemas de classificação múltipla e aprendizado por reforço, a *Softmax* calcula probabilidades que se situam no intervalo de 0 a 1. Na construção de redes neurais, essa função é frequentemente utilizada nas camadas finais, permitindo interpretar as saídas como distribuições de probabilidade sobre diversas classes (CAMARGOS & others 2021). Segundo Connor et al. (2024), a função *Softmax* desempenha um papel crucial no treinamento de redes de aprendizado profundo, sendo frequentemente utilizada como um passo preliminar à aplicação da perda por entropia cruzada. Essa função é responsável por transformar um conjunto de valores de ponto flutuante arbitrários em uma distribuição de probabilidades, onde todos os valores são estritamente positivos e somam 1. Somente após essa normalização proporcionada pela *Softmax*, a função de perda por entropia cruzada pode ser aplicada, permitindo a otimização eficaz do modelo. A função *Softmax* é representada matematicamente pela Equação:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ for } (i) = 1, \dots, K. \quad (3.11)$$

3.2.6 Algoritmos de treinamento

Diversos algoritmos de otimização não linear estão amplamente documentados na literatura, porém, nenhum é universalmente reconhecido como a melhor escolha para todas as aplicações. No contexto do treinamento de RNAs, a minimização da função de custo é frequentemente realizada por meio de variantes do método dos gradientes (Bueno et al. 2021).

Levenberg-Marquardt estocástico – O método de Levenberg-Marquardt tem se destacado pela eficiência na resolução de problemas de mínimos quadrados não lineares, combinando a rápida convergência do método de Newton com o uso exclusivo de informações de primeira ordem e a garantia de bem-definição de todos os seus iterandos. Nesse contexto, uma aplicação promissora dessa técnica é sua utilização na minimização da função de custo associada ao treinamento de RNAs (Bueno et al. 2021).

Gradiente Conjugado Escalonado SCG (do inglês, *Scaled Conjugate Gradient*) – O algoritmo SCG foi desenvolvido com o propósito de explorar de maneira eficiente espaços de parâmetros de alta dimensionalidade, consolidando-se como uma ferramenta essencial no treinamento de modelos complexos. Esse método de otimização é amplamente utilizado em áreas como aprendizado de máquina, otimização numérica e diversas outras disciplinas científicas. Reconhecido por sua alta eficiência e capacidade de lidar com problemas de grande escala, o SCG se destaca especialmente no treinamento de RNAs (Wu 2024).

Métodos de Quasi-Newton – Os métodos de minimização quasi-Newton (QNMs) destacam-se como ferramentas altamente eficazes na resolução de problemas de minimização suave, particularmente em situações onde as curvas de nível da função apresentam elevado grau de alongamento. Esses métodos encontram ampla aplicação em diversos campos, como biologia, processamento de imagens, engenharia e aprendizado profundo. A abordagem dos QNMs fundamenta-se na construção de uma matriz que aproxima as

derivadas segundas da função, utilizando informações derivadas dos gradientes (Krutikov et al. 2024).


Retropropagação Resiliente RPROP (do inglês, *Resilient Backpropagation*) – O algoritmo de retropropagação resiliente (RPROP) é uma técnica amplamente empregada no treinamento de redes neurais artificiais, caracterizada por sua eficiência e robustez. Seu principal objetivo é mitigar os efeitos adversos causados pelas magnitudes das derivadas parciais do erro, que podem desacelerar ou instabilizar o processo de aprendizado. Diferentemente de métodos tradicionais, o RPROP utiliza apenas o sinal da derivada parcial para determinar a direção de atualização dos pesos, eliminando a influência direta da magnitude dessas derivadas. Essa abordagem promove uma atualização mais estável e eficiente dos pesos, independentemente da escala das gradientes, permitindo que o algoritmo se concentre exclusivamente no ajuste das direções corretas (Kaur et al. 2016).

3.2.7 Arquiteturas de RNAs

Uma das maiores dificuldades no uso das redes neurais reside na escolha da arquitetura mais adequada, pois trata-se de um processo essencialmente experimental que demanda um grande tempo de execução (Fleck et al. 2016). As arquiteturas de RNAs podem ser agrupadas em três categorias fundamentais: Rede Neural *Feedforward* de Camada Única, Rede Neural *Feedforward* Multicamadas e Redes Neurais Recorrentes (RNR) ou Realimentadas.

Redes de Camada única – Essas redes possuem uma única camada de saída, sem camadas intermediárias. Elas representam a primeira e mais simples arquitetura de rede neural na qual os neurônios são organizados em uma estrutura de camadas e o fluxo de dados ocorre exclusivamente da entrada para a saída. A Figura 3.12 mostra o modelo de uma Rede *Feedforward* de Camada única.


Figura 3.12: Rede *Feedforward* de uma camada.



Fonte: Adaptado Freitas et al. (2022).

Rede *Feedforward* Multicamadas – Nesse tipo de arquitetura, a rede é organizada em uma ou mais camadas ocultas e não permite realimentação. As camadas ocultas são formadas por neurônios do tipo *Perceptron*, podem existir tantas camadas ocultas quanto necessário para a resolução do problema. A função dos neurônios ocultos é intervir de alguma forma útil entre a camada de entrada e a de saída da rede. A Figura 3.13 mostra o modelo de uma rede *Feedforward* de múltiplas camadas.


Figura 3.13: Rede *Feedforward* de múltiplas camadas.



Fonte: Adaptado Freitas et al. (2022).

Redes Neurais Recorrentes ou Realimentadas RNRs – As redes neurais recorrentes diferenciam-se pela presença de conexões de realimentação entre seus neurônios. Essas conexões permitem que as saídas da rede sejam reutilizadas como entradas, possibilitando o processamento de informações de sistemas variantes no tempo. Essa capacidade torna as RNRs ideais para aplicações dinâmicas, como previsão de séries temporais, controle de processos e identificação de sistemas. Exemplos de RNRs incluem redes NARX e redes de memória de longo e curto prazo LSTM (do inglês, *Long and Short Term Memory*) (Freitas et al. 2022). o modelo de arquitetura de uma RNR ou rede realimentada é ilustrada na Figura 3.14.

Figura 3.14: Rede recorrente ou realimentada.




Fonte: Adaptado Freitas et al. (2022).

3.2.8 Rede Neural NARX

O modelo NARX é uma forma especializada de rede neural recorrente que utiliza mecanismos de retroalimentação. Ele se destaca na modelagem não linear de sistemas, principalmente em séries temporais, onde dados passados são utilizados para prever valores futuros (Aquize et al. 2023). Esse modelo de rede auto-regressiva e com entradas exógenas é caracterizada pela recepção de dados tanto da própria realimentação, com atrasos temporais, quanto de variáveis externas, também com defasagem no tempo. Essa estrutura resulta em um modelo dinâmico, em que o comportamento do sistema varia ao longo do tempo. Assim, os valores previamente obtidos têm impacto direto nos resultados subsequentes, evidenciando a dependência temporal e a inter-relação entre as variáveis no processo de previsão (Souza & others 2019). (Khaled et al. 2020) afirmam que as redes NARX são uma alternativa eficiente às RNRs, proporcionando um desempenho computacional semelhante. Esse modelo combina dados de entrada originais e saídas geradas após o treinamento, permitindo que a rede aprimore continuamente sua capacidade de aprendizado.

A arquitetura interna do modelo NARX é baseada na *Perceptron* Multicamadas MLP (do inglês, *Multi-Layer Perceptron*), proporcionando uma estrutura robusta capaz de aprender qualquer tipo de mapeamento não linear contínuo. A NARX se destaca como um preditor confiável de séries temporais, apresentando uma estrutura composta por camada de entrada, camada oculta e camada de saída. Além disso, incorpora neurônios eficientes, funções de ativação, pesos ajustáveis, polarizações, conexões de realimentação e linhas de atraso (memória), proporcionando flexibilidade estrutural que equilibra simplicidade e eficácia na modelagem e previsão de séries temporais. Estudos indicam que as redes NARX tendem a ser mais rápidas e eficazes em sua convergência e propagação de informações, em comparação com outras arquiteturas de redes neurais. A topologia de uma rede neural NARX é ilustra pela Figura 3.15, onde u representa a entrada externa, y é a resposta e $y(k)$ a saída estimada.

Figura 3.15: Sistema dinâmico da rede neural NARX.



Fonte: Adaptado Khaled et al. (2020).

A Equação que define o modelo NARX é:

$$y(k) = f(u(k-1), u(k-2), \dots, u(k-n), y(k-1), y(k-2), \dots, y(k-m)), \quad (3.12)$$

onde:

u_k – é o vetor de características de entrada para a rede;

y_k – representa o vetor de saída para a rede;

n – é o índice do n -ésimo coeficiente em $u(k)$; e

m – o índice do m -ésimo coeficiente em $y(k)$.

3.2.9 Aprendizado da rede neural


De acordo com Haykin (2001), a capacidade de uma rede neural aprender a partir de interações com o ambiente e melhorar o seu desempenho através da aprendizagem é um dos fatores cruciais para sua eficácia. O processo de treinamento de uma rede neural consiste em modificar os valores das sinapses aos poucos, visando minimizar os erros e otimizar a saída de rede. O paradigma utilizado para treinamento de uma rede neural artificial é o cérebro humano (Furtado 2019).

As RNAs são capazes de aprender com exemplos, permitindo que realizem interpolações e extrapolações a partir dos dados apresentados. Inicialmente, a rede passa por uma fase de aprendizado, onde são extraídas informações relevantes dos padrões fornecidos, possibilitando a criação de uma representação própria do problema (Braga et al. 2007). De acordo com Lyra (2019), o processo de treinamento das RNAs permite que estas adquiram conhecimento sobre o projeto. As conexões entre os neurônios são estabelecidas por meio dos pesos sinápticos, que têm a função de armazenar o conhecimento adquirido. A modificação desses pesos ocorre por intermédio de um procedimento denominado algoritmo de aprendizagem, o qual ajusta os valores dos pesos de forma a minimizar ou eliminar os erros em relação à saída desejada do projeto.

Existem diversos métodos para treinamento de RNAs, podendo ser agrupados em três classes: aprendizado supervisionado, aprendizado não-supervisionado e aprendizado por reforço.

Aprendizado supervisionado - O aprendizado supervisionado é o método mais amplamente utilizado no treinamento de RNAs, aplicando-se tanto a neurônios com pesos quanto a neurônios sem pesos. Esse método é denominado aprendizado supervisionado porque as entradas e saídas desejadas são fornecidas por um supervisor (professor) externo. O objetivo é ajustar os parâmetros da rede de modo a estabelecer uma relação entre os pares de entrada e saída fornecidos (Braga et al. 2007). O diagrama de blocos do treinamento supervisionado é ilustrado pela Figura 3.16.


Figura 3.16: Aprendizado supervisionado.



Fonte: Adaptado Braga et al. (2007).

Aprendizado não-supervisionado – No aprendizado não-supervisionado, como o próprio nome indica, não há um professor ou supervisor para acompanhar o processo de aprendizado. Embora o aprendizado supervisionado tenha semelhanças com o processo de aprendizado dos seres humanos, muitos dos sistemas biológicos operam predominantemente por meio de aprendizado não supervisionado, como por exemplo, nos estágios iniciais dos sistemas de visão e audição. Diferente do aprendizado supervisionado, no qual o conjunto de treinamento é composto por pares de entrada e saída, nos algoritmos de aprendizado não supervisionado, apenas os padrões de entrada são disponibilizados para a rede. A estrutura do sistema de aprendizado não-supervisionado pode assumir diversas configurações. Em um exemplo, ela pode, consistir em uma camada de entrada, uma camada de saída, conexões *feedforward* da entrada para a saída e conexões laterais entre os neurônios da camada de saída. Em outro exemplo, pode-se ter é uma rede *feedforward* com múltiplas camadas, onde a organização ocorre progressivamente, camada por camada. Em ambos os casos, o processo de aprendizado envolve a modificação contínua dos pesos sinápticos de todas as conexões do sistema em resposta aos padrões de entrada (Braga et al. 2007). O diagrama de blocos do treinamento não-supervisionado é ilustrado na Figura 3.17.


Figura 3.17: Aprendizado não supervisionado.



Fonte: Adaptado Braga et al. (2007).

Aprendizado por reforço – O aprendizado por reforço pode ser considerado uma forma específica de aprendizado supervisionado. A principal diferença entre esses dois tipos de aprendizado está nos critérios de avaliação de desempenho adotados por cada abordagem. No aprendizado supervisionado, o desempenho é avaliado com base em um conjunto de respostas esperadas, utilizando-se um critério de erro previamente definido. Em contrapartida, no aprendizado por reforço, a avaliação de desempenho é realizada com base em qualquer tipo de *feedback* que o sistema receba. Nesse caso, a única informação fornecida à rede neural é se a saída gerada está correta ou não, sem que a resposta ideal para o padrão de entrada seja explicitamente disponibilizada (Braga et al. 2007). O diagrama de blocos do treinamento por reforço é ilustrado na Figura 3.18.

Figura 3.18: Aprendizado por reforço.



Fonte: Adaptado Braga et al. (2007).

3.3 Métricas de avaliação

Segundo Miller et al. (2024), o ML demonstra um potencial significativo em diversas áreas, onde a análise de grandes e complexos conjuntos de dados pode fornecer *insights* valiosos sobre diversos aspectos. Contudo, essa potencialidade traz consigo a responsabilidade de abordar questões relacionadas a preconceitos e à superestimação de resultados, os quais podem resultar em impactos indesejados e prejudiciais. Nesse sentido, é fundamental que os pesquisadores compreendam as métricas empregadas na avaliação de modelos de ML, uma vez que essas métricas desempenham um papel crucial na interpretação crítica dos resultados obtidos.

3.3.1 Métricas de avaliação para regressão

As métricas de desempenho, também referidas como métricas de avaliação ou métricas de erro, são componentes fundamentais na análise de regressão e nos modelos prediti-

vos baseados em aprendizado de máquina. Uma métrica de desempenho é definida como uma construção lógica e matemática elaborada para mensurar o grau de proximidade entre o resultado previsto e o resultado observado (Plevris et al. 2022).

- **Erro Médio Absoluto MAE** (do inglês, *Mean Absolute Error*): Essa métrica computa a média das diferenças absolutas entre as previsões do modelo e os valores reais, sendo amplamente utilizada por sua simplicidade interpretativa.
- **Erro Quadrático Médio MSE** (do inglês, *Mean Squared Error*): Trata-se de uma métrica que calcula a média dos quadrados das diferenças entre as previsões e os valores reais, penalizando mais severamente grandes desvios, o que a torna sensível a *outliers*.
- **Coefficiente de Determinação (R^2)**: O R^2 é uma métrica que quantifica o grau de ajuste do modelo aos dados, indicando a proporção da variabilidade dos valores dependentes que é explicada pelas variáveis independentes do modelo.

3.3.2 Métricas de avaliação para classificação

Os modelos de classificação têm como objetivo prever a classe de um determinado conjunto de dados rotulado, onde as entradas e os atributos estão associados a resultados conhecidos. A partir desse conjunto de dados, o modelo é treinado para realizar previsões em novos dados futuros (Mariano 2021).

Classes de dados preditos

Em problemas de classificação binária, a tarefa é prever a qual classe um dado pertence, geralmente denominadas positiva e negativa. No entanto, ao contrário da simples dicotomia entre acerto e erro, a avaliação de modelos de classificação envolve uma análise mais detalhada, levando em consideração quatro possíveis resultados (Mariano 2021):

- **Verdadeiro Positivo (VP)** – Ocorre quando o modelo prevê corretamente a classe positiva.
- **Verdadeiro Negativo (VN)** – Ocorre quando o modelo prevê corretamente a classe negativa.
- **Falso Positivo (FP)** – Refere-se à situação em que o modelo prevê uma classe positiva incorretamente, quando o valor real é negativo.
- **Falso Negativo (FN)** – Acontece quando o modelo prevê incorretamente uma classe negativa, quando o valor real é positivo.

Principais métricas de avaliação

Em problemas de classificação multiclasse, onde o número de classes excede o paradigma binário, a complexidade do problema aumenta, tornando-se mais suscetível a equívocos na implementação de classificadores. Por tanto, uma série de métricas adicionais é adotada para avaliar a eficácia dos classificadores, permitindo uma análise mais precisa da performance em sistemas de inteligência artificial (Junior et al. 2022).

As principais métricas que podem ser utilizadas para avaliar a qualidade de um classificador são:

Acurácia – É a proporção de previsões corretas em relação ao total de previsões. A métrica de acurácia é comumente empregada como um dos principais critérios na avaliação de classificadores em inteligência artificial. Isso ocorre devido à sua eficácia e à sua natureza conceitualmente simples, o que facilita sua compreensão (Junior et al. 2022). A Equação da acurácia é dada por:

$$\text{Acurácia} = \frac{\text{Previsões corretas}}{\text{Total de previsões}}. \quad (3.13)$$

Precisão – Esta métrica avalia a proporção de verdadeiros positivos entre todas as instâncias classificadas como positivas pelo modelo. A precisão busca responder à pergunta: Qual é a porcentagem de verdadeiros positivos previstos que está correta? Ela representa a proporção de verdadeiros positivos em relação a todos os valores positivos classificados (verdadeiros positivos mais falsos positivos). Quando o número de falsos positivos é alto, a precisão diminui significativamente. Geralmente, é empregada quando os falsos positivos têm potencialmente impacto mais prejudicial do que os falsos negativos (Junior et al. 2022). A métrica é definida pela Equação:

$$\text{Precisão} = \frac{VP}{VP + FP}. \quad (3.14)$$

Recall – Também conhecida como "sensibilidade", o recall mede a capacidade do modelo de identificar corretamente todas as instâncias positivas. É calculada como a razão entre os verdadeiros positivos e a soma dos verdadeiros positivos e dos falsos negativos. Essa métrica é comumente aplicada em situações em que os falsos negativos são potencialmente mais preocupantes que os falsos positivos. Ela avalia a taxa de verdadeiros positivos que o modelo consegue prever, permitindo uma análise da capacidade do classificador em identificar os falsos negativos (Junior et al. 2022). Essa métrica pode ser descrita pela Equação:

$$\text{Recall} = \frac{VP}{VP + FN}. \quad (3.15)$$


F1-Score – O F1-Score combina precisão e *recall* em uma única métrica, utilizando sua média harmônica. Um valor baixo de F1-Score indica que tanto a precisão quanto a sensibilidade estão abaixo do ideal, sugerindo a necessidade de ajustes no classificador. O F1-Score é uma métrica de desempenho do modelo de aprendizado de máquina que atribui pesos equivalentes à precisão e à sensibilidade. Os resultados fornecidos por essa métrica oferecem informações de alto nível e confiabilidade sobre a saída do classificador (Junior et al. 2022). Essa métrica pode ser descrita pela Equação:

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}. \quad (3.16)$$

Curva ROC (do inglês, *Receiver Operating Characteristic*) – A curva ROC é um dos métodos mais utilizados para a avaliação de modelos classificatórios, apresentando graficamente a relação entre a sensibilidade (taxa de verdadeiros positivos) e a sua es-

pecificidade (taxa de falsos positivos) ao longo de diferentes pontos de corte. (Polo & Miot 2020). A linha de classificação aleatória na diagonal, serve como um ponto de referência para avaliar o desempenho de um modelo de classificação. Qualquer modelo que tenha desempenho pior ou igual ao da linha classificatória não é útil para tarefas de classificação, pois não faz melhor do que escolher aleatoriamente. Quanto mais longe (e acima) da diagonal, melhor a capacidade do modelo de separar as classes. O modelo da curva ROC é ilustrado na Figura 3.19.

Figura 3.19: Curva ROC.



Fonte: Adaptado Polo & Miot (2020).

Matriz de confusão – A matriz de confusão, ilustrada na Tabela 3.20, detalha as previsões corretas e incorretas do modelo, organizadas de acordo com cada classe do conjunto de dados. Para problemas de classificação multiclasses, o modelo atribui uma classe a cada instância com base na maior probabilidade associada. Assim, a matriz de confusão permite avaliar o desempenho do classificador em termos de previsões corretas (valores na diagonal principal) e incorretas (fora da diagonal). A acurácia em problemas multiclasses é calculada da mesma forma, ou seja, pela razão entre a soma dos valores da diagonal principal e a soma de todas as entradas da matriz (Kubrusly 2023).

Figura 3.20: Matriz de confusão multiclasse.

0	495 9.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
1	0 0.0%	532 10.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	0 0.0%	507 10.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	0 0.0%	511 10.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	493 9.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	505 10.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	470 9.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	498 10.0%	0 0.0%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	495 9.9%	0 0.0%	100% 0.0%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	494 9.9%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	0	1	2	3	4	5	6	7	8	9	

Classe alvo

Fonte: Adaptado Kubrusly (2023).

3.4 Conclusão

O bom desempenho do motor de indução trifásico se dá pela sua construção simples e eficiente. Devido a essa simplicidade, associado à robustez e baixo custo, coloca o motor de indução trifásico na lista dos motores mais utilizados nas indústrias. O custo de manutenção com equipamentos ainda é consideravelmente alto na indústria, portanto desenvolver sistemas que possibilitem o monitoramento e diagnósticos de possíveis falhas podem reduzir tal custo. Com o propósito de desenvolvimento desses sistemas tem surgido variadas técnicas, e uma das mais empregadas na resolução de problemas complexos tem sido a inteligência artificial. O uso dessa técnica possibilita a detecção com maior rapidez e precisão as falhas que venham ocorrer no motor de indução trifásico. Duas áreas importantes são apresentadas da inteligência artificial: *machine learning* e *deep learning*. Existem várias métricas de avaliação comumente utilizadas em aprendizado de máquina, cada uma com seu propósito e interpretação específicos. A escolha das métricas adequadas depende do tipo de problema que estamos abordando e dos objetivos do modelo.

Capítulo 4

Materiais e métodos

Este capítulo apresenta, de forma detalhada, a metodologia adotada no desenvolvimento do sistema de monitoramento e diagnóstico de falhas em motores de indução trifásicos. O objetivo é fornecer uma descrição clara e estruturada das etapas realizadas, bem como dos materiais utilizados durante os testes experimentais. Além disso, este capítulo aborda aspectos fundamentais para o desenvolvimento do sistema, como o processamento dos dados coletados, a construção de diagramas de blocos no ambiente LabVIEW, a geração e organização dos *datasets* utilizados, e a adaptação da rede neural NARX para a tarefa de classificação das falhas.


4.1 Metodologia

Os experimentos foram realizados em uma bancada experimental instalada no Laboratório de Controle e Acionamento de Sistemas do DCA da Universidade Federal do Rio Grande do Norte (UFRN), a qual simula as condições reais de operação dos motores. O estudo abrangeu o diagnóstico de duas categorias de falhas: falhas mecânicas, incluindo eixo desbalanceado e defeitos em rolamentos, identificadas por meio de análises de vibração e temperatura, e falhas elétricas, como defeitos no estator, diagnosticadas a partir de sinais de corrente e temperatura nos enrolamentos. Os dados de corrente, vibração e temperatura coletados foram utilizados para compor o conjunto de dados necessário para treinar uma rede neural NARX. Os testes foram conduzidos tanto em condições normais de operação quanto em situações de falhas emuladas, abrangendo desequilíbrio de tensão no estator, desbalanceamento do eixo e defeitos nos rolamentos.

O diagrama de blocos que representa a metodologia proposta está ilustrado na Figura 4.1 sendo composto por cinco blocos principais. O Bloco 1 corresponde à bancada de testes, onde as falhas foram emuladas no motor instalado. O Bloco 2 é dedicado à coleta de dados, realizada através da leitura dos sinais capturados por sensores de vibração, corrente e temperatura. No Bloco 3, os sinais coletados são processados utilizando o *software* LabVIEW (do inglês, *Laboratory Virtual Instruments Engineering Workbench*), o qual gera representações gráficas tanto no domínio do tempo quanto no domínio da frequência. O Bloco 4 é responsável pela classificação das falhas utilizando a rede neural NARX. Finalmente, no Bloco 5, são apresentados os resultados obtidos a partir da classificação das falhas.

As seções subsequentes detalham os procedimentos, materiais e métodos utilizados na aquisição dos sinais, bem como explicar como as falhas foram emuladas.

Figura 4.1: Fluxograma de aquisição de dados.



Fonte: Elaboração do autor (2023).

4.2 Materiais - Bancada de Testes

A bancada utilizada para a realização dos experimentos é o modelo DLB MAQ-RN, fabricado pela empresa De Lorenzo do Brasil. Esta bancada está equipada com os recursos necessários para a aquisição de sinais e emulação de falhas de forma eficiente e precisa, garantindo a confiabilidade dos resultados. A composição da bancada inclui um inversor de frequência da marca WEG, modelo CFW-09, com potência nominal de 1,5 CV e corrente de 10 A, além de um motor de indução trifásico do tipo gaiola.

A bancada completa está ilustrada na Figura 4.2, enquanto o motor de indução trifásico é detalhado na Figura 4.3. As especificações técnicas do motor são apresentadas na Tabela 4.1.

Figura 4.2: Bancada de testes.



Fonte: Elaboração do autor (2023).

Figura 4.3: Motor de indução trifásico.



Fonte: Elaboração do autor (2023).

Motor Indução Trifásico	Características
Potência	1,1 CV
Velocidade	1720 RPM
Frequência	60 HZ
FS	1,15
Ip / In	7,8
Tensão	220 / 380 V
Corrente	4,43 / 2,56 A

Tabela 4.1: Características do MIT.

4.3 Materiais - Sensores

A coleta de dados foi realizada por meio de cinco sensores estrategicamente instalados no motor. Três sensores de corrente foram posicionados nas três fases de alimentação do motor, permitindo uma análise abrangente do seu desempenho elétrico. Além disso, um sensor de temperatura foi instalado para monitorar variações térmicas, enquanto um sensor de vibração do tipo acelerômetro foi utilizado para avaliar as oscilações mecânicas do sistema. Essa diversidade de sensores possibilita uma coleta abrangente de dados, fornecendo informações valiosas sobre diferentes aspectos do funcionamento do motor.

4.3.1 Medição de Corrente

Para a medição das correntes trifásicas no estator, foram utilizados sensores de corrente não invasivos baseados no efeito *Hall*, especificamente o modelo 5A/2 V - OPCT 10AL. A Figura 4.4 ilustra o sensor de corrente não invasivo, e suas características estão descritas na Tabela 4.2.

Figura 4.4: Sensor de corrente.



Fonte: Elaboração do autor (2023).


Características	Dados técnicos
Tensão alimentação	5 V (DC)
Corrente nominal	5 A (AC)
Sinal de Saída	2 V (DC)
Sensibilidade	0,4 V/A
Erro de precisão	0,5 %
Linearidade	0,5 %

Tabela 4.2: Características do sensor de corrente.

Conversão do sinal de tensão AC para DC

O sensor utilizado mede uma corrente alternada máxima de 5A RMS. Esse valor representa o valor eficaz da corrente alternada, sendo o valor RMS equivalente ao valor máximo da corrente (corrente de pico) dividido pela raiz quadrada de dois. O sensor converte uma corrente de 5 A em uma tensão de 2 V, resultando em uma sensibilidade de 0,4 V/A (ou seja, $2 \text{ V} / 5 \text{ A}$). O sinal de saída do sensor é uma tensão proporcional ao sinal da corrente medida, como ilustrado na Figura 4.5.


Figura 4.5: Sinal na saída do sensor.



Fonte: Elaboração do autor (2023).


Na Figura 4.5, é mostrado um sinal de tensão alternada oscilando entre +2,5 V e -2,5 V. Contudo, o dispositivo de interface DAQ-6008, sendo alimentado por uma fonte de 5 V, é capaz de medir sinais apenas na faixa de 0 a 5 V. Por esse motivo, torna-se necessário ajustar o sinal de modo que a sua variação permaneça dentro dessa faixa de 0 a 5 V. Para realizar esse ajuste, foi implementado um divisor de tensão, utilizando a alimentação de 5 V fornecida pelo dispositivo DAQ-6008. Nesse contexto, foram escolhidos resistores de valor igual para R1 e R2, ambos com 10 k Ω . O circuito condicionador de sinal é ilustrado na Figura 4.6, enquanto a placa condicionadora é apresentada na Figura 4.7.

Figura 4.6: Circuito de Condicionamento de Corrente.




Fonte: Elaboração do autor (2023).

Figura 4.7: Placa condicionadora de Corrente.



Fonte: Elaboração do autor (2023).

Essa configuração garante que a tensão seja distribuída igualmente entre os resistores, uma vez que os 5 V provenientes do dispositivo são divididos de forma equitativa, conforme ilustrado na Figura 4.8.


Figura 4.8: Forma de onda senoidal com valor de *offset*.

Fonte: Elaboração do autor (2023).

4.3.2 Medição de vibração

O módulo acelerômetro de 3 eixos GY-61 DXL335 utiliza o circuito integrado ADXL335. Este acelerômetro triaxial oferece um bom desempenho, caracterizado por um baixíssimo nível de ruído e consumo de energia. Com uma faixa de detecção completa de ± 3 g, o sensor é capaz de medir tanto a aceleração estática da gravidade, em aplicações de detecção de inclinação, quanto a aceleração dinâmica resultante de movimento, impacto ou vibração. O sensor de vibração é ilustrado na Figura 4.9 e suas características são apresentadas na Tabela 4.3.

Figura 4.9: Sensor acelerômetro de vibração.



Fonte: Elaboração do autor (2024).

Características	Dados técnicos
Chip do sensor	ADLX335
Faixa de tensão operacional	3 a 5 V (DC)
Fornecimento de corrente	400 uA
Faixa de escala	+/-3 g
Temperatura de operação	-40 °C a +85 °C
Sensibilidade	330 mV/g
Precisão	+/-10 %

Tabela 4.3: Características do acelerômetro.

A sensibilidade do sensor, especificada em 330 mV/g, indica que, para cada unidade de aceleração de 1 g, o sensor gera uma saída elétrica de 330 mV, considerando que 1 g equivale a uma aceleração de 9,81 m/s². A faixa de medição desse sensor varia de 0 V, que representa -3 g, até 3,3 V, correspondente a +3 g. Em termos de aceleração, isso significa que o sensor pode medir de -29,43 m/s² a +29,43 m/s².

Para expressar os valores de aceleração em m/s², foi realizada a conversão da unidade de g para m/s². Com base na sensibilidade de 330 mV/g, calculou-se que o sensor gera uma saída de 33,63 mV para cada m/s² de aceleração. Esse valor foi obtido pela relação da Equação 4.1:


$$\text{Sensibilidade} = \frac{330\text{mV/g}}{9,81 \text{ m/s}^2} = 33,63\text{mV/m/s}^2. \quad (4.1)$$

Dessa forma, a saída do sensor de vibração pode ser interpretada em termos de aceleração utilizando essa constante de conversão.

4.3.3 Medição de temperatura

Para a medição da temperatura do motor, utilizou-se o módulo sensor de temperatura LM35DZ. Este sensor é composto por um circuito integrado de alta precisão, cuja tensão de saída varia linearmente em relação à temperatura em graus Celsius. O dispositivo LM35DZ elimina a necessidade de calibração ou ajustes externos, proporcionando precisões notáveis de $\pm 1/4$ °C em condições de temperatura ambiente e $\pm 3/4$ °C ao longo de uma ampla faixa térmica, que abrange de -55 °C até 150 °C. O módulo sensor de temperatura é ilustrado na Figura 4.10, enquanto suas características estão detalhadas na Tabela 4.4.

Figura 4.10: Sensor de temperatura.



Fonte: Elaboração do autor (2024).

Características	Dados técnicos
Faixa de tensão operacional	4 a 30 V
Corrente drenada	<60 μ A
Faixa de leitura	-55 a 150 °C
Temperatura de operação	-40 °C a +85 °C
Sensibilidade	10 mV/°C
Precisão	0,5 °C (a 25 °C)

Tabela 4.4: Características do sensor de temperatura.

4.4 Processamento de dados

Durante a etapa da coleta de dados, os sensores foram conectados à placa de interface DAQ-USB-6008, fabricada pela *National Instruments*, para capturar os sinais. Esses sinais foram posteriormente processados no software LabVIEW. A placa DAQ-USB-6008 constitui uma solução acessível e de fácil utilização para interfacear sinais de entrada e saída com um computador. Sua conexão é realizada por meio de um cabo USB, que possibilita uma interação direta e eficiente com o computador. A Figura 4.11 ilustra o módulo

sensor de tensão, cujas especificações estão na Tabela 4.5.

Figura 4.11: NI USB 6008.



Fonte: Elaboração do autor (2024).

Características	Dados técnicos
Tensão de alimentação	5 V
Entradas Analógicas 12/14 bits	8
Saídas Analógicas 12 bits	2
Taxa de amostragem	1 khz
Modo de aquisição	Amostras Contínuas

Tabela 4.5: Características do NI-USB-6008.

4.4.1 Código e Diagrama de Blocos no LabVIEW

O LabVIEW é uma plataforma de desenvolvimento gráfico amplamente utilizada para sistemas de aquisição de dados, instrumentação e controle. Essa plataforma se comunica com o dispositivo NI-6008 através da Porta Serial Universal (USB) do computador. Este ambiente de desenvolvimento é composto por duas telas principais: frontal, que apresenta gráficos das grandezas medidas, como corrente, vibração e temperatura no domínio do tempo e da frequência; e o diagrama de blocos, onde são implementadas as funções para leitura dos sinais, cálculo da FFT e equações para análise dos dados. Além de representar graficamente os sinais, o LabVIEW permite a exportação dos dados para planilhas no *Excel*, que são utilizados na construção de um banco de dados destinado a alimentar


as entradas da rede neural. Para o monitoramento contínuo de vibração, corrente e temperatura, foi implementado um *loop* do tipo *while*, que interrompe a execução do sistema quando uma condição de parada, como o acionamento do botão "parar", é atendida.

O diagrama desenvolvido foi estruturado em cinco blocos principais: (i) O bloco 1, denominado *DAQ assistant*, Configura as portas da placa de aquisição de dados. (ii) O bloco 2 realiza a leitura do sinal de vibração nos três eixos do acelerômetro, gerando gráficos no domínio do tempo e da frequência. Para converter a tensão lida em unidades de aceleração, foi utilizada uma constante de $33,63 \text{ mV/m/s}^2$, calculada por meio da Equação 4.1. Após essa conversão, foi aplicada a FFT, possibilitando a análise vibracional no domínio da frequência diretamente em m/s^2 .

(iii) Similar ao Bloco 2, o bloco 3 realiza a leitura do sinal de corrente, cuja conversão da magnitude em tensão para corrente considerou a sensibilidade do sensor ($0,4 \text{ V/A}$). Para exibir os valores em corrente no gráfico, foi inserido um bloco multiplicador com a constante 2,5 (o inverso da sensibilidade).

O bloco 4 configura a leitura do sinal de temperatura, exibindo os valores em gráficos. (v) Por fim, no bloco 5, são configurados o tempo de execução do *loop while* e o critério de parada do sistema. A Figura 4.12 apresenta o diagrama de blocos desenvolvido para o processamento dos sinais no LabVIEW.

Figura 4.12: Diagrama de blocos *LabVIEW*.



Fonte: Elaboração do autor (2024).

4.5 Construção do *dataset*

Esta seção descreve a metodologia adotada para a construção dos *datasets* a partir dos sinais coletados no motor, incluindo a normalização desses dados. Para o treinamento, validação e teste da rede neural, foram construídos cinco *datasets* a partir dos sinais coletados pelos sensores instalados no motor, organizados no formato de uma tabela CSV com cinco colunas para os dados de entrada e uma coluna para os rótulos de saída da rede. Esse conjunto inclui um *dataset* padrão para treinamento da rede, e quatro *dataset* específicos, cada um representando um tipo de falha a ser classificado. Para expandir o conjunto de dados mantendo a variabilidade e a consistência dos dados originais, foi necessário gerar dados adicionais a partir das amostras experimentais coletadas. Esse processo foi realizado por meio de interpolação linear, implementada no Matlab®. Após a interpolação, o número de amostras nos *datasets* foi ampliado de 400 para 50 mil. Utilizou-se a divisão de um *dataset* em proporções como 70%-15%-15%. O conjunto de treinamento (70%) é usado para ajustar os pesos e biases da rede neural durante o processo de treinamento. Inclui a maior parte dos dados, garantindo que a rede tenha exemplos suficientes para aprender os padrões e relações nos dados. A rede utiliza esses dados para calcular o erro entre as previsões e os valores reais, ajustando os parâmetros para minimizar esse erro. O conjunto de validação (15%), é separado do conjunto de treinamento para garantir que a avaliação seja feita em dados que a rede ainda não viu durante o ajuste dos pesos. Durante o treinamento, a performance da rede no conjunto de validação é monitorada. Isso ajuda a detectar problemas como *overfitting* (quando a rede se ajusta demais aos dados de treinamento e perde capacidade de generalizar) ou *underfitting* (quando a rede não aprende suficientemente). O conjunto de teste (15%), avalia o desempenho final da rede após o treinamento. Consiste em dados completamente novos para a rede, garantindo que a avaliação do modelo seja imparcial. Após o treinamento e ajuste dos hiperparâmetros, o conjunto de teste é usado para medir a capacidade de generalização do modelo em condições reais.

Essa divisão é uma prática comum em projetos de redes neurais para garantir que o modelo aprenda bem, ajuste-se adequadamente e seja avaliado de forma confiável. As variáveis coletadas no motor apresentam diferentes escalas, o que pode fazer com que aquelas de maior magnitude dominem o aprendizado, influenciando desproporcionalmente o cálculo dos pesos em relação às variáveis de menor valor. A normalização dos dados é, portanto, uma etapa fundamental no processamento para redes neurais artificiais, pois auxilia na convergência mais rápida da rede durante o treinamento. Esse processo geralmente envolve o escalonamento dos dados para uma faixa, como $[0, 1]$ ou $[-1, 1]$, ou a padronização com média zero e desvio padrão unitário, o que prepara os dados de forma otimizada para o desempenho da rede neural (de Moura Pereira 2021). A Equação 4.2 apresenta a expressão utilizada para calcular o valor normalizado da entrada X :

$$X_{\text{normalizado}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}. \quad (4.2)$$

4.6 Ajustes da rede neural NARX

No presente trabalho, uma rede neural NARX foi adaptada para realizar a classificação de falhas em motores de indução trifásicos (MITs). A rede NARX, tradicionalmente utilizada para previsão de séries temporais, foi ajustada para uma tarefa de classificação multiclasse, com o objetivo de identificar diferentes tipos de falhas com base em entradas provenientes de sensores de vibração, temperatura e corrente. A adaptação da rede envolveu a configuração de uma camada de saída com a função de ativação softmax, permitindo que a rede forneça, como saída, um vetor de probabilidades associado a cada classe de falha. Assim, cada previsão corresponde à classe com a maior probabilidade entre as categorias: motor sem defeito, defeito desbalanceamento, rolamentos com defeito e estator com defeito.

Para otimizar a arquitetura da rede, os hiperparâmetros como o número de atrasos de entrada e *feedback*, o número de neurônios em cada camada oculta foram ajustados por meio de vários treinamentos em uma faixa de 1 a 30 iterações de varreduras até encontrar a melhor acurácia.

A configuração final incluiu duas camadas ocultas com 10 neurônios cada, funções de ativação sigmoide logística para as camadas ocultas e o algoritmo de treinamento Gradiente Conjugado Escalonado SCG (do inglês, *Scaled Conjugate Gradient*, conhecido por sua eficiência em problemas complexos).

- *Delay* – Passos de atrasos para os dados de entrada.
- *Feedback* – Passos de atrasos da realimentação da saída.
- Neuronios-H1 – Números de neurônios na primeira camada oculta.
- Neuronios-H2 – Números de neurônios na segunda camada oculta.

Para se alcançar o melhor desempenho da rede as seguintes configurações de hiperparâmetros foram determinadas:


- *TrainFcn* – *trainscg* – *Scaled Conjugate Gradient* (SCG).
- *TrainParam.epochs* – 500 – Número máximo de épocas de treinamento.
- *PerformFcn* – *crossentropy*; – Função custo-Entropia cruzada categórica.
- *layers1.transferFcn* – *logsig* – Função logística sigmoid 1ª camada oculta.
- *layers2.transferFcn* – *logsig* – Função logística sigmoid 2ª camada oculta.
- *layersend.transferFcn* – *softmax*; – Função de ativação de saída.

Para o treinamento da rede neural, utilizou-se um conjunto padrão com dados balanceados, contendo 25% das amostras para cada tipo de defeito. Essa distribuição uniforme assegura uma representação equitativa de exemplos para cada tipo de falha, favorecendo o aprendizado equilibrado da rede. Após múltiplas iterações de treinamento, foi possível identificar a melhor configuração, cujos detalhes estão apresentados na Tabela 4.6 e sua topologia para classificação multiclasse categórica ilustrada na Figura 4.13.

Delay	Feedback	Neurônio-H1	Neurônio-H2
3	4	10	10

Tabela 4.6: Melhores hiperparâmetros encontrados.

Figura 4.13: Rede neural NARX adaptada.



Fonte: Elaboração do autor (2024).

Ao final do treinamento, a rede foi avaliada em termos de acurácia nos conjuntos de treinamento, validação e teste, com base nas previsões feitas pela rede e nos rótulos reais. A abordagem demonstrou ser eficaz na classificação de falhas em MITs, destacando o potencial da rede NARX para tarefas que combinam dependências temporais com problemas de classificação.

4.7 Conclusão

Este capítulo descreveu de forma detalhada as principais ferramentas e metodologias adotadas ao longo deste trabalho. Durante o desenvolvimento, foram estabelecidas as bases essenciais para a implementação, embora alguns ajustes e decisões precisaram ser feitos ao longo do processo. Entre os pontos-chave, destacam-se a definição da arquitetura e topologia da rede neural, assim como a escolha da linguagem de programação e das bibliotecas mais adequadas para a sua implementação. Essas escolhas foram fundamentais para o êxito do projeto. No próximo capítulo, serão apresentados os experimentos realizados e os respectivos resultados.

Capítulo 5

Experimentos e resultados

O objetivo deste capítulo é apresentar os resultados obtidos a partir da aplicação da metodologia proposta, os quais visam avaliar o desempenho da rede Neural NARX, através de comparações de resposta dinâmica e eficiência. Estes resultados foram obtidos por meio de testes conduzidos na bancada experimental localizada Laboratório de Controle e Acionamento de Sistemas do DCA da Universidade Federal do Rio Grande do Norte. Foram estabelecidos quatro cenários para coletas de dados que serão descritos a continuação. Em seguida a rede neural NARX foi treinada, validada e testada com base nesses dados coletados.

5.1 Cenários para coletas de dados

O ensaio de falhas programadas seguiu um roteiro com o desenvolvimento de quatro cenários distintos para estudos de caso, visando identificar falhas no motor elétrico por meio da análise de sinais. Os cenários foram desenvolvidos para representar diversas condições de operação do motor, incluindo situações de funcionamento normal e falhas simuladas, como desbalanceamento do eixo, danos nos rolamentos e desbalanceamento das correntes do estator. Os testes foram realizados em três velocidades: 900RPM, 1200RPM e 1800RPM. Neste trabalho são apresentados apenas os dados para a velocidade de 1800RPM.

5.1.1 Cenário 1: Motor em boas condições de operação

Este cenário serve como referência, representando o funcionamento normal do motor sob condições ideais. Foram coletados sinais de vibração, corrente elétrica nas fases e temperatura. O motor com os sensores instalados está ilustrado na Figura 5.1.

Os sinais de vibração e corrente no domínio do tempo estão representados nas Figuras 5.2 e 5.4, respectivamente, enquanto os sinais no domínio da frequência para os mesmos parâmetros são mostrados nas Figuras 5.3 e 5.5.


A análise no domínio da frequência, como ilustrado na Figura 5.3, destaca um pico significativo no espectro de vibração na frequência de 30 Hz. Essa frequência corresponde à frequência mecânica do motor operando a uma velocidade de 1800 RPM, o que valida a regularidade do funcionamento sob condições normais. Esse comportamento é esperado,

pois a frequência mecânica está diretamente relacionada à rotação do eixo do motor e à sua interação com componentes estruturais. De maneira semelhante, o espectro de frequência da corrente elétrica de 60 Hz apresentado na Figura 5.5, corresponde à frequência elétrica do motor operando a uma velocidade de 1800 RPM, revela componentes harmônicos que refletem o equilíbrio do sistema e a ausência de anomalias operacionais.

O sinal de temperatura do motor em condições ideais, ilustrado na Figura 5.6, confirma o desempenho estável, com valores dentro da faixa esperada para esta operação de referência.


Esses resultados no domínio da frequência são fundamentais para validar a condição de referência do motor, pois permitem identificar tanto o padrão normal de operação quanto eventuais desvios em cenários futuros de falha.

Figura 5.1: Sensores instalados no motor.




Fonte: Elaboração do autor (2023).

Figura 5.2: Sinal de vibração no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.3: Sinal de vibração no domínio da frequência.




Fonte: Elaboração do autor (2023).

Figura 5.4: Sinal de corrente no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.5: Sinal de corrente no domínio da frequência.



Fonte: Elaboração do autor (2023).

Figura 5.6: Sinal de temperatura do motor em boas condições de operação.




Fonte: Elaboração do autor (2023).

5.1.2 Cenário 2: Motor com eixo desbalanceado

O desbalanceamento do motor é caracterizado pela distribuição irregular de massa ao redor da linha central de rotação do eixo do motor. Devido a esse desequilíbrio, as forças centrípetas geradas durante a operação aumentam o desgaste dos rolamentos. O fenômeno é tipicamente observado em todas as máquinas rotativas, e é identificado por um pico de amplitude na frequência de rotação do eixo, que é mostrado no espectro de frequência (HOLANDA 2016).


Para criar uma excentricidade dinâmica que simule o desbalanceamento no eixo do motor neste cenário, foi utilizada uma massa de 28 gramas acoplada ao disco do eixo, conforme ilustrado na Figura 5.7. O sinal de vibração resultante do desbalanceamento induzido está representado na Figura 5.8, exibindo um padrão senoidal, típico de desbalanceamentos. O sinal no domínio da frequência é apresentado na Figura 5.9, destacando um pico de amplitude na frequência de rotação do eixo, que corresponde a 30 Hz mecânicos para uma velocidade de 1800 RPM. Os sinais de corrente nos domínios do tempo e da frequência são mostrados nas Figuras 5.10 e 5.11, respectivamente, enquanto o sinal de temperatura do motor está ilustrado na Figura 5.12. Esses gráficos fornecem informações adicionais sobre o comportamento do motor sob desbalanceamento de eixo. Ao comparar o sinal de corrente do motor com eixo desbalanceado ao sinal em condições ideais, observa-se uma leve variação: a corrente aumentou de 2,8 A para 3 A, enquanto a temperatura, anteriormente em torno de 40 °C, elevou-se para aproximadamente 47 °C.

Figura 5.7: Instalação da massa para desbalanceamento do eixo.




Fonte: Elaboração do autor (2023).

Figura 5.8: Sinal de vibração no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.9: Sinal de vibração no domínio da frequência.




Fonte: Elaboração do autor (2023).

Figura 5.10: Sinal de corrente no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.11: Sinal de corrente no domínio da frequência.



Fonte: Elaboração do autor (2023).

Figura 5.12: Sinal de temperatura para motor desbalanceado.



Fonte: Elaboração do autor (2023).

5.1.3 Cenário 3: Motor com rolamentos defeituosos

Os rolamentos são compostos essencialmente por anéis internos e externos, elementos rolantes (como esferas ou rolos) e uma gaiola. Esse componente é amplamente reconhecido como uma das causas mais frequentes de falhas em máquinas rotativas. O surgimento prematuro de falhas está, em grande parte, associado a condições operacionais inadequadas. Entre os principais fatores que contribuem para falhas precoces nos rolamentos, destacam-se a contaminação por sujeira e água, sobrecarga, falta de lubrificação e procedimentos inadequados durante a montagem do conjunto do mancal. As falhas mais comuns ocorrem nas pistas internas e externas, bem como nos elementos rolantes. A detecção de falhas é frequentemente realizada por meio da conversão do sinal no domínio do tempo para o domínio da frequência. Essa abordagem é amplamente adotada por diversos motivos. Primeiramente, as falhas em máquinas podem ser identificadas no espectro do sinal por picos em frequências características, já que cada componente ou falha gera uma vibração em uma frequência única. A intensidade dessas harmônicas características fornece uma indicação tanto da presença quanto da gravidade da falha (César da Silva et al. 2020).

Cada componente de um rolamento possui uma frequência de defeito específica, o que possibilita a identificação de danos por especialistas. As frequências de defeitos calculadas são as seguintes:

- **Defeito BPFI (do inglês, *Ball Pass Frequency Inner Race*)** – Frequência de passagem da esfera pela pista do anel interno [Hz].
- **Defeito BPFO (do inglês, *Ball Pass Frequency Outer Race*)** – Frequência de passagem da esfera pela pista do anel externo [Hz].
- **Defeito BSF (do inglês, *Ball Spin Frequency*)** – Frequência de giro da esfera [Hz].
- **Defeito FTF (do inglês, *Fundamental Train Frequency*)** – Frequência da gaiola (frequência fundamental do trem) [Hz].

No site da SKF, um dos principais fabricantes de rolamentos, está disponível uma valiosa ferramenta *online* para calcular as frequências rotacional e sobrerolagem. Este calculador permite a determinação das frequências de rolamento com base na inserção manual de dados geométricos do rolamento. Para efeitos de comparação com os dados obtidos da análise do sinal de vibração para identificar rolamentos defeituosos, foram realizados cálculos para a frequência de 30 Hz mecânicos que corresponde a 1800 RPM para os rolamentos 6203-2Z e 6204-2Z.

As Figuras 5.13 e 5.14 mostram as frequências de rolamento calculadas. Os rolamentos 6403-2Z e 6404-2Z, com avarias, utilizados neste cenário de testes, estão ilustrados na Figura 5.15. O sinal de vibração está representado nas Figuras 5.16 (no domínio do tempo) e 5.17 (no domínio da frequência). O sinal de corrente é apresentado nas Figuras 5.18 (no domínio do tempo) e 5.19 (no domínio da frequência). A temperatura do motor nesse cenário está ilustrada na Figura 5.20.

Figura 5.13: Cálculo das frequências rotacional e sobrerolagem – 6203-2Z.

Resultados de Frequência

SKF	Frequência rotacional				Frequência de sobrerolagem			
	Designação	Anel interno	Anel externo	Conjunto de elementos rolantes e gaiola	Elemento rolante em seu eixo	Ponto no anel interno	Ponto no anel externo	Elemento rolante
		f _i (Hz)	f _e (Hz)	f _c (Hz)	f _r (Hz)	f _{ip} (Hz)	f _{ep} (Hz)	f _{rp} (Hz)
W 6203-2Z	30	0	11,449	59,81	148,408	91,592	119,621	

Fonte: Adaptado SKF (2023).

Figura 5.14: Cálculo das frequências rotacional e sobrerolagem – 6204-2Z.

Resultados de Frequência

SKF	Frequência rotacional				Frequência de sobrerolagem		
Designação	Anel interno	Anel externo	Conjunto de elementos rolantes e gaiola	Elemento rolante em seu eixo	Ponto no anel interno	Ponto no anel externo	Elemento rolante
	f _i (Hz)	f _e (Hz)	f _c (Hz)	f _r (Hz)	f _{ip} (Hz)	f _{ep} (Hz)	f _{rp} (Hz)
W 6204-2Z	30	0	11,549	61,741	147,61	92,39	123,483


Fonte: Adaptado SKF (2023).

Figura 5.15: Rolamentos defeituosos – 6203–2Z / 6204–2Z.




Fonte: Elaboração do autor (2023).

Figura 5.16: Sinal de vibração no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.17: Sinal de vibração no domínio da frequência.




Fonte: Elaboração do autor (2023).

Figura 5.18: Sinal de corrente no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.19: Sinal de corrente no domínio da frequência.



Fonte: Elaboração do autor (2023).

Figura 5.20: Sinal de temperatura motor rolamento com defeito.



Fonte: Elaboração do autor (2023).

Esses gráficos fornecem informações adicionais sobre o comportamento do motor com rolamentos defeituosos. Ao comparar o sinal de vibração no domínio da frequência entre os cenários motor com rolamentos defeituosos, Figura 5.17, e em boas condições de operação, Figura 5.3, notam-se picos nas frequências de 60 Hz, 80 Hz, 90 Hz e 120 Hz, vistos na Figura 5.17. Além disso, observa-se uma leve variação na corrente, que aumentou de 2,8 A para 2,9 A, enquanto a temperatura, antes próxima de 40 °C, subiu para cerca de 75 °C.

5.1.4 Cenário 4: Motor com desequilíbrio de corrente no estator


Quando as correntes do estator em um motor elétrico se desequilibram, uma série de problemas podem surgir, incluindo superaquecimento, vibração excessiva, queda de eficiência e desgaste prematuro. Para investigar esses fenômenos, uma abordagem foi adotada: um banco de resistores com uma carga ôhmica de 83.5 Ω foi conectado em série com uma das bobinas do estator, com o intuito de provocar variações nas correntes. O conjunto de resistores utilizado para induzir tais variações é ilustrado na Figura 5.21. Nas Figuras 5.22 (no domínio do tempo) e 5.23 (no domínio da frequência) são ilustrados os sinais de vibração registrados para este cenário. Nas Figuras 5.24 a 5.29 são ilustradas as leituras das correntes, tanto no domínio do tempo quanto no da frequência, correspondentes às três fases do sistema. Por fim, Na Figura 5.30 é ilustrada o comportamento da temperatura para este mesmo cenário experimental.

Figura 5.21: Banco de resistores para desequilíbrio de corrente.




Fonte: Elaboração do autor (2023).

Figura 5.22: Sinal de vibração no domínio do tempo.




Fonte: Elaboração do autor (2023).

Figura 5.23: Sinal de vibração no domínio da frequência.




Fonte: Elaboração do autor (2023).

Figura 5.24: Sinal de corrente no domínio do tempo – Fase 1.




Fonte: Elaboração do autor (2023).

Figura 5.25: Sinal de corrente no domínio da frequência – Fase 1.




Fonte: Elaboração do autor (2023).

Figura 5.26: Sinal de corrente no domínio do tempo – Fase 2.




Fonte: Elaboração do autor (2023).

Figura 5.27: Sinal de corrente no domínio da frequência - Fase 2.




Fonte: Elaboração do autor (2023).

Figura 5.28: Sinal de corrente no domínio do tempo – Fase 3.




Fonte: Elaboração do autor (2023).

Figura 5.29: Sinal de corrente no domínio da frequência – Fase 3.



Fonte: Elaboração do autor (2023).

Figura 5.30: Sinal de temperatura motor – desequilíbrio de fase.



Fonte: Elaboração do autor (2023).

Conforme ilustrado nas Figuras 5.25 (fase 1), 5.27 (fase 2) e 5.29 (fase 3), as correntes apresentam valores distintos. Na fase 1, a corrente é de 2,3 A; na fase 2, de 2,5 A; e na fase 3, de 3,7 A, com destaque para a corrente da fase 3, que é significativamente mais elevada que as demais. Esse desequilíbrio nas correntes provoca dois efeitos indesejáveis no motor: um aumento na vibração, caracterizado por picos nas frequências de 60 Hz, 120 Hz e 150 Hz (Figura 5.23), e uma elevação substancial na temperatura, que atinge aproximadamente 80 °C, conforme mostrado na Figura 5.30.

5.2 Treinamento, validação e teste da rede neural NARX

Após a adaptação dos parâmetros da rede NARX para a tarefa de classificação realizada na Seção 4.6, o modelo foi submetido aos processos de treinamento, validação e teste, utilizando o conjunto de dados construído a partir dos sinais coletados do motor nos quatro cenários previamente estabelecidos. Para avaliar o desempenho da rede, foram geradas e analisadas quatro representações gráficas.


Curva de erro da entropia cruzada – O gráfico do erro de entropia cruzada (*cross-entropy*), apresentado na Figura 5.31, ilustra a evolução do erro ao longo do treinamento do modelo. No eixo x, representa-se o número de épocas, que indica quantas vezes o algoritmo percorreu o conjunto de dados de treinamento de forma completa. Cada época corresponde a uma passagem integral pelos dados. No eixo y, encontra-se o valor do erro de entropia cruzada, uma métrica amplamente utilizada para avaliar a qualidade do modelo, medindo a discrepância entre as distribuições de probabilidade previstas e as reais. A observação da diminuição gradual das curvas de treinamento, até se estabilizarem em um erro de aproximadamente 0,0019497, indica que a rede está aprendendo bem os padrões dos dados, o que comprova sua eficiência ao longo do treinamento.

Curva ROC – A curva ROC, Figura 5.32, é gerada ao se variar o limiar de classificação do modelo, traçando a relação entre a taxa de verdadeiros positivos e a taxa de falsos positivos. O ponto ideal em uma curva ROC estaria no canto superior esquerdo, onde a taxa de verdadeiros positivos é máxima (1) e a de falsos positivos é mínima (0), indicando um modelo perfeito.

Matriz de confusão – A matriz de confusão multiclasse, ilustrada na Figura 5.33, é uma ferramenta importante para avaliar o desempenho de modelos de classificação que têm mais de duas classes. A matriz ajuda a identificar a qualidade das previsões, detalhando quais classes estão sendo corretamente ou incorretamente classificadas.


Quantidade de falhas classificadas – O gráfico que exibe a quantidade de falhas classificadas, ilustrado na Figura 5.34 permite observar em qual falha o modelo está classificando.

Figura 5.31: Curva limite de erro do conjunto de teste padrão.



Fonte: Elaboração do autor (2024).

Figura 5.32: Curva ROC do conjunto de teste padrão.




Fonte: Elaboração do autor (2024).

Figura 5.33: Matriz de confusão do conjunto de teste padrão.

Matriz de Confusão (Teste)					Classe Real
Motor sem defeito	1875 25.0%	0 0.0%	0 0.0%	0 0.0%	
Defeito desbalanceamento	0 0.0%	1875 25.0%	0 0.0%	0 0.0%	
Rolamentos com defeito	0 0.0%	0 0.0%	1871 25.0%	75 1.0%	
Estator com defeito	0 0.0%	0 0.0%	0 0.0%	1800 24.0%	
				99.0% 1.0%	
	Motor sem defeito	Defeito desbalanceamento	Rolamentos com defeito	Estator com defeito	Classe Preditiva

Fonte: Elaboração do autor (2024).

Figura 5.34: Número de falhas classificadas no conjunto de teste padrão.



Fonte: Elaboração do autor (2024).

O desempenho da rede neural treinada está apresentado na Tabela 5.1, que detalha as principais métricas avaliadas. A tabela oferece uma visão abrangente dos indicadores de acurácia, precisão, revocação (*recall*), *F1-Score*, permitindo uma análise criteriosa da eficácia do modelo em diferentes cenários. Esses resultados são fundamentais para avaliar o comportamento da rede e identificar possíveis áreas de melhoria no processo de treinamento e ajuste de parâmetros.

Acurácia	Precisão total	Racall	F1-Score
0,99	1,0	0,99	0,99

Tabela 5.1: Desempenho da rede neural NARX treinada.

A rede neural desenvolvida e adaptada foi submetida a um rigoroso processo de treinamento e avaliação, alcançando uma acurácia de 99%, o que indica excelente desempenho no reconhecimento de padrões e na classificação dos diferentes tipos de falhas do motor. Esse nível de acurácia demonstra a capacidade da rede em generalizar os dados apresentados, reduzindo significativamente o risco de erro na predição de novas amostras.

Durante o processo de treinamento, a rede neural foi ajustada com hiperparâmetros otimizados e validada em um conjunto de dados balanceado, assegurando que todas as classes de falhas estivessem igualmente representadas. Esse equilíbrio na distribuição de amostras contribuiu para o aprendizado eficiente da rede, garantindo que nenhuma categoria de falha fosse desconsiderada ou supervalorizada.

5.2.1 Aplicando ruído nos sinais do motor.

Ruído é todo sinal indesejado que interfere em uma medição, limitando assim a precisão do sistema de instrumentação. Esses sinais podem ter origem no próprio circuito de medição ou na transmissão do sinal e tem a capacidade de reduzir a inteligibilidade de informações sonoras, visuais ou de dados. Eles podem ser gerados internamente, devido ao uso de componentes passivos e ativos, ou podem ser introduzidos no circuito por fontes externas, como linhas de energia elétrica, motores elétricos, sistemas de ignição e sistemas de comunicação (Balbinot & Brusamarello 2010).

Os sinais provenientes do motor são suscetíveis a ruídos, o que torna crucial avaliar o desempenho da rede neural quando os dados de entrada estão contaminados por esses distúrbios. A relação sinal-ruído (SNR) é um parâmetro fundamental nessa análise, pois quantifica a proporção entre a potência do sinal e a potência total do ruído presente. Essa métrica é amplamente utilizada para medir a qualidade do sinal, sendo expressa pela Equação 5.1:

$$\text{SNR} = 10 \cdot \log \left(\frac{P_S}{P_N} \right), \quad (5.1)$$

onde:

SNR – relação Sinal Ruído em db;


P_S – potência do sinal;

P_N – potência do ruído.

Para avaliar o desempenho da rede neural em condições adversas, foi inserido um ruído gaussiano nos sinais coletados do motor. Esse procedimento teve como objetivo investigar o impacto de diferentes níveis de ruído na acurácia do modelo, permitindo verificar até que ponto a rede consegue manter sua eficácia mesmo quando os dados de entrada são afetados por distúrbios. A análise é essencial para determinar o nível máximo de ruído que o sistema pode tolerar sem comprometer significativamente o processo de classificação ou diagnóstico.

O gráfico de acurácia da rede em função do nível de ruído inserido é ilustrado na Figura 5.35. A partir dessa visualização, é possível observar a degradação progressiva da acurácia à medida que o ruído aumenta, o que oferece uma base sólida para identificar o ponto de saturação, ou seja, o nível de ruído a partir do qual o desempenho do modelo se torna inaceitável. Essa análise permite uma compreensão mais profunda da robustez da rede e auxilia na escolha de estratégias de mitigação de ruído, como o uso de métodos de regularização durante o treinamento.

Figura 5.35: Curva de Acurácia x SNR.



Fonte: Elaboração do autor (2024).

A curva apresentada no gráfico revela que, à medida que a relação sinal-ruído (SNR) aumenta, a acurácia da rede neural também se eleva de forma significativa. Isso indica que, com uma melhor SNR, a rede é capaz de interpretar os dados com maior preci-

são. Em níveis baixos de SNR, a predominância do ruído dificulta a distinção do sinal útil, resultando em uma acurácia inferior. À medida que a SNR se eleva, a interferência do ruído diminui, permitindo que a rede neural identifique as falhas com maior clareza, refletindo-se em uma acurácia superior.

Considerando o nível de SNR de 48 dB, conforme ilustrado na Figura 5.35, o sistema apresentou uma taxa de acertos próxima de 99 % para as classes treinadas. Em contrapartida, para uma SNR de 13 dB, a acurácia foi de 75 %. Esses resultados levam à conclusão de que a rede neural demonstra uma boa capacidade de resposta diante da interferência causada por ruídos. Essa análise reforça a importância de manter uma SNR adequada para garantir a eficácia do modelo.


5.3 Validação da rede neural NARX para novos dados

Após o treinamento da rede com dados balanceados, foram realizados novos testes com um conjunto de dados adicionais, com o intuito de validar a eficácia da rede NARX implementada. A seguir, serão apresentados quatro testes distintos que corroboram a robustez e a capacidade de generalização da rede, demonstrando seu desempenho em situações não previamente abordadas durante o treinamento. Esses testes são fundamentais para garantir que o modelo não apenas se ajuste bem aos dados de treinamento, mas também mantenha sua acurácia e confiabilidade em cenários reais.

5.3.1 Cenário 1 – Validação da rede – Motor sem defeito.


No primeiro cenário de validação da rede, um novo conjunto de dados, composto por sinais coletados de um motor em boas condições operacionais, foi inserido nas entradas da rede neural NARX. A rede respondeu de maneira satisfatória para esse tipo de falha, atingindo um desempenho de 94,2 %. Conforme ilustrado na Figura 5.36, o gráfico de entropia cruzada, que mostra a evolução do erro ao longo do treinamento, registrou um valor aproximado de 0,018618. Esse resultado evidencia que a rede conseguiu aprender os padrões de forma eficiente, refletido em seu elevado desempenho no cenário avaliado. O desempenho da rede foi também validado pelo gráfico ROC, Figura 5.37, pela matriz de confusão, Figura 5.38 e pela quantidade de falhas classificadas, Figura 5.39, que detalham a capacidade da rede em identificar corretamente as falhas nesse contexto. Além disso, a Tabela 5.2 apresenta uma visão geral do desempenho da rede.

Figura 5.36: Curva limite de erro – Motor sem defeito.




Fonte: Elaboração do autor (2024).

Figura 5.37: Curva ROC – Motor sem defeito.




Fonte: Elaboração do autor (2024).

Figura 5.38: Matriz de confusão – Motor sem defeito.



Fonte: Elaboração do autor (2024).

Figura 5.39: Falhas classificadas – Motor sem defeito.



Fonte: Elaboração do autor (2024).


Acurácia	Precisão total	Racall	F1-Score
0,94	0,96	0,98	0,97

Tabela 5.2: Desempenho da rede neural NARX – Motor sem defeito.

5.3.2 Cenário 2 – Validação da rede – Defeito Desbalanceamento.


No segundo cenário de validação da rede, um novo conjunto de dados, composto por sinais coletados de um motor com eixo desbalanceado, foi inserido nas entradas da rede neural NARX. A rede respondeu de forma satisfatória a esse tipo de falha, alcançando um desempenho de 95 %. Conforme ilustrado na Figura 5.40, o gráfico de entropia cruzada, que ilustra a evolução do erro ao longo do treinamento, registrou um valor aproximado de 0,012069, o que demonstra a capacidade da rede de aprender os padrões de forma eficiente. O desempenho da rede foi corroborado pelas análises do gráfico ROC, Figura 5.41, da matriz de confusão, Figura 5.42, e da quantidade de falhas classificadas, Figura 5.43 que forneceram uma visão detalhada da precisão do modelo na identificação correta do desbalanceamento do eixo. Essas métricas complementares reforçam a eficácia da rede na classificação das diferentes condições de falha, como ilustrado na Tabela 5.3.

Figura 5.40: Curva desempenho – defeito desbalanceamento.



Fonte: Elaboração do autor (2024).

Figura 5.41: Curva limite de erro – Defeito desbalanceamento.




Fonte: Elaboração do autor (2024).

Figura 5.42: Matriz de confusão – Defeito desbalanceamento.

		Matriz de Confusão (Teste)				
		Motor sem defeito	Defeito desbalanceamento	Rolamentos com defeito	Estator com defeito	
Classe Real	Motor sem defeito	1499 20.0%	0 0.0%	0 0.0%	375 5.0%	
	Defeito desbalanceamento	0 0.0%	3748 50.0%	0 0.0%	0 0.0%	
	Rolamentos com defeito	0 0.0%	0 0.0%	750 10.0%	0 0.0%	
	Estator com defeito	0 0.0%	0 0.0%	0 0.0%	1124 15.0%	
						95.0% 5.0%
		Motor sem defeito	Defeito desbalanceamento	Rolamentos com defeito	Estator com defeito	Classe Preditiva

Fonte: Elaboração do autor (2024).

Figura 5.43: Número de falhas classificadas – Defeito desbalanceamento.



Fonte: Elaboração do autor (2024).


Acurácia	Precisão total	Racall	F1-Score
0,95	1,0	0,95	0,97

Tabela 5.3: Desempenho da rede neural NARX – Defeito desbalanceamento.

5.3.3 Validação da rede NARX – Rolamentos com defeito.


No terceiro cenário de validação da rede, um novo conjunto de dados, composto por sinais coletados de um motor com rolamentos defeituosos, foi inserido nas entradas da rede neural NARX. A rede respondeu de forma satisfatória a esse tipo de falha, alcançando um desempenho de 98 %. Conforme ilustrado na Figura 5.44, o gráfico de entropia cruzada, que mostra a evolução do erro ao longo do treinamento, registrou um valor aproximado de 0,006815, evidenciando a capacidade da rede de aprender os padrões de maneira eficaz. Além disso, o desempenho da rede foi validado por meio do gráfico ROC, Figura 5.45, da matriz de confusão, Figura 5.46, e da quantidade de falhas classificadas, Figura 5.47 que demonstraram a competência do modelo em identificar corretamente os problemas relacionados aos rolamentos. Essas análises complementares reforçam a eficácia da rede na classificação das diferentes condições de falha, consolidando sua precisão no processo de validação, como ilustrado na Tabela 5.4.

Figura 5.44: Curva limite do erro – Rolamentos com defeito.



Fonte: Elaboração do autor (2024).

Figura 5.45: Curva ROC – Rolamentos com defeito.




Fonte: Elaboração do autor (2024).

Figura 5.46: Matriz de confusão – Rolamentos com defeito.

		Matriz de Confusão (Teste)			
Classe Real	Motor sem defeito	1750 14.0%	124 1.0%	0 0.0%	0 0.0%
	Defeito desbalanceamento	0 0.0%	2250 18.0%	0 0.0%	124 1.0%
	Rolamentos com defeito	0 0.0%	0 0.0%	6498 52.0%	0 0.0%
	Estator com defeito	0 0.0%	0 0.0%	0 0.0%	1750 14.0%
					98.0% 2.0%
		Motor sem defeito	Defeito desbalanceamento	Rolamentos com defeito	Estator com defeito
		Classe Preditiva			

Fonte: Elaboração do autor (2024).

Figura 5.47: Número de falhas classificadas – Rolamentos com defeito.



Fonte: Elaboração do autor (2024).


Acurácia	Precisão total	Racall	F1-Score
0,98	1,0	0,98	0,99

Tabela 5.4: Desempenho da rede neural NARX – Rolamentos com defeito.

5.3.4 Validação da rede NARX - Estator com defeito.


No quarto cenário de validação da rede, um novo conjunto de dados, composto por sinais coletados de um motor com desbalanceamento de fase no estator, foi inserido nas entradas da rede neural NARX. A rede respondeu de forma satisfatória a esse tipo de falha, alcançando um desempenho de 95 %. Conforme ilustrado na Figura 5.48, o gráfico de entropia cruzada, que mostra a evolução do erro ao longo do treinamento, registrou um valor aproximado de 0,010249, evidenciando a capacidade da rede de aprender os padrões de forma eficaz. Além disso, o desempenho da rede foi validado por meio do gráfico ROC, ilustrado na Figura 5.49, da matriz de confusão, ilustrada na Figura 5.50, e da quantidade de falhas classificadas, ilustrada na Figura 5.51 que demonstraram a competência do modelo em identificar corretamente os problemas associados ao desbalanceamento de fase no estator. Essas análises adicionais reforçam a eficácia da rede na classificação das diversas condições de falha, consolidando sua precisão no processo de validação, como ilustrado na Tabela Tabela 5.5.

Figura 5.48: Curva limite do erro – Estator com defeito.



Fonte: Elaboração do autor (2024).

Figura 5.49: Curva ROC – Estator com defeito.




Fonte: Elaboração do autor (2024).

Figura 5.50: Matriz de confusão – Estator com defeito.

Matriz de Confusão (Teste)						
Classe Real	Motor sem defeito	1499 20.0%	0 0.0%	0 0.0%	0 0.0%	
	Defeito desbalanceamento	0 0.0%	749 10.0%	375 5.0%	0 0.0%	
	Rolamentos com defeito	0 0.0%	0 0.0%	750 10.0%	0 0.0%	
	Estator com defeito	0 0.0%	0 0.0%	0 0.0%	4123 55.0%	
						95.0% 5.0%
	Motor sem defeito	Defeito desbalanceamento	Rolamentos com defeito	Estator com defeito	Classe Preditiva	

Fonte: Elaboração do autor (2024).

Figura 5.51: Número de falhas classificadas – Estator com defeito.



Fonte: Elaboração do autor (2024).

Acurácia	Precisão total	Racall	F1-Score
0,95	1,0	0,95	0,97

Tabela 5.5: Desempenho da rede neural NARX – Estator com defeito.

5.4 Resultados

O modelo NARX demonstrou-se uma ferramenta eficaz para o diagnóstico e classificação de falhas em motores de indução trifásicos. Após um processo de otimização para determinar o número ideal de neurônios nas duas camadas ocultas, bem como os atrasos nas entradas e saídas, a rede selecionada foi submetida a uma série de testes de validação. Os resultados desses testes indicaram uma excelente capacidade de generalização da rede em todos os cenários avaliados. Os dados obtidos comprovam o alto desempenho do modelo na classificação de falhas, mesmo diante de novos dados. A Tabela 5.6 apresenta a taxa de acerto para cada condição do motor nos quatro cenários de teste discutidos na Seção 5.1.

Motor sem defeito	Defeito desbalanceamento	Rolamentos com defeito	Estator com defeito
94.2 %	95 %	98 %	95 %

Tabela 5.6: Desempenho da rede neural NARX para cada tipo de falha classificada.

5.5 Comparando os Resultados

Nesta seção, busca-se contextualizar os resultados obtidos pela Rede Autorregressiva Não Linear com Entradas Exógenas (NARX) no cenário de trabalhos relacionados ao monitoramento e diagnóstico de falhas em motores de indução trifásicos. Diversos estudos recentes apresentaram metodologias baseadas em técnicas de inteligência artificial, utilizando diferentes abordagens e conjuntos de dados para avaliar o desempenho de modelos de diagnóstico. Embora não tenha sido possível utilizar os mesmos *datasets* empregados em outros estudos, as comparações realizadas visam destacar as similaridades e os pontos fortes observados em cada metodologia, respeitando as limitações impostas pelas diferenças nos cenários experimentais. Por exemplo, trabalhos apresentados na Tabela 5.7 relataram acurácias médias de 91,39% a 97,7%, utilizando abordagens baseadas em redes neurais profundas e algoritmos de aprendizado de máquina, respectivamente. De forma consistente, o modelo NARX desenvolvido neste estudo apresentou um desempenho competitivo, alcançando acurácias entre 94,2% e 98% no conjunto de teste, dependendo do estado operacional do motor. É importante ressaltar que o desempenho observado neste trabalho reflete o rigoroso processo de validação empregado e a diversidade do conjunto de dados utilizados, que contemplaram condições operacionais variadas. Da mesma forma, os estudos relacionados também destacam a importância de bases de dados robustas e da escolha adequada de técnicas de inteligência artificial para alcançar resultados satisfatórios. A principal contribuição deste estudo reside na aplicação da rede neural NARX, cuja estrutura se mostrou eficiente para modelar as relações dinâmicas e não lineares entre variáveis elétricas e mecânicas em motores de indução trifásicos. Essa abordagem complementa os trabalhos anteriores, ampliando as possibilidades de aplicação no setor industrial. Assim, os resultados obtidos reforçam que o modelo NARX é uma solução viável e eficaz para o diagnóstico de falhas, sem que se possa afirmar uma superioridade geral em relação a outras abordagens, dada a diversidade de métodos, condições experimentais e *datasets* nos estudos analisados. Em síntese, ao comparar os resultados deste trabalho com os da literatura, conclui-se que o modelo desenvolvido está alinhado com os avanços recentes, contribuindo para o campo de diagnóstico de falhas em motores de indução trifásicos, ao mesmo tempo que respeita as particularidades e limitações dos diferentes contextos de pesquisa.

Referência	Falhas	Algoritmo	Acurácia
Gongora et al. (2016)	Falhas em rolamentos	PMC	97 %
Lyra (2019)	Falhas em rolamentos	PMC e RBF	97 e 90 %
Araújo (2022)	Falhas de rolamentos, desbalanceamento, desalinhamento horizontal, desalinhamento vertical.	<i>Random Forest</i> , SVM, RNA e K-NN	97,18%, 94,05%, 92,1%, e 91,39 %
dos Santos & de Araújo (2023)	Falhas em rolamentos.	CNN	97,7%

Tabela 5.7: Comparação com trabalhos publicados.

5.6 Conclusão

Neste capítulo, foram apresentados os experimentos realizados e os resultados obtidos, com ênfase na análise dos quatro cenários de teste aplicados ao motor de indução trifásico. Detalhou-se o processo de treinamento, validação e teste da rede neural NARX, utilizando tanto o *datasets* padrão quanto os *datasets* modificados, que contemplam os cenários específicos de falhas. Os resultados obtidos evidenciaram o desempenho do modelo na identificação e classificação das falhas com elevada precisão, ressaltando a eficácia da abordagem proposta. Além disso, a comparação com estudos anteriores destacou as melhorias alcançadas, tanto em termos de acurácia quanto na capacidade de adaptação a diferentes condições operacionais. A análise dos experimentos confirma a viabilidade da metodologia desenvolvida, representando uma contribuição significativa para o avanço das técnicas de monitoramento e diagnóstico de falhas em motores de indução trifásicos. Os resultados discutidos aqui servirão de base para as conclusões finais, que serão abordadas no próximo capítulo.

Capítulo 6

Conclusão

Motores de indução trifásicos desempenham um papel essencial nos processos industriais devido à sua robustez, eficiência e confiabilidade. O funcionamento adequado desses equipamentos é crucial para garantir a continuidade das operações, a qualidade da produção e a segurança das instalações. No entanto, falhas nesses motores podem levar a interrupções inesperadas, custos elevados com manutenção e perda de produtividade. A identificação e classificação de falhas em estágios iniciais tornam-se, portanto, indispensáveis para aumentar a eficiência, a segurança e a durabilidade desses equipamentos. Este trabalho teve como objetivo desenvolver e aplicar uma Rede Autorregressiva Não Linear com Entradas Exógenas (NARX) para o monitoramento e a classificação de falhas em motores de indução trifásicos, com foco na detecção de falhas em estágios iniciais, no aprimoramento da precisão do diagnóstico e na garantia da continuidade operacional. Para isso, foram analisados sinais de corrente elétrica, temperatura e vibração em diferentes condições operacionais, utilizando metodologias que validaram a eficácia do modelo proposto. Os resultados obtidos evidenciam que a rede neural NARX é capaz de identificar e classificar falhas com elevada precisão, robustez e confiabilidade, mesmo em cenários operacionais complexos e sob influência de variáveis externas. A estrutura autorregressiva da rede, aliada à incorporação de entradas exógenas e ao uso de dados históricos, demonstrou ser fundamental para modelar padrões temporais e dinâmicos associados às condições de operação dos motores. Essas características permitiram ao modelo proposto alcançar taxas de precisão superiores a 94% no diagnóstico de falhas, com destaque para a detecção de rolamentos defeituosos, que atingiu 98% de acurácia em novos dados.

Entre as principais contribuições deste trabalho, destaca-se o desenvolvimento de uma metodologia eficaz para diagnóstico de falhas em motores de indução trifásicos, com resultados que apontam melhorias significativas em termos de:

- **Precisão Diagnóstica:** O modelo demonstrou capacidade de identificar falhas em seus estágios iniciais, o que contribui diretamente para evitar paradas inesperadas e custos elevados de manutenção.
- **Flexibilidade e Adaptação:** A arquitetura NARX mostrou-se altamente adaptável a diferentes cenários industriais, sendo capaz de lidar com variáveis externas, condições operacionais dinâmicas e diferentes tipos de falhas.
- **Contribuições Inovadoras:** Este trabalho se destacou ao aplicar uma rede neural NARX, tradicionalmente utilizada para previsão de séries temporais, como um clas-

sificador multiclass no contexto de motores de indução trifásicos. Essa abordagem é relativamente pouco explorada na literatura e oferece um novo paradigma para o uso dessa tecnologia em aplicações industriais.

O impacto prático da metodologia desenvolvida é evidente, pois sua aplicação em ambientes industriais pode melhorar significativamente os processos de manutenção preditiva, reduzindo custos e aumentando a confiabilidade operacional. Além disso, o trabalho complementa e reforça os avanços técnicos e científicos no campo de diagnóstico de falhas, posicionando a rede neural NARX como uma ferramenta promissora para resolver problemas complexos de engenharia elétrica. Apesar dos avanços alcançados, reconhecem-se as limitações do estudo, como o uso de um *dataset* restrito em termos de tipos e severidades de falhas e a necessidade de adaptação do modelo para implementação em sistemas embarcados. Essas questões foram consideradas ao propor recomendações para trabalhos futuros.

6.1 Trabalhos futuros

- Nesta pesquisa, a rede neural foi desenvolvida no ambiente Matlab®, o qual apresentou excelente desempenho. Contudo, para pesquisas futuras, é importante considerar a necessidade de adaptação do código para uma linguagem que possa ser incorporada em sistemas embarcados para a detecção em tempo real.
- Desenvolver uma plataforma de monitoramento remoto baseada em IoT que utilize redes neurais para detecção de falhas em motores. A implementação pode incluir a criação de um sistema que possibilite o monitoramento em tempo real e a transmissão de alertas automáticos de falhas.
- Expandir o *dataset* de falhas, incluindo outros tipos e severidades de falhas, e incorporar também diferentes modelos e tamanhos de motores. Isso pode aprimorar o treinamento da rede, tornando-a mais robusta e generalizável para diversas condições de operação.
- Utilizar a rede neural NARX em uma arquitetura preditiva para quantificar o fator de desequilíbrio em motores de indução, aplicando os métodos: NEMA, IEEE, método das componentes simétricas, e método CIGRE. Essa abordagem poderá fornecer uma análise precisa e eficiente, possibilitando a identificação antecipada de desequilíbrios e contribuindo para a manutenção preditiva dos motores.

Referências Bibliográficas

- Almounajjed, Abdelelah, Ashwin Kumar Sahoo & Mani Kant Kumar (2021), 'Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis', *Measurement* **182**, 109780.
- Alsaedi, Malik Abadulrazzaq (2015), 'Fault diagnosis of three-phase induction motor: A review', *Optics* **4**(1), 1–8.
- Aquize, Rubén, Armando Cajahuaringa, José Machuca, David Mauricio & Juan M Mauricio Villanueva (2023), 'System identification methodology of a gas turbine based on artificial recurrent neural networks', *Sensors* **23**(4), 2231.
- Araújo, Alvaro Souza de (2022), 'Análise, avaliação e validação do uso de técnicas de inteligência artificial para o diagnóstico de falhas em motores de indução'.
- Balbinot, Alexandre & Valner João Brusamarello (2010), 'Instrumentação e fundamentos de medidas–vol. 1', *Rio De* p. 20.
- Barcelos, Arlei Fonseca & Hugo Shokychi Toshimitsu (2018), 'modelo matemático neural artificial para cálculo de rendimento metálico teórico de um laminador de tiras a frio'.
- Bazan, Gustavo H. (2020), Indetificação Inteligente de Falhas em Máquinas Elétricas Utilizando Informação Mútua, Tese de doutorado, UTFPR, Cornélio Procópio,PR.
URL: <http://repositorio.utfpr.edu.br/jspui/handle/1/25597>
- Braga, Antonio de Pádua, Teresa Bernarda Ludermir & André Carlos Ponce de Leon Ferreira de Carvalho (2007), *Redes neurais artificiais: teoria e aplicações*, LTC.
- Broniera, P. J., W. S. Gongora, A. Goedel & W. F. Godoy (2013), Diagnosis of stator winding inter-turn short circuit in three-phase induction motors by using artificial neural networks, *em* '2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)', pp. 281–287.
- Bueno, Luis Felipe, Kléber Aderaldo Benatti & Tiago Santana de Nazaré (2021), 'O método de levenberg-marquardt estocástico aplicado ao treinamento de redes neurais artificiais'.
- CAMARGOS, Pedro Henrique et al. (2021), 'Sistemas inteligentes para monitoramento e diagnostico de falhas em motores de indução iec 60034/iso 20816'.

- Chapman, Stephen J (2013), *Fundamentos de máquinas elétricas*, AMGH editora.
- Connor, Richard, Alan Dearle, Ben Claydon & Lucia Vadicamo (2024), ‘Correlations of cross-entropy loss in machine learning’, *Entropy* **26**(6), 491.
- Corrêa, Weldson A. (2020), Aplicando aprendizado de máquina para estimativa de esforço no desenvolvimento de software, Dissertação de mestrado, UFMA, São Luiz, MA.
URL: <https://tedebc.ufma.br/jspui/handle/tede/tede/3289>
- Cruz, A. G. Araujo, R. Delgado Gomes, F. Antonio Belo & A. Cavalcante Lima Filho (2017), ‘A hybrid system based on fuzzy logic to failure diagnosis in induction motors’, *IEEE Latin America Transactions* **15**(8), 1480–1489.
- César da Silva, Júlio, Thyago Leite de Vasconcelos Lima, José Anselmo de Lucena Júnior, Gabriela Jordão Lyra, Filipe Vidal Souto, Hugo de Souza Pimentel, Francisco Antônio Belo & Abel Cavalcante Lima Filho (2020), ‘Non-invasive method for in-service induction motor efficiency estimation based on sound acquisition’, *Applied Sciences* **10**(11), 3757.
- de Moura Pereira, Daiane (2021), PREDIÇÃO DE MÉTRICAS EM GRAFOS TEMPORAIS UTILIZANDO REDES NEURAIAS, Tese de doutorado, Universidade Federal do Rio de Janeiro.
- Dias, André L. (2019), Diagnóstico de Anomalias em Aplicações de Acionamento de Motores Elétricos a Partir de Dados de Processo de Rede Profinet e Aprendizagem de Máquina, Tese de doutorado, EESC/USP, São Carlos, SP.
URL: <https://teses.usp.br/teses/disponiveis/18/18153/tde-10092019-104345/pt-br.php>
- dos Santos, Wallisson Fernandes Martins & Fábio Meneghetti Ugulino de Araújo (2023), ‘Detecção e diagnóstico de falhas em rolamentos, sob diferentes cargas e velocidades, utilizando redes neurais convolucionais’, *Brazilian Journal of Development* **9**(8), 24682–24700.
- Fleck, Leandro, Maria H. F. Tavares, Eduardo Eyng, Andrieli C. Helmann & Minéia A. M. Andrade (2016), ‘Redes neurais artificiais: Princípios básicos’, *Revista Eletrônica Científica Inovação e Tecnologia* **1**(13), 37–42.
- Freitas, Victor Carvalho Galvão De, Valério Gonzaga De Araujo, Daniel Carlos de Carvalho Crisóstomo, Gustavo Fernandes De Lima, Adrião Duarte Dória Neto & Andrés Ortiz Salazar (2022), ‘Velocity prediction of a pipeline inspection gauge (pig) with machine learning’, *Sensors* **22**(23), 9162.
- Furtado, Maria I. V. (2019), *Redes Neurais Artificiais: Uma Abordagem Para Sala de Aula*, Atena Editora, Ponta Grossa.
- Gongora, Wylliam Salviano, Alessandro Goedtel, Sergio Augusto Oliveira da Silva & Clayton Luiz Graciola (2016), ‘Neural approach to fault detection in three-phase induction motors’, *IEEE Latin America Transactions* **14**(3), 1279–1288.

- Guedes, Jacqueline Jordan, Alessandro Goedel, Marcelo Favoretto Castoldi, Danilo Sipoli Sanches, Paulo José Amaral Serni, Agnes Fernanda Ferreira Rezende, Gustavo Henrique Bazan & Wesley Angelino de Souza (2024), ‘Three-phase induction motor fault identification using optimization algorithms and intelligent systems’, *Soft Computing* pp. 1–16.
- Haykin, Simon (2001), *Redes Neurais: Princípios e Práticas*, ADBR, Porto Alegre.
- HOLANDA, Sandra Maria Santos (2016), Application of predictive maintenance by vibration analysis in urban train equipment with proposed maintenance plan, Dissertação de mestrado, Federal University of Pernambuco.
- Jagadanand, G & Fedora Lia Dias (2015), Arm based induction motor fault detection using wavelet and support vector machine, *em* ‘2015 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)’, pp. 1–4.
- Junior, Guanís B Vilela, Bráulio N Lima, Adriano A Pereira, Marcelo F Rodrigues, José Ricardo L Oliveira, Luís F Silio, Anderson S Carvalho, Heros R Ferreira & Ricardo P Passos (2022), ‘Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes’, *Revista CPAQV-Centro de Pesquisas Avançadas em Qualidade de Vida* **14**(2), 2.
- Kandukuri, Surya Teja, Jagath Sri Lal Senanyaka, Kjell G Robbersmyr et al. (2019), ‘A two-stage fault detection and classification scheme for electrical pitch drives in offshore wind farms using support vector machine’, *IEEE Transactions on Industry Applications* **55**(5), 5109–5118.
- Kaur, Sukhdeep, Ajay Shiv Sharma, Harpreet Kaur & Karamjit Singh (2016), Gene selection for tumor classification using resilient backpropagation neural network, *em* ‘2016 2nd International Conference on Advances in Computing, Communication, & Automation (ICACCA)(Fall)’, IEEE, pp. 1–5.
- Kavana, V & M Neethi (2018), Fault analysis and predictive maintenance of induction motor using machine learning, *em* ‘2018 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEEC-COT)’, pp. 963–966.
- Khaled, Sara, Mahmoud Fakhry & Ahmed S Mubarak (2020), Classification of pcg signals using a nonlinear autoregressive network with exogenous inputs (narx), *em* ‘2020 International Conference on Innovative Trends in Communication and Computer Engineering (ITCE)’, IEEE, pp. 98–102.
- Krutikov, Vladimir, Elena Tovbis, Predrag Stanimirović, Lev Kazakovtsev & Darjan Karabašević (2024), ‘Machine learning in quasi-newton methods’, *Axioms* **13**(4), 240.
- Kubrusly, Jessica (2023), Curso de Machine Learning: Comparação entre Modelos de Classificação Multiclasses’s homepage, Página na internet, bookdown.org.

- URL:** https://bookdown.org/jessicakubrusly/curso_de_machine_learning/_book/
- Kumar, R.Senthil, L Gerald Christopher Raj & J. Abarna (2018), Analysis of fuzzy logic based fault detection for three phase induction motor drive system, *em* '2018 4th International Conference on Electrical Energy Systems (ICEES)', pp. 700–705.
- Liboni, Luiza H. B. (2017), Diagnóstico de Falhas em Motores de Indução Trifásicos Baseado em Decomposição em Componentes Ortogonais e Aprendizagem de Máquinas, Tese de doutorado, UFRN, São Carlos, SP.
- URL:** <https://teses.usp.br/teses/disponiveis/18/18153/tde-30062017-091155/pt-br.php>
- Lima, Enio C. (2016), Diagnóstico de Motores de Indução Trifásicos Operando em Redes desequilibradas e Distorcidas, Tese de doutorado, UNIFEI, Itajubá, MG.
- URL:** <https://repositorio.unifei.edu.br/jspui/handle/123456789/642>
- Liu, Ruonan, Boyuan Yang, Enrico Zio & Xuefeng Chen (2018), 'Artificial intelligence for fault diagnosis of rotating machinery: A review', *Mechanical Systems and Signal Processing* **108**, 33–47.
- URL:** <https://www.sciencedirect.com/science/article/pii/S0888327018300748>
- Lucas, Guilherme Beraldi (2020), A new technique for monitoring and diagnosing voltage imbalances applied to three-phase induction motors using acoustic emission and wavelet transform sensors, Dissertação de mestrado, Paulista State University (Unesp), Baurú, SP.
- Lyra, Gabriela J. (2019), Sistema inteligente para diagnóstico de falhas em rolamentos de motores de indução trifásicos via análise sonora, Tese de doutorado, UFPB, João Pessoa, PB.
- URL:** <https://repositorio.ufpb.br/jspui/handle/123456789/19360>
- Mariano, Diego (2021), *Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score*.
- Miller, Catriona, Theo Portlock, Denis M Nyaga & Justin M O'Sullivan (2024), 'A review of model evaluation metrics for machine learning in genetics and genomics', *Frontiers in Bioinformatics* **4**.
- Mohamed, Menshawy, Essam Mohamed, Al-Attar Mohamed, Mohamed Abdel-Nasser & Mohamed Moustafa Hassan (2020), Detection of inter turn short circuit faults in induction motor using artificial neural network, *em* '2020 26th Conference of Open Innovations Association (FRUCT)', pp. 297–304.

- Narwade, Sumit, Prasad Kulkarni & CY Partil (2013), 'Fault detection of induction motor using current and vibration monitoring', *International Journal of Advanced Computer Research* **3**(4), 272.
- Nicolau, Alexandre, Arnaldo P. Couto, Claudio Cardozo, Daniela Jacobovitz, Danielle Monteiro, Dionisio G. Junior, Edson S. Bessa, Hamilton T. Silva & Luiz H. O. Bueno (2019), *Desmistificando o Aprendizado de Máquina*, International Association of Artificial intelligence, São Paulo.
- Nóbrega-Sobrinho, Carlos A. (2015), Estudo Comparativo de Técnicas para Diagnóstico de Falhas em Motores de Indução Trifásicos, Tese de doutorado, UFPB, João Pessoa, PB.
URL: <https://repositorio.ufpb.br/jspui/handle/tede/8958>
- Ojaghi, Mansour & Maryam Mohammadi (2016), Modeling eccentricity faults with axial asymmetry in three-phase induction motors, *em* 'IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society', pp. 1524–1529.
- Okpo, Ekom E, Peet F Le Roux & Agha F Nnachi (2023), Induction motor fault identification using support vector machine, *em* '2023 6th International Conference on Renewable Energy and Power Engineering (REPE)', pp. 168–174.
- Perin, Matheus. (2017), Estimação de Parâmetros de Motores de Indução Trifásicos Usando Impedância Instantânea, Tese de doutorado, UFRGS, Porto Alegre, RS.
URL: <https://lume.ufrgs.br/bitstream/handle/10183/169757/001048231.pdf?sequence=1&isAllowed=y>
- Plevris, Vagelis, German Solorzano, Nikolaos P Bakas & Mohamed El Amine Ben Seghier (2022), Investigation of performance metrics in regression analysis and machine learning-based prediction models, *em* '8th European Congress on Computational Methods in Applied Sciences and Engineering (ECCOMAS Congress 2022)', European Community on Computational Methods in Applied Sciences.
- Polo, Tatiana Cristina Figueira & Hélio Amante Miot (2020), 'Aplicações da curva roc em estudos clínicos e experimentais'.
- Preethi, I, S Suryaprakash & M Mathankumar (2021), A state-of-art approach on fault detection in three phase induction motor using ai techniques, *em* '2021 5th International Conference on Computing Methodologies and Communication (ICCMC)', pp. 567–573.
- Ramalho, Geraldo Luis Bezerra, Adriano Holanda Pereira, Pedro Pedrosa Rebouças Filho & Claudio Marques de Silva Medeiros (2014), 'Detecção de falhas em motores elétricos através da classificação de padrões de vibração utilizando uma rede neural elm', *Holos* **4**, 185–194.
- Santos, Araken M. (2012), Investigando a Combinação de Técnicas de Aprendizado Semissupervisionado e Classificação Hierárquica Multirrótulo, Tese de doutorado,

UFRN, Natal, RN.

URL: <https://repositorio.ufrn.br/handle/123456789/18690>

Santos, Gabriel Rocha, Jorge Nei Brito, Clarice Santana & Hygor Lara (2018), ‘Monitoramento de motores trifásicos através de inteligência artificial’, *Anais do XVIII Congresso Nacional de Engenharia Mecânica e Industrial* **2**.

Santos, Mauri S., Eduardo H. Paz, Victor B. Aguiar & Ricardo T. Pontes (2022), Non-invasive monitoring system for analysis of energy efficiency of three-phase induction motors, *em* ‘2022 Workshop on Communication Networks and Power Systems (WCNPS)’, pp. 1–6.

Seidor, Viceri (2023), As classificações dos algoritmos de Machine Learning’s homepage, Página na internet, Viceri-Seidor.

URL: <https://viceri.com.br/insights/as-classificacoes-dos-algoritmos-de-machine-learning/>

Sheikh, Aman, Sheikh Bakhsh, Muhammad Irfan, Nursyarizal Nor & Grzegorz Nowakowski (2022), ‘A review to diagnose faults related to three-phase industrial induction motors’, *Journal of Failure Analysis and Prevention* **22**.

Silva, Adilane Ribeiro (2023), Uma visão geral sobre machine learning – Classificação’s homepage, Página na internet, Statplace.

URL: <https://statplace.com.br/blog/uma-visao-geral-sobre-machine-learning/>

Silva-Filho, Nelson M. (2017), Diagnóstico de defeitos em estatores de motores de indução trifásicos por meio de sensores piezelétrico de baixo custo e redes neurais artificiais, Dissertação de mestrado, UNESP, Bauru, SP.

URL: <http://hdl.handle.net/11449/152134>

Silva-Júnior, Edson M. (2018), Técnica de diagnóstico de falhas em motores a combustão interna utilizando aprendizagem de máquina, Tese de doutorado, UFRN, Natal, RN.

URL: <https://repositorio.ufrn.br/handle/123456789/27194>

Silva, Marlio Antonio da et al. (2021), ‘Método de estimação da velocidade em motores de indução trifásicos através da corrente de armadura com aplicação da teoria do caos’.

Silva, Marlio Antonio, Jose Anselmo Lucena-Junior, Julio Cesar da Silva, Francisco Antonio Belo, Abel Cavalcante Lima-Filho, Jorge Gabriel Gomes de Souza Ramos, Romulo Camara & Alisson Brito (2024), ‘Sensorless speed estimation of induction motors through signal analysis based on chaos using density of maxima’, *Entropy* **26**(5), 361.

Souza, Danilo F. (2018), Uma avaliação do desempenho de motores elétricos de indução trifásicos comercializados no Brasil entre 1945-2016 e o impacto da legislação brasileira, Dissertação de mestrado, IEE/USP, São Paulo, SP.

URL: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/2631>

Souza, Felipe Maraschin Pereira de et al. (2019), ‘Aplicação de uma rede neural artificial narx para obtenção do comportamento dinâmico de um atenuador de impacto de alumínio do tipo honeycomb’.

Vale, Karliane M. O. (2019), Uma Proposta de Automatização do Processo de Rotulagem de Instâncias em Algoritmos de Aprendizado Semissupervisionado, Tese de doutorado, UFRN, Natal, RN.

URL: <https://repositorio.ufrn.br/handle/123456789/28464>

Vitor, Avyner L. O. (2015), Detecção de falhas de estator em motores de indução trifásicos utilizando transformada wavelet, medida rms e potência de previsão, Dissertação de mestrado, UTFPR, Cornélio Procopio, PR.

URL: <http://repositorio.utfpr.edu.br/jspui/handle/1/3194>

Vitor, Avyner L. O., Fernando M. Oliveira, Larissa A. Ronqui, Alessandro Goedel, Paulo R. Scalassara, Sérgio A. O. Silva & Marcos B. R. Valim (2014), Detecção de falhas elétricas em motores de indução utilizando rede radial basis function, *em* F. O.A. Vitor, ed., ‘XX Congresso Brasileiro de Automática’, Universidade Tecnológica Federal do Paraná – UTFPR, Belo Horizonte, MG, p. 2.

WEG (2021), *Guia de Especificação. Motores Elétricos*, WEG Motores, Jaraguá do Sul, SC.

WEG, SA (2023), ‘Specification guide: Electric motors. in portuguese language’.

Wu, Di (2024), Scaled conjugate gradient digital cancellation algorithm study for 6g full duplex wireless communication system, *em* ‘2024 International Wireless Communications and Mobile Computing (IWCMC)’, pp. 1124–1128.