



Universidade Estadual Paulista “Júlio de Mesquita Filho”
Instituto de Ciência e Tecnologia

Eduardo Ferreira Rios de Oliveira

**Determinação dos Parâmetros de Motores de Indução
Trifásico Através de Técnicas de Aprendizado de
Máquina**

Sorocaba

2026

Eduardo Ferreira Rios de Oliveira

**Determinação dos Parâmetros de Motores de Indução
Trifásico Através de Técnicas de Aprendizado de
Máquina**

Trabalho de Conclusão de Curso apresentado à Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, como parte dos requisitos para obtenção do grau de Bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Helmo Kelis Morales Paredes
Coorientador: Prof. Dr. Rafael dos Santos

Sorocaba

2026

O48d	Oliveira, Eduardo Ferreira Rios de Determinação dos parâmetros de motores de indução trifásico através de técnicas de aprendizado de máquina / Eduardo Ferreira Rios de Oliveira. -- Sorocaba, 2026 60 p. Trabalho de conclusão de curso (Bacharelado - Engenharia de Controle e Automação) - Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba Orientador: Helmo Kelis Morales Paredes Coorientador: Rafael dos Santos 1. Inteligencia artificial. 2. Motores elétricos. 3. Redes neurais (Computação). 4. Árvores de decisão. I. Título.
------	---

Eduardo Ferreira Rios de Oliveira

Determinação dos Parâmetros de Motores de Indução Trifásico Através de Técnicas de Aprendizado de Máquina

Trabalho de Conclusão de Curso apresentado ao Instituto de Ciência e Tecnologia de Sorocaba, Universidade Estadual Paulista (UNESP), como parte dos requisitos para obtenção do grau de Bacharel em Engenharia de Controle e Automação.

Data da defesa: 04/05/2026

Banca Examinadora:

Prof. Dr. Helmo Kelis Morales Paredes

Prof. Dr. Fernando Pinhabel Marafão

Prof. Dr. Leopoldo André Dutra Lusquino Filho

Agradecimentos

A conclusão deste trabalho representa muito mais do que o término de uma etapa acadêmica. Simboliza o ápice de uma jornada repleta de aprendizados, desafios superados e apoio fundamental de diversas pessoas e instituições, às quais dedico meus sinceros agradecimentos.

Em primeiro lugar, expresso minha profunda gratidão aos meus orientadores, Prof. Dr. Helmo Kelis Morales Paredes e Prof. Dr. Rafael dos Santos, cuja orientação metódica, paciência excepcional e incentivo constante foram pilares essenciais para o desenvolvimento desta pesquisa. Sua expertise técnica, disponibilidade para discussões profundas e críticas construtivas não apenas nortearam este trabalho, mas também contribuíram significativamente para minha formação como pesquisador e engenheiro.

Agradeço à Universidade Estadual Paulista (UNESP), em especial ao Instituto de Ciência e Tecnologia de Sorocaba, pela excelente infraestrutura acadêmica e pelo ambiente propício ao desenvolvimento científico, pessoal e profissional de seus estudantes. Aos professores do curso de Engenharia de Controle e Automação, meu reconhecimento pela sólida formação técnica que recebi ao longo destes anos.

Aos membros da banca examinadora, agradeço pela disponibilidade em avaliar este trabalho e pelas valiosas contribuições que certamente enriquecerão sua qualidade final.

Aos colegas de laboratório e de curso, em especial aos amigos que compartilharam desta jornada acadêmica, pelo companheirismo, pelas trocas de conhecimento e pelos momentos de descontração que tornaram os desafios mais leves. Em particular, agradeço aos colegas do grupo de pesquisa pelo ambiente colaborativo e pelo apoio mútuo durante os experimentos e discussões técnicas.

Aos técnicos e funcionários do Instituto, pelo suporte administrativo e técnico sempre prestado com competência e cordialidade.

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2022/16250-5.

Por fim, mas com especial destaque, direciono meus mais profundos agradecimentos à minha família. Aos meus pais, pelo amor incondicional, pelo sacrifício incansável e pela crença constante em meu potencial. Seus ensinamentos de perseverança, ética e dedicação formaram a base sobre a qual construí minha trajetória. Aos meus irmãos e demais familiares, pelo apoio e incentivo em todos os momentos.

Esta conquista não é individual, mas coletiva. A cada pessoa que, direta ou indiretamente, contribuiu para esta realização, meu sincero obrigado.

Resumo

Considerando os desafios associados à estimação de parâmetros internos de motores de indução trifásicos, em especial, as limitações dos métodos tradicionais, pouco abrangentes ou restritos a ensaios laboratoriais, este trabalho propõe uma metodologia alternativa para determinar tais parâmetros utilizando técnicas de aprendizado de máquina e *deep learning*, a partir de informações obtidas de catálogos dos próprios fabricantes. A abordagem desenvolvida é não invasiva e prática, permitindo obter dados essenciais para a compreensão do comportamento dinâmico das máquinas sem a necessidade de ensaios experimentais complexos. Para viabilizar a metodologia, foram utilizadas ferramentas como MATLAB/Simulink por meio da função *power_AsynchrousMachineParams* e a linguagem Python em ambientes de desenvolvimento integrado, o que possibilitou a construção de um *dataset* abrangente e representativo de diferentes categorias de motores. Esse conjunto de dados serviu de base para o treinamento e avaliação de modelos de inteligência artificial com diversas arquiteturas e algoritmos que apresentaram convergência excepcional com o comportamento de um motor avaliado experimentalmente em laboratório.

Palavras-chave: Motor de indução trifásico; Estimação de parâmetros; Aprendizado de máquina; *Deep Learning*; MATLAB/Simulink; *Python*.

Abstract

Considering the challenges associated with estimating internal parameters of three-phase induction motors, particularly the limitations of traditional methods which are often limited in scope or restricted to laboratory tests, this work proposes an alternative methodology to determine such parameters using state-of-the-art machine learning and deep learning techniques, based on information obtained from manufacturers' catalogs. The developed approach is non-invasive and practical, allowing the acquisition of essential data for understanding the dynamic behavior of machines without the need for complex experimental testing. To implement the methodology, tools such as MATLAB/Simulink and its built-in *power_AsynchronousMachineParams* function and the Python programming language in integrated development environments were used, enabling the construction of a comprehensive and representative dataset of different motor categories. This dataset served as the basis for training and evaluating artificial intelligence models with various architectures and algorithms that presented exceptional convergence with the experimentally assessed motor during laboratory tests.

Keywords: Three-phase induction motor; Parameter estimation; Machine learning; Deep Learning; MATLAB/Simulink; Python.

Lista de Figuras

1	Circuito equivalente por fase do MIT tipo gaiola simples, conforme modelo IEEE [3].	17
2	Configurações construtivas do rotor: (a) Gaiola simples, (b) Gaiola dupla sem conexão entre as gaiolas, (c) Gaiola dupla com conexão [4].	18
3	Circuito equivalente por fase do MIT tipo gaiola dupla, conforme modelo IEEE [3].	19
4	Exemplo de sub-árvore de decisão extraída do modelo <i>Random Forest</i> desenvolvido para estimação do parâmetro X_m (impedância de magnetização). A estrutura demonstra o processo decisório baseado em características nominais do motor, incluindo corrente nominal (I_n) e velocidade (N). .	24
5	Arquitetura híbrida de RNA desenvolvida para estimação de parâmetros de motores de indução, combinando elementos convolucionais e recorrentes para capturar tanto padrões locais quanto dependências temporais nos dados dos catálogos.	30
6	Curvas de torque eletromagnético para os parâmetros de gaiola-dupla estimados, usando o método de Newton Modificado e a abordagem proposta para: a) M6; b) M7; c) M8; d) M9.	44
7	Parâmetros do modelo de gaiola-dupla em p.u. obtidos por meio do Método de Newton Modificado (MNM), Redes Neurais Artificiais (ANNs) e algoritmos baseados em árvores de decisão (DTAs) para os motores: (a) M10, (b) M11, (c) M12 e (d) M13.	46
8	Respostas a variações de V_n e I_n para o motor M6 - (a) e (b) método de Newton Modificado [6], (c) e (d) respostas obtidas pelos modelos propostos. .	47
9	Configuração experimental do banco de testes para aquisição de dados. . .	49
10	Comparação entre curvas experimentais e de simulação para: (a) Velocidade angular, (b) Corrente do estator, (c) Potências ativa e reativa, (d) Fator de potência.	51

Lista de Tabelas

1	Distribuição dos motores no banco de dados por faixa de potência.	36
2	Dados dos motores utilizados para validação dos modelos de RNA.	39
3	Resultados obtidos para o Motor M1.	39
4	Resultados obtidos para o Motor M2.	40
5	Resultados obtidos para o Motor M3.	40
6	Resultados obtidos para o Motor M4.	40
7	Resultados obtidos para o Motor M5.	41
8	Distribuição de algoritmos por parâmetro.	42
9	Dados dos motores utilizados para validação dos modelos baseados em árvores de decisão.	43
10	Resultados para o Motor M6 (7,5 kW).	43
11	Resultados para o Motor M7 (15 kW).	44
12	Resultados para o Motor M8 (22 kW).	44
13	Resultados para o Motor M9 (90 kW).	45
14	Motores utilizados para análise comparativa entre RNAs e algoritmos baseados em árvores de decisão.	45
15	Resultados de referência para todos os motores analisados na comparação.	45
16	Parâmetros estimados para o motor experimental de 0,37 kW.	50

Sumário

1	Introdução	10
1.1	Objetivos	12
1.2	Objetivo Geral	12
1.3	Objetivos Específicos	12
1.4	Justificativa	13
2	Contribuições	15
2.1	Contribuições Acadêmicas	15
2.2	Contribuições Práticas	15
3	Referencial Teórico	17
3.1	Modelos em Regime Permanente do MIT: Gaiola Simples e Gaiola Dupla .	17
3.1.1	Modelo Tipo Gaiola Simples	17
3.1.2	Modelo Tipo Gaiola Dupla	18
3.2	Métodos Tradicionais de Estimacão de Parâmetros	20
3.2.1	Ensaio Laboratoriais Padronizados: Fundamentos e Procedimentos	20
3.2.2	Limitações Práticas	20
3.3	Abordagens Baseadas em Dados de Catálogo	20
3.3.1	Método por Planilhas Eletrônicas: Natarajan e Misra (1989)	20
3.3.2	Método por Newton Modificado: Pedra (2008)	21
3.4	Análise Comparativa e Transição para Abordagens Modernas	22
3.5	Fundamentos de Aprendizado de Máquina	22
3.5.1	Paradigmas de Aprendizado: Abordagens Supervisionadas	22
3.5.2	Árvores de Regressão: Fundamentos Históricos e Aplicações	23
3.5.3	Aprendizado por Ensemble: Fundamentos Teóricos	25
3.5.4	<i>Gradient Boosting</i> : Fundamentos Matemáticos e Implementação . .	25
3.6	Algoritmos Específicos e Suas Implementações	25
3.6.1	<i>Random Forest</i> : Arquitetura e Características	25
3.6.2	XGBoost (<i>eXtreme Gradient Boosting</i>)	27
3.6.3	<i>CatBoost</i>	27
3.7	Redes Neurais Artificiais: Fundamentos Históricos e Aplicações em Enge- nharia	28
3.7.1	Evolução Histórica e Fundamentos Teóricos	28
3.7.2	Complexidade Paramétrica e Requisitos de Dados	29
3.7.3	Funções de Ativação: Análise Quantitativa e Aplicações	29
3.7.4	Arquiteturas Avançadas para Dados Tabulares de Engenharia	29
3.8	Análise Comparativa de Abordagens e Métricas de Desempenho	31
3.8.1	Métricas de Avaliação para Problemas de Regressão	31

3.8.2	Protocolos de Validação e Prevenção de Overfitting	31
4	Metodologia	35
4.1	Construção do Banco de Dados e Metodologia Experimental	35
4.1.1	Compilação Sistemática de Dados de Catálogos	35
4.1.2	Determinação dos Parâmetros de Referência	36
4.2	Arquitetura da Rede Neural Artificial	36
4.2.1	Pré-processamento e Normalização dos Dados	36
4.2.2	Arquitetura Proposta da RNA	37
4.2.3	Otimização e Treinamento	37
4.3	Protocolos de Validação e Métricas de Desempenho	37
4.3.1	Validação Cruzada Robusta	38
4.3.2	Métricas de Avaliação	38
4.4	Abrangência Metodológica para Análises Comparativas Futuras	38
5	Resultados e Discussões	39
5.1	Resultados Obtidos com Redes Neurais Artificiais	39
5.1.1	Resultados para o Motor M1 (55 kW)	39
5.1.2	Resultados para o Motor M2 (0,12 kW)	39
5.1.3	Resultados para o Motor M3 (37 kW)	40
5.1.4	Resultados para os Motores M4 (1,5 kW) e M5 (300 kW)	40
5.2	Resultados com Algoritmos Baseados em Árvores de Decisão	41
5.2.1	Seleção Estratégica e Otimização dos Algoritmos	41
5.2.2	Engenharia de Atributos e Pré-processamento	42
5.2.3	Desempenho dos Modelos em Diferentes Motores	42
5.2.4	Análise Comparativa entre RNA e Algoritmos Baseados em Árvores de Decisão	44
5.2.5	Análise de Robustez a Variações na Entrada	46
5.2.6	Discussão Consolidada dos Resultados	47
5.3	Validação Experimental	48
5.3.1	Configuração Experimental e Metodologia	48
5.3.2	Instrumentação e Aquisição de Dados	49
5.3.3	Procedimento Experimental	50
5.4	Resultados Experimentais e Comparação com Simulações	50
5.4.1	Parâmetros Estimados para o Motor Experimental	50
5.4.2	Análise Comparativa das Curvas Características	51
5.5	Discussão dos Resultados Experimentais	52
5.5.1	Acurácia e Precisão das Estimativas	52
5.5.2	Implicações Práticas e Aplicabilidade Industrial	53
5.5.3	Limitações e Considerações	54

6	Conclusão	56
6.1	Síntese dos Principais Resultados	56
6.2	Limitações e Trabalhos Futuros	56
	REFERÊNCIAS	58

1 Introdução

Os Motores de Indução Trifásicos (MITs) têm caráter fundamental em sistemas de acionamento industrial modernos, sendo responsáveis por aproximadamente dois terços do consumo de energia elétrica no setor industrial [1]. Sua ampla adoção deve-se a características intrínsecas como robustez estrutural, baixa necessidade de manutenção, simplicidade construtiva e custos reduzidos quando comparados a outras tecnologias de máquinas elétricas rotativas [2]. A versatilidade operacional desses equipamentos permite sua aplicação em cenários diversos que vão desde sistemas de bombeamento e ventilação até acionamentos de precisão em ambientes industriais complexos.

Apesar de vantagens operacionais, a modelagem matemática precisa do comportamento dinâmico dos MITs representa um desafio significativo para engenheiros e pesquisadores da temática. O desempenho dessas máquinas em regime permanente e transitório é ditado por parâmetros elétricos internos que, em condições ideais, seriam determinados através de ensaios laboratoriais padronizados. Tradicionalmente, os testes a vazio e com rotor bloqueado constituem a metodologia indicada para esta finalidade [3]. No entanto, a execução desses ensaios frequentemente exige a desativação e remoção do motor de sua linha de produção, resultando em paradas operacionais e, em muitos casos, na inviabilidade prática da abordagem [4].

Em resposta a estas limitações, métodos numéricos e computacionais surgem como alternativas promissoras. Trabalhos seminais na área, como os desenvolvidos por [5] e [6], propuseram a basearam-se no Método de Newton Modificado para estimar os parâmetros do circuito equivalente de MITs a partir de dados normalmente apresentados em catálogos de fabricantes. Esta abordagem baseia-se na solução de um sistema de equações não-lineares que relaciona grandezas nominais dos motores fornecidas pelos fabricantes, como potência, torque, corrente e fator de potência, com os parâmetros do modelo de gaiola-dupla recomendado pelo IEEE [3]. Embora represente um avanço considerável, esta metodologia apresenta sensibilidade a variações estatísticas inerentes aos dados de catálogo, especialmente pronunciada em motores de baixa potência onde as curvas torque-velocidade exibem baixa variação próxima ao ponto de operação nominal [7].

A revolução digital e o advento de técnicas de Aprendizado de Máquina (ML - *Machine Learning*) trazem novas perspectivas para a solução de problemas complexos de engenharia. Neste contexto, as Redes Neurais Artificiais (RNAs) destacam-se por sua capacidade intrínseca de capturar padrões não-lineares complexos a partir de dados de entrada para atividades de regressão e classificação, posicionando-se como ferramentas de grande potencial para estimação de parâmetros em sistemas dinâmicos [8]. A arquitetura *Multilayer Perceptron* (MLP), em particular, demonstrou aplicabilidade promissora em problemas de regressão não-linear. Vale ressaltar a relação direta entre a eficácia das estimações e a qualidade e abrangência do conjunto de dados de treinamento [9].

Paralelamente, algoritmos baseados em árvores de decisão vêm ganhando notoriedade em tarefas de regressão envolvendo dados tabulares. Metodologias como *Random Forest*, *XGBoost* e *CatBoost* combinam sua capacidade de modelar relações não-lineares com mecanismos sofisticados de regularização que atenuam o fenômeno de *overfitting* [10]. Estudos comparativos recentes sugerem que, para conjuntos de dados de dimensão limitada (realidade comum em aplicações de engenharia), estes algoritmos podem superar as RNAs em termos de precisão e robustez [10].

Diante deste panorama, este trabalho apresenta uma investigação abrangente e progressiva sobre a determinação dos parâmetros do circuito equivalente de MITs de gaiola-dupla. A pesquisa, desenvolvida ao longo deste trabalho, seguiu uma trajetória metodológica que se inicia com a aplicação de RNAs e progride para uma análise comparativa que incorpora algoritmos baseados em árvores de decisão. O banco de dados, inicialmente composto por 188 motores, foi expandido para 860 unidades, permitindo uma validação abrangente das metodologias propostas.

A presente pesquisa apresenta contribuição fundamental em termos de proposição e validação de uma metodologia alternativa aos métodos já existentes demonstrando melhores resultados no que se refere à robustez a variações nos dados de entrada e eficiência computacional. A abordagem final, baseada em algoritmos de árvore de decisão, permite o fornecimento de um conjunto reduzido de parâmetros de entrada quando comparada ao método numérico tradicional, mantendo consistência mesmo diante de variações percentuais significativas nos dados informados. A metodologia proposta foi validada em laboratório com um motor real de 0,37 kW que corrobora sua eficiência com os resultados de simulação alinhando-se satisfatoriamente com as curvas experimentais de velocidade, corrente, potência e fator de potência.

Estruturalmente, este trabalho organiza-se em seções distintas. A seção 1.1 apresenta os objetivos, em um contexto geral e mais específico do trabalho. As contribuições resultantes do trabalho elaborado são apresentados na seção 2. A seção 3 apresenta o referencial teórico que sustenta a metodologia, detalhada na seção 4. Na sequência, as seções 5 e 5.3 apresentam os resultados obtidos nos diferentes testes realizados e a validação experimental da metodologia proposta. E por fim, a seção 6 apresenta as conclusões referentes ao trabalho elaborado.

1.1 Objetivos

Esta seção apresenta os objetivos que direcionaram o andamento da pesquisa, destacando o propósito central (objetivo geral) e os objetivos específicos, necessárias para sua conclusão.

1.2 Objetivo Geral

O objetivo geral deste trabalho é desenvolver, implementar e validar uma metodologia computacional baseada em técnicas de Aprendizado de Máquina para a estimação precisa dos parâmetros do circuito equivalente de motores de indução trifásicos (MITs) de rotor de gaiola-dupla, utilizando exclusivamente dados disponíveis em catálogos de fabricantes. Considerando métodos tradicionais existentes que visam solucionar a mesma problemática, busca-se superar suas limitações em termos de robustez a possíveis variações nos dados de entrada, especialmente em contextos práticos, eficiência computacional e garantia de funcionamento mesmo com número reduzido de parâmetros de entrada acessíveis, proporcionando uma alternativa viável para aplicações industriais e de engenharia.

1.3 Objetivos Específicos

Para atingir o objetivo geral, foram estabelecidos os seguintes objetivos específicos:

1. Compilar, organizar e estruturar, em formato tabular, um banco de dados robusto e representativo contendo informações nominais de motores de indução trifásicos, contemplando diferentes faixas de potências e fabricantes, a partir de catálogos técnicos disponíveis publicamente;
2. Determinar os parâmetros do circuito equivalente de gaiola-dupla para os motores que compõem o banco de dados, utilizando o Método de Newton Modificado implementado na função *power_AsynchronousMachineParams* do MATLAB, bem como validar os parâmetros obtidos por meio da comparação com curvas características disponibilizadas pelos fabricantes;
3. Projetar, implementar e otimizar arquiteturas de Redes Neurais Artificiais (RNAs) para a estimação dos sete parâmetros do modelo de gaiola dupla, considerando também abordagens híbridas não convencionais que combinem elementos convolucionais e recorrentes;
4. Investigar, implementar e avaliar algoritmos avançados baseados em árvores de decisão, tais como *Random Forest*, *XGBoost* e *CatBoost*, aplicados à estimação dos parâmetros do modelo de gaiola dupla, empregando o framework *Optuna* com o algoritmo *Tree-structured Parzen Estimator* (TPE) para a busca eficiente de hiperparâmetros;

5. Comparar o desempenho das arquiteturas de RNAs e dos algoritmos baseados em árvores de decisão, utilizando métricas rigorosas de avaliação, de modo a identificar as abordagens mais precisas, robustas e adequadas à estimação dos parâmetros do circuito equivalente;
6. Avaliar a robustez das metodologias propostas frente a variações estatísticas nos dados de entrada, simulando cenários práticos associados a incertezas de medição, dispersões paramétricas e tolerâncias de fabricação;
7. Validar experimentalmente a metodologia selecionada em um banco de testes com motor real, comparando as curvas características dinâmicas e de regime permanente, tais como velocidade, corrente, potência, fator de potência, obtidas experimentalmente com aquelas geradas por simulação a partir dos parâmetros estimados;
8. Consolidar as contribuições acadêmicas, metodológicas e práticas do trabalho, destacando suas implicações para a modelagem, simulação e análise de motores de indução trifásicos, bem como indicando perspectivas e direcionamentos para pesquisas futuras.

1.4 Justificativa

A motivação para o desenvolvimento desta pesquisa se encontra nas carências presentes nos métodos tradicionais de estimação de parâmetros de MITs, sejam eles experimentais (ensaios a vazio e rotor bloqueado) ou numéricos (como o proposto em [5] e [6]) e na demanda constante da indústria atual por soluções rápidas, não-invasivas, robustas e baseada em dados.

A utilização de técnicas de Aprendizado de Máquina, como os algoritmos baseados em árvores de decisão que vêm demonstrando superioridade em problemas tabulares com conjuntos de dados de dimensão limitada, apresenta-se como uma abordagem promissora e inovadora no contexto da Engenharia Elétrica. A capacidade de tais modelos de aprender relações não-lineares complexas a partir de dados de entrada, aliada à sua robustez e eficiência computacional, os insere como opções às pesquisas como ferramentas de grande potencial para superar limitações de sensibilidade a valores iniciais e a variações paramétricas, inerentes aos métodos numéricos tradicionais.

Além da contribuição acadêmica na intersecção entre Aprendizado de Máquinas e modelagem de máquinas elétricas, este trabalho oferece contribuições práticas. A metodologia proposta possibilita a caracterização precisa de MITs sem a necessidade de paradas produtivas para ensaios ou de informações detalhadas além daquelas contidas na placa de identificação do motor. Isto se traduz em redução de custos operacionais, viabilização de manutenção preditiva em larga escala e suporte a estratégias de eficiência energética, alinhando-se com princípios da Indústria 4.0 e da digitalização de ativos industriais.

Portanto, os objetivos aqui delineados justificam-se pelo avanço do conhecimento na área e também pelo potencial impacto positivo na eficiência, confiabilidade e viabilidade na estimação de parâmetros internos de motores de indução trifásicos.

2 Contribuições

Entre as contribuições do presente trabalho destacam-se:

2.1 Contribuições Acadêmicas

- Demonstrou-se de maneira prática a superioridade de algoritmos baseados em árvores de regressão sobre abordagens numéricas tradicionais e redes neurais em problemas de engenharia elétrica envolvendo dados tabulares de dimensão limitada;
- Como resultado, houve o aprimoramento das técnicas de estimação de parâmetros para o modelo de gaiola-dupla do IEEE, com significativa melhoria na robustez frente a variações paramétricas e redução na sensibilidade a valores iniciais;
- Adicionalmente, o trabalho contribuiu com a construção de um banco de dados estruturado e representativo, composto por 860 motores de indução trifásicos, compilados a partir de catálogos técnicos de fabricantes reconhecidos e organizados por faixas de potência, ao possibilitar estudos comparativos, validação de modelos computacionais e *benchmarking* de futuras metodologias de estimação paramétrica de máquinas elétricas.

2.2 Contribuições Práticas

- Os resultados obtidos sinalizam que a metodologia pode levar à redução significativa da necessidade de ensaios laboratoriais complexos e invasivos (ensaio a vazio e rotor bloqueado), os quais frequentemente exigem paradas produtivas custosas e equipamentos especializados;
- Desenvolveu-se uma abordagem que requer apenas cinco variáveis de entrada (corrente nominal, potência nominal, velocidade nominal, tensão nominal e torque nominal), informações normalmente disponíveis na placa de identificação do motor, em contraste com métodos tradicionais que exigem conjuntos de dados mais extensivos;
- A implementação da solução demonstra robustez frente a variações nos dados de entrada (até $\pm 5\%$), simulando condições reais em que incertezas de medição e tolerâncias de fabricação estão presentes.
- Em diferentes estratégias de controle de grandezas elétricas, tais como tensão, corrente, velocidade e torque em máquinas rotativas, o conhecimento dos parâmetros internos do motor é fundamental para a obtenção de desempenho satisfatório e elevada precisão de controle. Nesse contexto, a metodologia proposta auxilia a implementação dessas estratégias ao possibilitar a estimação e a atualização periódica

desses parâmetros. Tal abordagem permite compensar eventuais variações decorrentes das condições de operação, contribuindo para o aumento da robustez, da confiabilidade e da eficiência dos sistemas de controle.

3 Referencial Teórico

3.1 Modelos em Regime Permanente do MIT: Gaiola Simples e Gaiola Dupla

A modelagem precisa do Motor de Indução Trifásico (MIT) é fundamental para a análise do seu desempenho em regime permanente. Tais modelos baseiam-se na representação do comportamento elétrico da máquina por meio de circuitos equivalentes, que permitem a determinação de grandezas de interesse como torque, corrente e eficiência. A configuração construtiva do rotor, em particular, impõe a estrutura do modelo a ser adotado.

3.1.1 Modelo Tipo Gaiola Simples

A configuração de rotor de gaiola simples caracteriza-se pela sua robustez, simplicidade construtiva e baixo custo de manufatura. Ela é composta por barras condutoras curto-circuitadas por anéis em ambas as extremidades, formando uma estrutura resistente e de alta confiabilidade. O circuito equivalente monofásico recomendado pelo IEEE (*Institute of Electrical and Electronics Engineers*) para esta configuração é apresentado na Figura 1.




Figura 1: Circuito equivalente por fase do MIT tipo gaiola simples, conforme modelo IEEE [3].

Nesta representação, os parâmetros do estator são:

- R_1 : Resistência do enrolamento do estator $[\Omega]$.
- X_1 : Reatância de dispersão do estator $[\Omega]$.

O ramo de magnetização, responsável pela criação do fluxo magnético principal no entreferro, é definido pela reatância de magnetização X_m .

Os parâmetros do rotor, referidos ao estator, são:

- R'_2 : Resistência do rotor $[\Omega]$.
- X'_2 : Reatância de dispersão do rotor $[\Omega]$.

A variável s denota o escorregamento da máquina, dada por (1):

$$s = \frac{n_s - n}{n_s} \quad (1)$$

Onde n_s é a velocidade síncrona e n a velocidade mecânica do rotor.

A impedância equivalente do circuito, Z_{eq} , vista pelos terminais de alimentação, é calculada pela associação série-paralelo dos componentes detalhados em (2):

$$Z_{eq} = R_1 + jX_1 + \left(\frac{1}{jX_m} + \frac{1}{\frac{R'_2}{s} + jX'_2} \right)^{-1} \quad (2)$$

3.1.2 Modelo Tipo Gaiola Dupla

O motor de indução trifásico de gaiola-dupla é uma variação do motor de gaiola simples que oferece características únicas e vantagens em aplicações específicas. Esta configuração de rotor incorpora duas gaiolas concêntricas e eletricamente isoladas, embora possam ser conectadas nos anéis de curto-circuito, conforme ilustram as configurações da Figura 2.




Figura 2: Configurações construtivas do rotor: (a) Gaiola simples, (b) Gaiola dupla sem conexão entre as gaiolas, (c) Gaiola dupla com conexão [4].

A gaiola externa, tipicamente fabricada com materiais de alta resistividade e de seção transversal reduzida, apresenta alta resistência ôhmica. A gaiola interna, com maior seção e fabricada com materiais de baixa resistividade (e.g., cobre ou alumínio), possui baixa resistência. Esta arquitetura explora inteligentemente o efeito pelicular: em altas frequências (partida), a corrente concentra-se na gaiola externa de maior resistência, produzindo alto torque; à medida que o motor acelera e a frequência do rotor diminui, e a circulação de corrente migra para a gaiola interna de baixa resistência, maximizando a eficiência em regime permanente.

O circuito equivalente por fase para o modelo de gaiola dupla, padronizado pelo IEEE, é apresentado na Figura 3.




Figura 3: Circuito equivalente por fase do MIT tipo gaiola dupla, conforme modelo IEEE [3].

Neste modelo, os parâmetros do estator (R_1 , X_1) e do ramo de magnetização (X_m) mantêm-se análogos ao modelo de gaiola simples. A complexidade adicional reside na representação do rotor, que agora possui dois conjuntos de parâmetros:

- **Gaiola Interna:** Resistência R'_2 e reatância de dispersão X'_2 .
- **Gaiola Externa:** Resistência R''_2 e reatância de dispersão X''_2 .

A impedância equivalente para o circuito de gaiola dupla é, portanto, dada pela associação em paralelo dos dois ramos do rotor com o ramo de magnetização:

$$Z_{eq} = R_1 + jX_1 + \left(\frac{1}{jX_m} + \frac{1}{\frac{R'_2}{s} + jX'_2} + \frac{1}{\frac{R''_2}{s} + jX''_2} \right)^{-1} \quad (3)$$

Durante a partida ($s \approx 1$), as reatâncias indutivas do rotor (X'_2 e X''_2) representam o principal meio de circulação da corrente. Uma vez que a gaiola externa é projetada com menor indutância ($X''_2 < X'_2$), logo, sua impedância é significativamente menor. A alta resistência R''_2 resulta, então, em um torque de partida elevado. Conforme o motor acelera e o escorregamento se reduz, a influência das reatâncias diminui, e a corrente migra para a gaiola interna de baixa resistência R'_2 , otimizando a eficiência energética em regime permanente ($s \approx s_N$).

Resultados experimentais e simulações computacionais, como os documentados por [5] e corroborados pelos dados do relatório parcial, demonstram que o circuito equivalente de gaiola dupla fornece uma representação mais acurada para as curvas de torque e corrente ao longo de toda a faixa de velocidade, especialmente nas condições dinâmicas de partida. Esta fidelidade superior justifica a escolha do modelo de gaiola dupla como base para a estimação de parâmetros via técnicas de aprendizado de máquina no presente trabalho, visando aplicações onde a precisão do comportamento transitório e de partida é crítica.

3.2 Métodos Tradicionais de Estimação de Parâmetros

3.2.1 Ensaios Laboratoriais Padronizados: Fundamentos e Procedimentos

Os métodos experimentais para caracterização de MITs encontram-se rigorosamente padronizados por organismos internacionais como IEEE, IEC e NEMA, constituindo referência absoluta para validação de modelos teóricos. Estes ensaios fornecem determinações precisas dos parâmetros do circuito equivalente através de medições elétricas e mecânicas controladas.

O ensaio a vazio realiza-se com o motor desacoplado mecanicamente e alimentado em tensão e frequência nominais. Neste teste o eixo da máquina é desacoplado de qualquer tipo de carga mecânica, permitindo que o motor atinja os valores máximos de velocidade. Isso possibilita a obtenção de informações sobre a corrente necessária para a excitação da máquina e as perdas rotacionais, consideradas constantes para as diferentes condições de operação [3].

O ensaio de rotor bloqueado, executado com o rotor mecanicamente impedido de girar, emprega tensão reduzida para limitar a corrente aos valores nominais. Como o próprio nome indica, sua execução é dada com o bloqueio do rotor, evitando a rotação. A frequência da alimentação também é reduzida, uma vez que a frequência do rotor deve ser correspondente àquela encontrada na região de baixo escorregamento da máquina. Recomenda-se que a frequência seja reduzida para 25% do seu valor nominal para a realização desse teste, reforçando a necessidade de aplicação do mesmo em um ambiente apropriado.

3.2.2 Limitações Práticas

A eficiência destes métodos é diretamente relacionada a fatores que podem se apresentar como limitações práticas significativas. Entre elas, tem-se por exemplo, a necessidade de equipamentos de medição de alta precisão e realização em ambiente laboratorial adequado. Além disso, em casos, há a necessidade de desligamento de motores de processos produtivos para realização dos ensaios, o que pode levar a custos elevados em determinados cenários industriais de substituição dificultada. E por fim, para casos extraordinários, de motores de grande porte, a execução é dificultada por desafios logísticos.

Estas limitações motivaram o desenvolvimento de abordagens alternativas baseadas em dados de catálogo.

3.3 Abordagens Baseadas em Dados de Catálogo

3.3.1 Método por Planilhas Eletrônicas: Natarajan e Misra (1989)

O trabalho de [11] representou um marco na busca por técnicas de estimação, utilizando planilhas eletrônicas em computadores pessoais da época.

Contribuições Principais:

- Tornou técnicas complexas acessíveis a engenheiros de campo;
- Facilidade de acompanhamento dos cálculos passo a passo.

Limitações Identificadas:

- Restrições computacionais da época;
- Sensibilidade a valores iniciais;
- Dificuldade de convergência;
- Escalabilidade limitada.

3.3.2 Método por Newton Modificado: Pedra (2008)

Duas décadas depois, em [6] propôs-se uma abordagem sofisticada baseada no Método de Newton Modificado, representando avanço significativo em termos de precisão das estimações dos parâmetros de circuito equivalente.

Formulação Matemática: O método resolve o sistema de equações descrito por (4) - (9):

$$f_1(x) = \frac{P_N - P(s_N)}{P_N} = 0 \quad (4)$$

$$f_2(x) = \frac{PF_N - PF(s_N)}{PF_N} = 0 \quad (5)$$

$$f_3(x) = \frac{T_M - T(s_M)}{T_M} = 0 \quad (6)$$

$$f_4(x) = \frac{I_{ST} - I(1)}{I_{ST}} = 0 \quad (7)$$

$$f_5(x) = \frac{T_{ST} - T(1)}{T_{ST}} = 0 \quad (8)$$

$$f_6(x) = \frac{\eta_N - \eta(s_N)}{\eta_N} = 0 \quad (9)$$

sendo $x = \{R_1, X_1, X_m, R'_2, X'_2, R''_2, X''_2\}$ o vetor de parâmetros, P_N à potência nominal da máquina; PF_N o fator de potência nominal; T_M o torque máximo desenvolvido pela máquina; I_{ST} e T_{ST} representam a corrente de partida e torque de partida do motor, respectivamente; S_N o escorregamento nominal e S_M , o escorregamento de torque máximo. Por fim, η_N indica o rendimento nominal da máquina.

Impacto e Adoção: Atualmente, ferramentas computacionais como o MATLAB utilizam da técnica consolidada por [6] para estimação de parâmetros internos de motores trifásicos por meio da função *power_AynchronousMachineParams*, ampliando o alcance da técnica desenvolvida em comparação aos ensaios exclusivamente realizados em laboratórios.

3.4 Análise Comparativa e Transição para Abordagens Modernas

A evolução histórica demonstra progresso contínuo na busca por métodos mais precisos, robustos e acessíveis. Enquanto os ensaios laboratoriais permanecem como a solução mais adequada, suas limitações práticas impulsionaram o desenvolvimento de abordagens baseadas em informações alternativas acessíveis aos pesquisadores, como dados de catálogos de fabricantes.

Esta fundamentação estabelece as bases para o desenvolvimento de metodologias contemporâneas que buscam superar as limitações identificadas, particularmente no que se refere à robustez frente a variações nos dados de entrada e à redução do número de parâmetros requeridos.

3.5 Fundamentos de Aprendizado de Máquina

3.5.1 Paradigmas de Aprendizado: Abordagens Supervisionadas

O aprendizado de máquina supervisionado constitui uma abordagem computacional na qual modelos são treinados para aprender mapeamentos entre variáveis de entrada e saída a partir de exemplos rotulados. No contexto de problemas de regressão, como a estimação de parâmetros de MITs, o objetivo é aprender uma função $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ que mapeie variáveis de entrada (dados de catálogo) para variáveis de saída (parâmetros do circuito equivalente) minimizando uma função de perda apropriada.

A função de perda mais utilizada em problemas de regressão é o Erro Quadrático Médio (MSE):

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (10)$$

sendo y_i representa os valores observados, e $\hat{y}_i$, os valores estimados.

Para problemas com variáveis de magnitude distinta, como os parâmetros de MITs que variam de miliohm a centenas de ohms, o Erro Quadrático Médio Logarítmico (MSLE) mostra-se mais apropriado:

$$\text{MSLE} = \frac{1}{N} \sum_{i=1}^N [\log(y_i + 1) - \log(\hat{y}_i + 1)]^2 \quad (11)$$

3.5.2 Árvores de Regressão: Fundamentos Históricos e Aplicações

Os algoritmos baseados em árvores de decisão representam uma classe versátil de métodos de aprendizado de máquina com raízes históricas que remontam aos trabalhos seminais de [12] sobre Árvores de Regressão e Classificação (CART, *Classification and Regression Trees*) e [13] com o algoritmo ID3. Esta abordagem consolidou-se como uma das técnicas mais populares no mercado de aprendizado de máquina devido à sua interpretabilidade inerente e robustez para diferentes tipos de dados [14].

O conceito fundamental das árvores de decisão envolve a divisão recursiva do espaço de características em subconjuntos homogêneos mediante a aplicação sequencial de regras de decisão baseadas nos atributos de entrada. Esta estratégia assemelha-se a processos decisórios humanos, constituindo uma das principais vantagens para aplicações em engenharia onde a transparência do modelo é crucial [15].

Para problemas de regressão, as árvores de decisão (denominadas *Regression Trees*) são construídas mediante a minimização da variância entre os nós da estrutura. O algoritmo seleciona iterativamente o atributo A e o ponto de corte t que maximizam a redução na variância, formalizada por 12:

$$\Delta(D, A, t) = Var(D) - \frac{|D_{left}|}{|D|} Var(D_{left}) - \frac{|D_{right}|}{|D|} Var(D_{right}) \quad (12)$$

sendo $Var(D)$ representa a variância do nó pai, D_{left} e D_{right} os subconjuntos resultantes da divisão, e $|D|$ o número total de observações no nó.

Os critérios de divisão mais comumente empregados incluem o Erro Quadrático Médio (MSE) para regressão, definido pela Equação (10).

e o Índice de Gini ou Ganho de Informação para classificação [14]. Uma vantagem distintiva das árvores de decisão reside em sua interpretabilidade inerente [15], uma vez que a estrutura hierárquica fornece um caminho lógico e transparente para cada previsão, fator determinante em aplicações de engenharia que exigem justificativas claras para os resultados obtidos.




Figura 4: Exemplo de sub-árvore de decisão extraída do modelo *Random Forest* desenvolvido para estimação do parâmetro X_m (impedância de magnetização). A estrutura demonstra o processo decisório baseado em características nominais do motor, incluindo corrente nominal (I_n) e velocidade (N).

A Figura 4 ilustra uma sub-árvore representativa do *ensemble Random Forest* desenvolvido neste trabalho, especificamente para a estimação do parâmetro X_m . Nota-se que as divisões são baseadas predominantemente na corrente nominal (I_n [A]) e velocidade (N [rpm]), refletindo relações físicas esperadas entre parâmetros elétricos e magnéticos dos motores de indução.

O estabelecimento das árvores de decisão no mercado de aprendizado de máquina deve-se a várias características vantajosas como sua interpretabilidade, por apresentar processo decisório transparente e facilmente rastreável; robustez; tratamento de dados heterogêneos, por permitir operações com variáveis de diferentes naturezas; e seleção automática de características, cujas respectivas importâncias são inferidas através da frequência de uso nos nós.

Contudo, árvores de decisão individuais apresentam limitações significativas, incluindo alta variância e tendência ao sobreajuste (*overfitting*). Estas limitações motivaram o desenvolvimento de técnicas de *ensemble learning*, como *Random Forests* e métodos de *Boosting*, que combinam múltiplas árvores para produzir modelos mais robustos e precisos [16][17].

3.5.3 Aprendizado por Ensemble: Fundamentos Teóricos

O aprendizado por *ensemble* (conjunto) baseia-se na combinação estratégica de múltiplos modelos de aprendizado de máquina para produzir um modelo único e mais robusto. Dois paradigmas fundamentais destacam-se nesta abordagem:

Bagging (Bootstrap Aggregating): Técnica que reduz a variância do modelo através do treinamento de múltiplos estimadores independentes, cada um utilizando uma amostra aleatória com reposição (*bootstrap sample*) do conjunto de treinamento original. A previsão final é obtida pela média (para tarefas de regressão) ou votação (para tarefas de classificação) das previsões individuais. Matematicamente, para regressão, tem-se 13:

$$\hat{y}_{\text{bagging}} = \frac{1}{T} \sum_{t=1}^T \hat{y}_t \quad (13)$$

onde T representa o número de modelos no *ensemble*.

Boosting: Abordagem sequencial que constrói modelos de forma incremental, onde cada novo modelo é treinado para corrigir os erros dos modelos anteriores. Diferentemente do *bagging*, o *boosting* foca na redução do viés, adaptando-se progressivamente aos padrões mais complexos dos dados.

3.5.4 Gradient Boosting: Fundamentos Matemáticos e Implementação

O *Gradient Boosting* constitui uma implementação sofisticada do paradigma de *boosting*, onde a construção sequencial do modelo é guiada pelo gradiente da função de perda [18]. Esta abordagem permite a aplicação a diversos problemas de regressão e classificação através da minimização direta da função de perda. Sua sequência de funcionamento é detalhada pelo Algoritmo 1.

A eficácia do *Gradient Boosting* é consequência da minimização sequencial da função de perda através de direções do gradiente, permitindo a captura progressiva de relações não-lineares complexas nos dados. A taxa de aprendizado η controla a contribuição de cada modelo individual, prevenindo *overfitting* e permitindo uma convergência suave.

3.6 Algoritmos Específicos e Suas Implementações

3.6.1 Random Forest: Arquitetura e Características

O algoritmo *Random Forest* combina o conceito de *bagging* com a seleção aleatória de características, onde cada árvore é treinada em uma amostra *bootstrap* dos dados e utiliza um subconjunto aleatório de características para cada divisão [17]. A característica de dupla aleatorização promove diversidade entre as árvores e reduz significativamente a correlação entre os estimadores individuais.

Input: Conjunto de dados $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n$

Função de perda $L(y, F(x))$

Aprendiz base $\mathcal{L}_\phi$

Número de iterações M

Taxa de aprendizado η

Inicialize o modelo com um valor constante:

$$F^{(0)}(x) = \arg \min_{\theta} \sum_{i=1}^n L(y_i, \theta)$$

for $m = 1$ **até** M **do**

Calcule os resíduos $(\hat{g}_m)$ para cada instância:

$$\hat{g}_m(x_i) = \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F^{(m-1)}(x)}$$

Ajuste um novo aprendiz base ϕ_m aos resíduos negativos minimizando:

$$\phi_m = \arg \min_{\phi} \sum_{i=1}^n [-\hat{g}_m(x_i) - \beta \phi(x_i)]^2$$

Compute o peso ótimo ρ_m através de busca linear:

$$\rho_m = \arg \min_{\rho} \sum_{i=1}^n L(y_i, F^{(m-1)}(x_i) + \rho \phi_m(x_i))$$

Atualize o modelo aditivamente:

$$F^{(m)}(x) = F^{(m-1)}(x) + \eta \rho_m \phi_m(x)$$

end

Output: Modelo final:

$$F(x) \equiv F^{(M)}(x) = F^{(0)}(x) + \sum_{m=1}^M \eta \rho_m \phi_m(x)$$

Algoritmo 1: *Gradient Boosting* para Problemas de Regressão.

Para problemas de regressão, a previsão final é dada pela média das previsões individuais:

$$\hat{y}_{\text{RF}} = \frac{1}{T} \sum_{t=1}^T \hat{y}_t \quad (14)$$

A importância de cada característica é calculada por meio da redução média na impureza (ou aumento na precisão) proporcionada pela *feature* em todas as árvores nas quais ela aparece.

3.6.2 XGBoost (*eXtreme Gradient Boosting*)

O *XGBoost* representa uma implementação altamente otimizada do algoritmo de *Gradient Boosting*, incorporando diversas inovações computacionais e teóricas [19]. A função objetivo expandida inclui termos de regularização explícitos:

$$\mathcal{L}(\phi) = \sum_{i=1}^n l(\hat{y}_i, y_i) + \sum_{k=1}^K \Omega(f_k) \quad (15)$$

onde o termo de regularização é definido como:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 + \alpha \|w\|_1 \quad (16)$$

sendo:

- γ : Parâmetro de complexidade que controla o custo de adicionar novas folhas
- T : Número de folhas na árvore
- λ : Parâmetro de regularização L2 (ridge) que penaliza grandes pesos
- α : Parâmetro de regularização L1 (lasso) que zera o peso de nós com pouca influência
- w : Vetor de pesos associados às folhas

O *XGBoost* emprega técnicas avançadas de *pruning* preventivo mediante parâmetros como *max_depth* (profundidade máxima), *gamma* (ganho mínimo para divisão) e regularizações L1/L2 (*alpha* e *lambda*), que, em conjunto, promovem eficiência computacional e mitigação do *overfitting* [19].

3.6.3 CatBoost

O *CatBoost* (*Categorical Boosting*) constitui uma implementação avançada de algoritmos baseados em *Gradient Boosting*, otimizada para oferecer robustez e precisão em tarefas de regressão, mesmo na ausência de variáveis categóricas [20].

Diferentemente de outras implementações de *boosting*, o *CatBoost* incorpora uma técnica de *Ordered Boosting* que aborda o problema do *target leakage* (vazamento de informação) durante o treinamento sequencial. Esta abordagem processa as instâncias em uma ordem aleatória fixa, calculando os resíduos para cada instância com base apenas nas observações anteriores.

Para problemas de regressão como o abordado neste trabalho, o *CatBoost* utiliza uma função de perda baseada no erro quadrático médio (MSE) adaptada para o contexto de *boosting* sequencial.

Uma característica distintiva do *CatBoost* é sua arquitetura de crescimento simétrico de árvores, onde todos os nós no mesmo nível são divididos usando o mesmo critério. Esta abordagem, embora computacionalmente eficiente, mantém a capacidade de capturar relações não-lineares complexas entre as variáveis de entrada e os parâmetros do motor de indução.

3.7 Redes Neurais Artificiais: Fundamentos Históricos e Aplicações em Engenharia

3.7.1 Evolução Histórica e Fundamentos Teóricos

As Redes Neurais Artificiais (RNAs) representam um paradigma computacional com origens apontam ao trabalho pioneiro de McCulloch e Pitts (1943) sobre modelos matemáticos de neurônios biológicos. A evolução histórica desses modelos pode ser traçada através de marcos fundamentais: o desenvolvimento do perceptron por Rosenblatt [21], o algoritmo de retropropagação [22], e eventualmente o ressurgimento moderno impulsionado por avanços computacionais e teóricos [23].

A unidade fundamental, o neurônio artificial de McCulloch-Pitts, implementa uma transformação não-linear da forma:

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (17)$$

onde x_i representam as entradas, w_i os pesos sinápticos, b o *bias* e $f(\cdot)$ a função de ativação.

O desenvolvimento das arquiteturas *Multilayer Perceptron* (MLP) marcou um avanço significativo, com a demonstração formal do Teorema de Aproximação Universal por Hornik [24], que estabeleceu que redes neurais *feedforward* com uma única camada oculta e funções de ativação não-lineares são aproximadores universais de funções contínuas em espaços compactos.

3.7.2 Complexidade Paramétrica e Requisitos de Dados

Uma característica fundamental das RNAs que impacta diretamente sua aplicabilidade é sua natureza parametricamente complexa. Diferentemente de modelos tradicionais baseados em árvores, as RNAs exigem a otimização de um número tipicamente elevado de parâmetros (pesos e *biases*), o que implica em requisitos computacionais e de dados significativamente maiores [10].

Esta complexidade paramétrica exige conjuntos de dados extensos para evitar sobreajuste (*overfitting*) e garantir generalização adequada. Enquanto algoritmos baseados em árvores demonstram robustez com centenas ou milhares de amostras, RNAs tipicamente exigem ordens de grandeza superiores para alcançar desempenho ótimo [25].

3.7.3 Funções de Ativação: Análise Quantitativa e Aplicações

A escolha da função de ativação impacta significativamente a capacidade de aprendizado e convergência da rede. Para problemas de regressão em engenharia, como a estimação de parâmetros de MITs, diferentes funções foram avaliadas quantitativamente:

ReLU (Rectified Linear Unit): $f(x) = \max(0, x)$ - Apresenta eficiência computacional ótima e mitigação do problema de *vanishing gradient*, porém pode sofrer com neurônios "mortos" (*dying ReLU*) quando a entrada é consistentemente negativa. Sua derivada é descontínua na origem:

$$f'(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases} \quad (18)$$

Softplus: $f(x) = \ln(1 + e^x)$ - Fornece aproximação suave e diferenciável da ReLU, evitando o problema de neurônios mortos às custas de maior complexidade computacional. Sua derivada é a função sigmóide:

$$f'(x) = \frac{1}{1 + e^{-x}} \quad (19)$$

A análise comparativa realizada neste trabalho identificou a Softplus como particularmente adequada para camadas de saída em problemas de regressão, devido à sua continuidade e diferenciabilidade em todo o domínio, enquanto a ReLU demonstrou superioridade em camadas ocultas pela eficiência computacional.

3.7.4 Arquiteturas Avançadas para Dados Tabulares de Engenharia

A aplicação de arquiteturas especializadas a dados tabulares de catálogos de motores exigiu adaptações:

Redes Neurais Convolucionais 1D (CNNs): A operação de convolução unidimensional, definida para uma sequência de características como:

$$y[i] = \sum_{k=1}^K x[i+k-1] \cdot w[k] + b \quad (20)$$

demonstrou capacidade de extrair padrões locais em sequências de parâmetros nominais, tratando características correlacionadas (como tensão, corrente e potência) como canais em uma "imagem" unidimensional dos dados do motor.

Long Short-Term Memory (LSTM): Originalmente desenvolvidas para sequências temporais, as células LSTM adaptaram-se eficientemente para capturar dependências não-lineares entre parâmetros do motor.

A arquitetura híbrida desenvolvida e validada experimentalmente neste trabalho (Figura 5) combina camadas Conv1D (128 filtros, kernel=3) para extração de características locais, MaxPooling1D para redução dimensional, LSTM para captura de dependências complexas, Dropout (40%) para regularização, e camadas *Dense* com ativação ReLU/Softplus. Esta configuração demonstrou capacidade superior na modelagem dos parâmetros de MITs, embora com requisitos computacionais significativamente superiores aos algoritmos baseados em árvores.




Figura 5: Arquitetura híbrida de RNA desenvolvida para estimação de parâmetros de motores de indução, combinando elementos convolucionais e recorrentes para capturar tanto padrões locais quanto dependências temporais nos dados dos catálogos.

A escolha criteriosa desta arquitetura reflete o compromisso entre capacidade de modelagem e viabilidade computacional, considerando as limitações do *dataset* disponível.

3.8 Análise Comparativa de Abordagens e Métricas de Desempenho

3.8.1 Métricas de Avaliação para Problemas de Regressão

O desempenho das diferentes abordagens foi avaliado através de múltiplas métricas complementares:

Erro Percentual Absoluto (APE): Fornece uma medida relativa do erro para cada predição individual:

$$\text{APE} = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (21)$$

Erro Quadrático Médio (MSE): Penaliza mais severamente erros maiores, sendo sensível a outliers - Equação (10).

Raiz do Erro Quadrático Médio (RMSE): Mantém a mesma unidade da variável alvo, facilitando interpretação:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (22)$$

Coefficiente de Determinação (R^2): Mede a proporção da variância da variável dependente que é previsível a partir das variáveis independentes:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (23)$$

3.8.2 Protocolos de Validação e Prevenção de Overfitting

Para garantir a robustez dos resultados e prevenir *overfitting*, implementaram-se protocolos rigorosos de validação. Como a validação cruzada *k-fold* onde os dados foram divididos em $k = 8$ subconjuntos, o treinamento ocorre em $k - 1$ folds (87.5% dos dados) e é validado no fold restante (12.5%), repetindo o processo k vezes. Além disso, a otimização de hiperparâmetros constitui uma etapa crítica no desenvolvimento de modelos de aprendizado de máquina, visando identificar a configuração ótima que maximiza o desempenho preditivo. Neste trabalho, adotou-se uma abordagem bayesiana através do algoritmo *Tree-structured Parzen Estimator* (TPE) [26], implementado pelo *framework Optuna* [27], que supera as limitações de métodos tradicionais como busca em grade (*grid search*) e busca aleatória (*random search*).

Fundamentação Teórica do TPE :

O TPE baseia-se no conceito de estimação de densidade kernel para modelar a distribuição de probabilidade dos hiperparâmetros. O TPE constrói um modelo probabilístico

da relação entre hiperparâmetros e desempenho, utilizando as observações anteriores para guiar a busca de forma inteligente.

O algoritmo opera através de um processo iterativo que mantém duas distribuições de probabilidade:

$$p(x|y) = \begin{cases} \ell(x) & \text{se } y < y^* \\ g(x) & \text{se } y \geq y^* \end{cases} \quad (24)$$

onde:

- $\ell(x)$ representa a densidade de probabilidade das configurações que produziram bons resultados ($y < y^*$)
- $g(x)$ representa a densidade de probabilidade das configurações que produziram resultados ruins ($y \geq y^*$)
- y^* é um threshold definido como um quantil dos valores observados

A função de aquisição, que determina a próxima configuração a ser testada, é dada pela razão:

$$\text{EI}(x) = \frac{\ell(x)}{g(x)} \quad (25)$$

sendo EI, *Expected Improvement* (Melhoria Esperada). O algoritmo seleciona iterativamente pontos que maximizam esta razão, concentrando a busca em regiões do espaço de parâmetros com maior probabilidade de conter a configuração ótima.

Implementação Prática no Contexto Experimental No presente trabalho, o processo de otimização foi configurado com os seguintes parâmetros:

- **Número de *trials*:** 50 execuções completas do modelo;
- **Função objetivo:** Minimização do Erro Quadrático Médio (MSE) no conjunto de validação;
- **Distribuições de parâmetros:** Definições específicas para cada tipo de hiperparâmetro.

O espaço de busca para os algoritmos baseados em árvores incluiu:

$$\begin{aligned}
\text{max_depth} &\sim (3, 15) \\
\text{learning_rate} &\sim (10^{-4}, 10^{-1}) \\
\text{n_estimators} &\sim (50, 500) \\
\text{subsample} &\sim (0.5, 1.0) \\
\text{colsample_bytree} &\sim (0.5, 1.0) \\
\text{reg_alpha} &\sim (10^{-4}, 10) \\
\text{reg_lambda} &\sim (10^{-4}, 10)
\end{aligned}$$

Vantagens Comparativas da Abordagem Adotada A seleção do TPE sobre métodos tradicionais justifica-se por várias vantagens fundamentais:

- **Eficiência Computacional:** Requer significativamente menos avaliações da função objetivo comparado à busca em grade, reduzindo o tempo de experimentação de dias para horas;
- **Lidar com Espaços Complexos:** Capacidade de explorar eficientemente espaços de alta dimensionalidade com dependências complexas entre parâmetros;
- **Robustez a Ruído:** Modelagem probabilística inerentemente robusta a variações estocásticas no processo de avaliação.

Processo Iterativo de Otimização O algoritmo segue o fluxo sequencial detalhado no algoritmo 2:

Input: Espaço de busca $\mathcal{H}$, função objetivo f , número de iterações N , quantil γ

Output: Melhor configuração de hiperparâmetros x^*

Inicialize o histórico de observações $\mathcal{D} \leftarrow \emptyset$

for $i \leftarrow 1$ **até** N **do**

if $i \leq N_{warmup}$ **then**

 Amostre x_i uniformemente de $\mathcal{H}$; // Fase de exploração inicial

else

 Ajuste as densidades $\ell(x)$ e $g(x)$ usando $\mathcal{D}$ e γ

 Amostre x_i maximizando $EI(x) = \frac{\ell(x)}{g(x)}$; // Fase guiada

end

 Avalie $y_i = f(x_i)$ através de validação cruzada

 Atualize $\mathcal{D} \leftarrow \mathcal{D} \cup \{(x_i, y_i)\}$

 Atualize y^* como o γ -quantil de $\{y_1, \dots, y_i\}$

end

return $x^* = \arg \min_{(x,y) \in \mathcal{D}} y$

Algoritmo 2: Otimização de Hiperparâmetros com TPE

A eficácia desta abordagem foi validada experimentalmente através da convergência consistente para configurações ótimas em múltiplas execuções independentes.

Análise SHAP (Shapley Additive Explanations): Empregou-se parâmetros SHAP [8] para quantificar a contribuição de cada variável de entrada nas previsões, proporcionando interpretabilidade aos modelos.

Engenharia de Atributos: Aplicou-se técnicas de transformação como a transformação recíproca ($f(x) = 1/x$) para normalização de valores extremos, e expansão polinomial com *PolynomialFeatures* (degree=2) para capturar relações não-lineares.

Esta fundamentação teórica abrangente estabelece as bases sólidas para a compreensão da metodologia experimental e análise de resultados que serão apresentadas nas seções subsequentes, demonstrando a evolução sistemática da pesquisa desde os fundamentos elétricos dos motores de indução até as técnicas mais avançadas de aprendizado de máquina.

4 Metodologia

Esta seção detalha a metodologia empregada para a estimação dos parâmetros do circuito equivalente de motores de indução trifásicos (MITs) de rotor tipo gaiola-dupla, utilizando Redes Neurais Artificiais (RNAs). O processo compreendeu as etapas de construção do banco de dados, projeto e treinamento da arquitetura de RNA, e validação dos resultados.

4.1 Construção do Banco de Dados e Metodologia Experimental

4.1.1 Compilação Sistemática de Dados de Catálogos

A partir do método descrito por [6], construiu-se um *dataset* composto por 860 motores catalogados em uma ampla faixa de potências, considerando fabricantes como ABB, WEG e Siemens. De maneira geral, os catálogos em questão fornecem informações como:

- Tensão de linha nominal (V_n) em volts [V];
- Frequência nominal (f_n) em hertz [Hz];
- Potência nominal (P_n) em quilowatts [kW];
- Corrente nominal (I_n) em amperes [A];
- Torque nominal (T_n) em newton-metros [Nm];
- Velocidade nominal (N_n) em rotações por minuto [RPM];
- Razão corrente de partida/corrente nominal (I_s/I_n);
- Razão torque de partida/torque nominal (T_s/T_n);
- Razão torque máximo/torque nominal (T_b/T_n);
- Fator de potência nominal (PF);
- Eficiências em 100%, 75% e 50% da carga nominal [%];

A distribuição final do banco de dados, organizada por faixas de potência, é apresentada na Tabela 1, demonstrando a abrangência e representatividade do conjunto de dados levantado.

Tabela 1: Distribuição dos motores no banco de dados por faixa de potência.

Faixa de Potência (kW)	Quantidade de Motores
$P < 1$	99
$1 \leq P < 10$	232
$10 \leq P < 100$	271
$100 \leq P < 200$	113
$200 \leq P < 300$	48
$P \geq 300$	97

4.1.2 Determinação dos Parâmetros de Referência

Para estabelecer valores de referência para treinamento e validação dos modelos de aprendizado de máquina, empregou-se a função *power_AynchronousMachineParams* do MATLAB, que implementa o método de Newton Modificado proposto em [6]. Esta função resolve numericamente o sistema de seis equações não-lineares que relacionam os parâmetros do catálogo com os parâmetros do circuito equivalente de gaiola-dupla.

O processo de validação dos parâmetros obtidos incluiu a comparação sistemática entre as curvas torque-velocidade e corrente-velocidade fornecidas pelos fabricantes e aquelas geradas pela simulação com os parâmetros estimados. Esta verificação assegurou a coerência física dos resultados e a adequação dos parâmetros como referência para os modelos de aprendizado de máquina.

4.2 Arquitetura da Rede Neural Artificial

Para a estimação dos parâmetros do MIT, foi desenvolvida uma rede neural do tipo *Multilayer Perceptron* (MLP) com arquitetura híbrida, combinando camadas especializadas para extração de características e captura de dependências temporais.

4.2.1 Pré-processamento e Normalização dos Dados

Os dados de entrada foram submetidos a um rigoroso processo de pré-processamento:

- **Seleção de Variáveis:** Foram selecionadas 10 variáveis de entrada (as mesmas utilizadas por [6]) baseadas na disponibilidade nos catálogos e relevância para o problema.
- **Normalização:** Aplicou-se a técnica de padronização (*standardization*) utilizando *StandardScaler* da biblioteca *scikit-learn*:

$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (26)$$

- **Validação Cruzada:** Implementou-se validação cruzada *k-fold* com $k = 8$, utilizando 87.5% dos dados para treinamento e 12.5% para teste em cada iteração.

4.2.2 Arquitetura Proposta da RNA

A arquitetura final da RNA, implementada em Python utilizando *TensorFlow* e *Keras*, é composta pelas seguintes camadas:

1. **Camada de Entrada:** 10 neurônios, correspondentes às variáveis de catálogo
2. **Camada Conv1D:** 128 filtros, kernel size=3, ativação ReLU
3. **Camada MaxPooling1D:** Tamanho 2, para redução dimensional
4. **Duas Camadas LSTM:** 128 unidades cada, ativação ReLU
5. **Camada Dropout:** Taxa de 40%, para prevenção de *overfitting*
6. **Camada Dense:** 128 neurônios, ativação ReLU
7. **Camada de Saída:** 7 neurônios com ativação *softplus*, correspondentes aos parâmetros do circuito equivalente

A escolha da função de ativação *softplus* na camada de saída deve-se à sua adequação para problemas de regressão, proporcionando saída contínua e diferenciável.

4.2.3 Otimização e Treinamento

O treinamento da RNA foi conduzido com as seguintes configurações:

- **Otimizador:** Adam com taxa de aprendizado $\eta = 0.0025$
- **Função de Perda:** Erro Quadrático Médio Logarítmico (MSLE)
- **Métrica de Avaliação:** MSLE
- **Épocas:** O treinamento foi monitorado através de *early stopping* baseado na perda de validação

A função MSLE mostrou-se particularmente adequada devido à grande variação nas magnitudes dos parâmetros do MIT (de miliohms a centenas de ohms), sendo calculada a partir da equação (11).

4.3 Protocolos de Validação e Métricas de Desempenho

Para avaliação abrangente do modelo, foram implementados múltiplos protocolos de validação:

4.3.1 Validação Cruzada Robusta

- **k-fold Cross Validation:** Divisão dos dados em 8 *folds* com repetição múltipla do processo de treinamento e validação
- **Early Stopping:** Interrupção do treinamento quando a perda de validação não apresenta melhora

4.3.2 Métricas de Avaliação

O desempenho do modelo foi quantificado através das seguintes métricas:

- **Erro Percentual Absoluto:**

$$\text{Erro \%} = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (27)$$

4.4 Abrangência Metodológica para Análises Comparativas Futuras

A metodologia aqui descrita estabelece as bases para uma avaliação abrangente da capacidade das RNAs em estimar parâmetros de MITs, enquanto proporciona o *framework* necessário para análises comparativas futuras com outras abordagens de aprendizado de máquina, particularmente com algoritmos baseados em árvores de decisão que serão explorados em trabalhos subsequentes.

5 Resultados e Discussões

5.1 Resultados Obtidos com Redes Neurais Artificiais

O modelo de RNA desenvolvido foi submetido a testes para validação considerando motores com diferentes faixas de potência, buscando uma análise abrangente do desempenho da metodologia em diferentes condições operacionais. Definiu-se cinco motores (M1 a M5) para análise, cujos dados nominais conforme catálogos de fabricantes são apresentados na Tabela 2.

Tabela 2: Dados dos motores utilizados para validação dos modelos de RNA.

ID	V_n [V]	f_n [Hz]	P [kW]	I_n [A]	T_n [Nm]	N [rpm]	I_s/I_n	T_s/T_n	T_b/T_n	$FP_{100\%}$
M1	220	60	55	173	147,6881	3565	8,5	2,6	3,6	0,89
M2	220	60	0,12	0,891	0,6865	1720	4,5	3	3,2	0,62
M3	220	60	37	125	296,2589	1185	7	2,7	2,8	0,83
M4	220	60	1,5	7,21	12,2583	1150	5,8	2,4	2,8	0,7
M5	220	60	300	1010	2360,1665	1190	6,5	2	2,1	0,82

5.1.1 Resultados para o Motor M1 (55 kW)

O Motor M1 possui potência nominal dentro da faixa mais representativa do *dataset*, com 271 motores nesta categoria. Os resultados das previsões para este motor estão apresentados na Tabela 3.

Tabela 3: Resultados obtidos para o Motor M1.

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	0,0333	0,0268	1,7993	0,0594	0,0080	0,0268	0,1084
Estimado	0,0533	0,0375	2,3293	0,1419	0,0233	0,0376	0,0836
Dif. (%)	59,9598	40,0158	29,4584	138,9119	190,6836	40,2626	22,8463

A análise das diferenças percentuais revela erros consideráveis em todos os parâmetros, com a melhor previsão sendo a da resistência da gaiola externa (R''_2), ainda assim com uma diferença percentual de 22,8463%. Apresentando, portanto, erros significativos que podem levar a uma interpretação inadequada da operação da máquina.

5.1.2 Resultados para o Motor M2 (0,12 kW)

O Motor M2 representa a faixa de baixa potência, permitindo validar a amplitude do *dataset* construído. Os resultados são apresentados na Tabela 4.

Tabela 4: Resultados obtidos para o Motor M2.

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	24,4178	7,5899	142,9629	7,7610	23,2654	7,5899	23,3524
Estimado	14,4665	5,5693	89,8889	6,6574	14,6163	5,7165	16,3288
Dif. (%)	40,7542	26,6219	37,1243	14,2192	37,1756	24,6828	30,0765

Embora a expansão do *dataset* busque validar o desempenho da metodologia proposta até mesmo em motores menores, ainda são observadas diferenças consideráveis que comprometem a compreensão da dinâmica da máquina.

5.1.3 Resultados para o Motor M3 (37 kW)

O Motor M3 também se encontra na faixa de potência mais representada no *dataset*. Os resultados são apresentados na Tabela 5.

Tabela 5: Resultados obtidos para o Motor M3.

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	0,0492	0,0539	2,0761	0,1537	0,0161	0,0539	0,1014
Estimado	0,0734	0,0582	1,9574	0,1848	0,0345	0,0617	0,1057
Dif. (%)	49,2053	7,9220	5,7195	20,2385	114,1350	14,4690	4,2102

Embora alguns parâmetros como X_1 e R''_2 apresentem erros percentuais razoáveis (7,922% e 4,2102%, respectivamente), outros como R'_2 apresentam erro superior a 100%, prejudicando a análise.

5.1.4 Resultados para os Motores M4 (1,5 kW) e M5 (300 kW)

As Tabelas 6 e 7 apresentam os resultados para os motores M4 e M5, representando os limites inferior e superior da faixa de potências do *dataset*.

Tabela 6: Resultados obtidos para o Motor M4.

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	2,3797	0,7615	20,2183	0,7630	1,9468	0,7615	1,9690
Estimado	2,5579	0,8921	23,8813	1,2506	2,2372	0,8517	2,3400
Dif. (%)	7,4893	17,1521	18,1172	63,9025	14,9143	11,8486	18,8401

A análise dos resultados apresentados nas Tabelas 3 a 7 revela uma baixa precisão do modelo de RNA utilizado. Os erros percentuais variam significativamente entre os diferentes parâmetros e motores, com valores que chegam a ultrapassar 150% em casos.

Tabela 7: Resultados obtidos para o Motor M5.

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	0,0062	0,0090	0,2689	0,0248	0,0013	0,0090	0,0101
Estimado	0,0035	0,0017	0,4543	0,0086	0,0033	0,0009	0,0114
Dif. (%)	43,6115	81,1086	68,9422	65,3383	151,3199	89,7146	12,5715

Os melhores resultados foram observados para parâmetros como R''_2 no Motor M1 (22,85%) e R'_2 no Motor M3 (4,21%), enquanto os piores desempenhos foram verificados em parâmetros como R'_2 no Motor M3 (114,14%) e R'_2 no Motor M5 (151,32%).

Estes resultados indicam a necessidade de estudos mais aprofundados para determinar a melhor parametrização da RNA para esta aplicação específica, o que motivou a investigação de abordagens alternativas baseadas em algoritmos de árvore de decisão, que serão discutidas na próxima seção.

5.2 Resultados com Algoritmos Baseados em Árvores de Decisão

Diante dos resultados limitados obtidos com as RNAs, conforme detalhado na Seção 5.1, investigou-se abordagens alternativas baseadas em algoritmos de árvores de decisão. Esta transição metodológica foi fundamentada em evidências recentes da literatura que demonstram a superioridade de algoritmos baseados em árvores para conjuntos de dados tabulares de dimensão limitada [10]. Considerando que o *dataset* construído compreende 860 motores - quantidade insuficiente para otimização eficiente dos parâmetros de redes neurais profundas [25] -, a adoção de técnicas alternativas mostrou-se necessária e estratégica.

5.2.1 Seleção Estratégica e Otimização dos Algoritmos

A seleção dos algoritmos *XGBoost*, *CatBoost* e *Random Forest* foi fundamentada em suas características complementares. O processo de otimização empregou o framework *Optuna* com o algoritmo *Tree-structured Parzen Estimator* (TPE), realizando 50 iterações de busca para cada combinação algoritmo-parâmetro. Foram avaliados hiperparâmetros como o número de estimadores, a profundidade máxima das árvores e o número mínimo de amostras necessárias para dividir um nó.

A Tabela 8 apresenta a distribuição final dos algoritmos por parâmetro, resultante de um processo rigoroso de avaliação baseado no Erro Quadrático Médio Logarítmico (MSLE). Cada um dos três algoritmos foram submetidos aos mesmo procedimentos de treinamento e validação. Durante a validação, o modelo que apresentou o menor MSLE entre os avaliados foi escolhido:

Além do MSLE, utilizou-se parâmetros SHAP (*Shapley Additive Explanations*) para

Tabela 8: Distribuição de algoritmos por parâmetro.

Parâmetro	Algoritmo
R_1, R'_2, R''_2	<i>XGBoost</i>
X_1, X'_2	<i>CatBoost</i>
X_m, X''_2	<i>Random Forest</i>

interpretabilidade das contribuições das variáveis, confirmando a coerência física das previsões com os princípios eletromagnéticos estabelecidos.

5.2.2 Engenharia de Atributos e Pré-processamento

A significativa redução para cinco variáveis de entrada (I_n, P_n, N, V_n, T_n) em comparação com métodos tradicionais [6] foi possibilitada por técnicas avançadas de engenharia de atributos. Para cada parâmetro de saída, aplicaram-se transformações específicas baseadas em avaliação empírica do impacto no MSE:

- **Transformação Recíproca:** Aplicada conforme $f(x) = \frac{1}{x}$ para parâmetros resistivos (R_1, R'_2, R''_2);
- **Transformação Avançada:** Combinação de atributos baseados em interações entre variáveis e termos polinomiais de segunda ordem;
- **Expansão Polinomial:** Inserção de termos quadráticos através de *PolynomialFeatures*.

A interação entre as variáveis de entrada foi feita a partir do uso da função *PolynomialFeatures* da biblioteca *sklearn.preprocessing*, com o parâmetro *interaction_only = True*. Para a expansão polinomial, utilizou-se *PolynomialFeatures* (*degree=2, include_bias=False*).

5.2.3 Desempenho dos Modelos em Diferentes Motores

Para validação dos modelos, selecionaram-se quatro motores representativos (M6 a M9) abrangendo a faixa de 7,5 a 90 kW. Os dados destes motores são apresentados na Tabela 9.

Os resultados detalhados para cada motor demonstram a eficácia da abordagem proposta:

A análise consolidada revela que para os parâmetros R_1, X_1, X'_2 e R''_2 , todos os erros absolutos permaneceram abaixo de 0,5%. Para R'_2 e X''_2 , os erros absolutos mantiveram-se abaixo de 2,5%, enquanto o maior erro observado foi associado ao parâmetro X_m no motor M6 (11,035%).

Tabela 9: Dados dos motores utilizados para validação dos modelos baseados em árvores de decisão.

ID	V_n [V]	f_n [Hz]	P [kW]	I_n [A]	T_n [Nm]	N [rpm]	I_s/I_n	T_s/T_n	T_b/T_n	$FP_{100\%}$
M6	460	60	7,5	12,4	40	1770	9,6	2,7	4,2	0,83
M7	460	60	15	26	122	1178	6,8	2,5	3	0,79
M8	460	60	22	37,5	178	1180	6,3	2,6	2,8	0,79
M9	460	60	90	142	721	1192	7,7	2,7	3	0,84

Tabela 10: Resultados para o Motor M6 (7,5 kW).

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	1,43137	0,50340	36,23425	0,81338	0,44544	0,50340	4,53337
Estimado	1,42949	0,50340	32,23576	0,81339	0,44561	0,50929	4,53324
Dif. (%)	0,131	0,000	11,035	0,002	0,038	1,170	0,003

Figura 6 compara as curvas de torque eletromagnético obtidas para os MITs M6 a M9, utilizando os parâmetros de circuito estimados utilizando o método de Newton Modificado e a metodologia proposta, respectivamente. Apesar de pequenas diferenças observáveis entre as curvas de torque de referência e estimada, essas variações são mínimas, destacando a confiabilidade e acurácia da abordagem desenvolvida.

Tabela 11: Resultados para o Motor M7 (15 kW).

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	0,50993	0,62757	17,89279	1,75193	0,28392	0,62757	0,86152
Estimado	0,51314	0,62757	17,01062	1,75190	0,28316	0,61457	0,86156
Dif. (%)	0,629	0,000	4,930	0,002	0,268	2,071	0,005

Tabela 12: Resultados para o Motor M8 (22 kW).

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	0,29283	0,45067	12,97244	1,16053	0,15801	0,45067	0,89339
Estimado	0,29293	0,45067	12,53155	1,16052	0,15810	0,44432	0,89346
Dif. (%)	0,033	0,000	3,399	0,001	0,057	1,408	0,008




Figura 6: Curvas de torque eletromagnético para os parâmetros de gaiola-dupla estimados, usando o método de Newton Modificado e a abordagem proposta para: a) M6; b) M7; c) M8; d) M9.

5.2.4 Análise Comparativa entre RNA e Algoritmos Baseados em Árvores de Decisão

Para determinar a melhor abordagem para o desafio proposto, compararam-se os resultados obtidos por ambas as soluções nas mesmas condições de teste. Foram selecionados

Tabela 13: Resultados para o Motor M9 (90 kW).

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Real	0,07327	0,09580	3,99441	0,23150	0,01469	0,09580	0,18374
Estimado	0,07352	0,09580	3,95218	0,23146	0,01496	0,09366	0,18486
Dif. (%)	0,351	0,000	1,057	0,020	1,840	2,229	0,608

quatro motores (M10 a M13) para análise comparativa, conforme apresentado na Tabela 14.

Tabela 14: Motores utilizados para análise comparativa entre RNAs e algoritmos baseados em árvores de decisão.

ID	V_n [V]	f_n [Hz]	P [kW]	I_n [A]	T_n [Nm]	N [rpm]	I_s/I_n	T_s/T_n	T_b/T_n	$FP_{100\%}$
M10	220	60	55	173	147,6881	3565	8,5	2,6	3,6	0,89
M11	220	60	0,12	0,891	0,6865	1720	4,5	3	3,2	0,62
M12	220	60	37	125	296,2589	1185	7	2,7	2,8	0,83
M13	220	60	1,5	7,21	12,2583	1150	5,8	2,4	2,8	0,7

A Tabela 15 apresenta os valores de referência dos parâmetros para os motores M10 a M13, obtidos através do método de Newton Modificado.

Tabela 15: Resultados de referência para todos os motores analisados na comparação.

ID	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
M10	0,0333	0,0268	1,7993	0,0594	0,0080	0,0268	0,1084
M11	24,4178	7,5899	142,9629	7,7610	23,2654	7,5899	23,3524
M12	0,0492	0,0539	2,0761	0,1537	0,0161	0,0539	0,1014
M13	2,3797	0,7615	20,2183	0,7630	1,9468	0,7615	1,9690

A análise comparativa (Figura 7) revela que as estimações utilizando as RNAs apresentaram o maior erro de estimação no caso do parâmetro X'_2 do M10, com um erro percentual de 170%, e menor erro observável na estimação de R_1 para M12, com um erro absoluto relativo de 10,56%.

No caso dos modelos baseados em DTAs, o maior erro foi observado no parâmetro R'_2 do M12, com um erro absoluto relativo de 168%, enquanto os erros mínimos ficaram abaixo de 1% para diversos parâmetros do MIT. Esses resultados indicam uma performance significativamente superior em comparação com os modelos de RNAs.

A superioridade dos algoritmos baseados em DTAs na determinação de parâmetros do modelo de gaiola-dupla do MIT pode ser atribuída ao fato de que, na última década, métodos tradicionais de aprendizado de máquina, particularmente os que utilizam *Gradient Boosting*, têm consistentemente apresentaram resultados mais eficazes do que as RNAs em tarefas que envolvem dados tabulares [10].




Figura 7: Parâmetros do modelo de gaiola-dupla em p.u. obtidos por meio do Método de Newton Modificado (MNM), Redes Neurais Artificiais (ANNs) e algoritmos baseados em árvores de decisão (DTAs) para os motores: (a) M10, (b) M11, (c) M12 e (d) M13.

5.2.5 Análise de Robustez a Variações na Entrada

Para avaliar a eficiência do método proposto em cenários práticos, onde os dados do MIT fornecidos pelo fabricante podem apresentar desvios estatísticos, examinou-se como ambas as abordagens - o método de Newton Modificado [6] e o método desenvolvido com base em algoritmos de árvores de decisão respondem a variações nos parâmetros de entrada, em específico a tensão V_n e a corrente I_n . Os testes foram conduzidos considerando variações de $\pm 1\%$, $\pm 3\%$ e $\pm 5\%$ para essas variáveis em diferentes MITs.

Como ilustrado na Figura 8, o método convencional [6] apresenta diferenças significativas nos parâmetros estimados para o circuito, dependendo das variações nos valores de V_n e I_n . Para variações em V_n , o erro relativo absoluto foi de 44% para o parâmetro R_1 utilizando o método convencional, enquanto o método proposto apresentou um erro relativo de 4% para o mesmo parâmetro. Em relação às variações em I_n , o método convencional obteve um erro absoluto de 414% para X'_2 , enquanto a abordagem proposta apresentou um erro de aproximadamente 0%.

As estimativas dos modelos propostos mantiveram respostas consistentes com a refe-




Figura 8: Respostas a variações de V_n e I_n para o motor M6 - (a) e (b) método de Newton Modificado [6], (c) e (d) respostas obtidas pelos modelos propostos.

rência, mesmo com variações nos dados de entrada. Vale destacar que esses resultados foram obtidos utilizando apenas 5 entradas, ressaltando a aplicabilidade da solução proposta em cenários práticos. O método proposto em [6], apesar de utilizar um maior número de entradas, não conseguiu um comportamento consistente quando comparado à referência associada aos valores nominais de entrada.

5.2.6 Discussão Consolidada dos Resultados

Com base nos resultados apresentados nas seções 5.1 e 5.2, nota-se que as características intrínsecas aos algoritmos baseados em árvores de decisão contribuíram diretamente na obtenção de melhores resultados, permitindo interpretações assertivas quanto aos atributos elétricos dos motores trifásicos.

A análise comparativa demonstra claramente a superioridade dos DTAs, com erros significativamente inferiores aos obtidos com RNAs. Esta vantagem é particularmente evidente na análise de robustez, onde os modelos baseados em árvores mantiveram con-

sistência mesmo com variações de até $\pm 5\%$ nos dados de entrada.

O dataset relativamente pequeno pode ter influenciado a performance das RNAs, que geralmente exigem maiores volumes de dados para otimizar seus resultados. Por outro lado, os DTAs se destacam na estimação dos parâmetros, dado o tamanho e as características do dataset, o que reforça sua aplicabilidade em cenários reais.

Os efeitos do tamanho do dataset são evidentes nos resultados dos motores M10 e M12, onde os parâmetros R_1 , X_m , R'_2 e R''_2 ficaram mais próximos dos valores de referência. Estes motores estão entre os mais predominantes no dataset de 860 registrados, representando aproximadamente 31,5% do total. Por outro lado, os resultados para M11 mostram a maior discrepância, o que está diretamente relacionado à baixa representação de motores com potências inferiores a 1 kW no dataset utilizado (apenas 11,5%).

Apesar das limitações do dataset, os modelos baseados em DTAs se destacaram por sua capacidade de capturar efetivamente os padrões entre as variáveis de entradas e saídas. A seleção cuidadosa de cada modelo baseou-se na sua aptidão para lidar com desafios comuns dos algoritmos baseados em árvores de decisão, como o overfitting.

Trabalhos futuros podem explorar novas abordagens de machine learning, técnicas alternativas para otimização de hiperparâmetros, métodos para mitigar overfitting e técnicas de ensemble learning (como stacking), que podem levar a um desempenho ainda melhor. Também podem ser realizados testes com novas arquiteturas de RNAs, como redes mais profundas, com camadas distintas, que podem oferecer melhorias na precisão das estimativas, especialmente com a expansão do dataset para incluir mais motores e uma diversidade maior de faixas de potência.

5.3 Validação Experimental

Para validar a eficácia da metodologia proposta na estimação dos parâmetros internos do modelo de gaiola-dupla em um motor real, foram realizados testes experimentais em bancada. Esta etapa é fundamental para verificar a aplicabilidade prática dos modelos desenvolvidos e sua capacidade de representar adequadamente o comportamento dinâmico de motores de indução trifásicos considerando condições reais de operação.

5.3.1 Configuração Experimental e Metodologia

Os experimentos foram conduzidos utilizando um motor de indução trifásico com as seguintes características de placa:

- **Potência nominal:** 0,37 kW (0,5 CV);
- **Velocidade nominal:** 1780 RPM;
- **Conexões:** Delta (Δ) e Estrela (Y);

- **Tensões de linha:** 220/380 V;
- **Correntes de linha:** 2,08/1,20 A;
- **Frequência nominal:** 60 Hz.

Para a execução dos testes em bancada, o motor foi conectado em configuração delta a um circuito de alimentação trifásico balanceado, com controle manual implementado em painel separado, estabelecendo a segurança operacional durante os ensaios.

5.3.2 Instrumentação e Aquisição de Dados

O sistema de aquisição de dados foi composto por instrumentos indicados na Figura 9:




Figura 9: Configuração experimental do banco de testes para aquisição de dados.

Os principais componentes do sistema de medição incluem:

- **Sensor de velocidade:** GMT-P1 com interface ModBus, configurado com taxa de transmissão de 9600 e tempo de resposta de 1 ms;
- **Medição de tensão:** Duas ponteiros de tensão conectadas ao osciloscópio Tektronix DPO3014;
- **Medição de corrente:** Duas ponteiros de corrente, permitindo a determinação matemática das correntes de fase;
- **Sistema de carga:** Freio eletromagnético com capacidade de aplicar torque controlado.

5.3.3 Procedimento Experimental

Os ensaios foram realizados seguindo protocolo padronizado, compreendendo as seguintes etapas:

1. **Caracterização inicial:** Verificação das condições do motor e dos instrumentos de medição;
2. **Carga específica:** Aplicação de torque constante de 0,5 Nm para análise comparativa;
3. **Aquisição contínua:** Registro temporal de todas as variáveis elétricas e mecânicas durante os transientes de partida e regime permanente.

A carga mecânica acoplada ao eixo foi modelada conforme a equação (28), considerando componentes de atrito viscoso e ventilação:

$$T_{load} = k\omega^2 + B\omega \quad (28)$$

onde:

- $k = 3,5854 \times 10^{-6}$ Nms²/rad² (coeficiente de ventilação);
- $B = 0,0058$ Nms/rad (coeficiente de atrito viscoso);
- ω : velocidade angular do rotor [rad/s].

Os parâmetros mecânicos do conjunto motor-carga foram determinados experimentalmente:

- **Inércia total (J):** 0,00734 kg·m²;
- **Atrito viscoso (B):** 0,0058 Nms/rad.

5.4 Resultados Experimentais e Comparação com Simulações

5.4.1 Parâmetros Estimados para o Motor Experimental

Utilizou-se as informações nominais do motor em teste como entrada aos modelos obtidos mediante a proposta baseada em algoritmos de árvores de decisão para a estimação dos parâmetros do circuito equivalente, apresentados na Tabela 16 juntamente aos algoritmos otimizados para o caso em análise.

Tabela 16: Parâmetros estimados para o motor experimental de 0,37 kW.

Parâmetro	$R_1[\Omega]$	$X_1[\Omega]$	$X_m[\Omega]$	$X'_2[\Omega]$	$R'_2[\Omega]$	$X''_2[\Omega]$	$R''_2[\Omega]$
Valor	8,9184	2,7576	66,9134	2,8700	8,1348	2,7571	8,2330
Algoritmo	XGBoost	CatBoost	Random Forest	CatBoost	CatBoost	CatBoost	CatBoost

5.4.2 Análise Comparativa das Curvas Características

A validação experimental foi realizada através da comparação sistemática entre as curvas obtidas experimentalmente e aquelas geradas por simulação no MATLAB utilizando os parâmetros estimados pela metodologia proposta. A Figura 10 apresenta esta comparação para as principais variáveis de interesse.




Figura 10: Comparação entre curvas experimentais e de simulação para: (a) Velocidade angular, (b) Corrente do estator, (c) Potências ativa e reativa, (d) Fator de potência.

Análise da Velocidade Angular Conforme ilustrado na Figura 10a, o comportamento dinâmico durante a partida apresenta excelente concordância entre resultados experimentais e simulados. O tempo de aceleração foi de aproximadamente 0,33 s em ambos os casos, demonstrando que os parâmetros estimados capturam adequadamente as características dinâmicas do motor. Em regime permanente, os valores estabilizaram em 1779 RPM (experimental) e 1759 RPM (simulação), correspondendo a um erro absoluto de apenas 1,12%.

Análise da Corrente do Estator A Figura 10b evidencia a capacidade do modelo em reproduzir tanto o regime transitório quanto o permanente das correntes do estator.

Durante a partida, o pico de corrente eficaz medido experimentalmente foi de 9,36 A, enquanto a simulação indicou 9,33 A, resultando em erro de 0,32%. Em regime permanente, a corrente eficaz experimental foi de 1,79 A contra 1,85 A na simulação (erro de 3,3%). A forma de onda instantânea também apresenta concordância significativa, particularmente em regime estabelecido.

Análise das Potências Ativa e Reativa Conforme mostrado na Figura 10c, as potências ativa (P) e reativa (Q) durante a partida apresentam comportamentos similares entre experimento e simulação. O valor máximo de P no experimento foi de 3,36 kW, enquanto a simulação registrou 3,14 kW (discrepância de 6,5%). Para Q, os valores foram 2,82 kVAR (experimental) e 1,34 kVAR (simulação), correspondendo a uma diferença de 52% durante o transitório. Em regime permanente, os resultados para ambos convergem satisfatoriamente: P experimental = 320 W vs P simulado = 315 W (erro 1,6%), Q experimental = 627 VAR vs Q simulado = 630 VAR (erro 0,5%).

Análise do Fator de Potência A evolução temporal do fator de potência (Figura 10d) demonstra boa concordância qualitativa e quantitativa. Durante a partida, o FP experimental variou em torno de 0,86, enquanto a simulação apresentou oscilações próximas a 0,92 (diferença de 6,5%). Em regime permanente, ambos os casos estabilizaram em aproximadamente 0,44, indicando excelente concordância para a condição de operação nominal.

5.5 Discussão dos Resultados Experimentais

Os resultados apresentados validam a eficácia da metodologia proposta para estimação de parâmetros de motores de indução trifásicos. A concordância observada entre as curvas experimentais e simuladas atesta a capacidade dos modelos baseados em árvores de decisão em capturar adequadamente as características dinâmicas e de regime permanente dos MITs, confirmando a aplicabilidade da metodologia proposta mesmo em cenários não-ideais, o que realça sua robustez em contextos práticos.

5.5.1 Acurácia e Precisão das Estimativas

A análise quantitativa dos erros entre valores experimentais e simulados revela que a metodologia proposta apresenta um desempenho extremamente satisfatório para aplicações práticas.

Entre as grandezas que se destacam positivamente, tem-se a velocidade com erro de 1,12% em condições de regime permanente, por exemplo. Além disso, os valores de corrente apresentaram erros entre 0,32% e 3,3% a depender da condição operacional em análise. Por fim, a potência ativa avaliada apresentou erro de apenas 1,6% em regime

permanente e, além disso, o fator de potência obtido mostrou uma concordância excelente em regime permanente.

As discrepâncias observadas durante os transitórios, particularmente para a potência reativa, podem ser atribuídas a fenômenos não modelados, como a saturação magnética durante a partida e efeitos de histerese no circuito magnético.

5.5.2 Implicações Práticas e Aplicabilidade Industrial

A validação experimental indica a possibilidade de aplicação da metodologia proposta em cenários onde frequentemente há acesso limitado a informações completas dos fabricantes, como em indústrias com motores que operam há muitos anos. A capacidade de estimar parâmetros precisos utilizando apenas cinco variáveis de entrada (corrente nominal, potência nominal, velocidade nominal, tensão nominal e torque nominal) representa uma vantagem significativa em comparação com métodos tradicionais.

A robustez demonstrada frente a variações nos dados de entrada, conforme analisado na Seção 5.2.5, combinada com os resultados experimentais satisfatórios, posiciona a abordagem proposta como uma alternativa viável para diversas aplicações industriais.

Entre estas, tem-se a facilitação do diagnóstico de condições dos equipamentos e manutenção preditiva, mediante o monitoramento contínuo da degradação de parâmetros elétricos ao longo do tempo, que permite a detecção precoce de falhas. A capacidade de estimar parâmetros sem a necessidade de parada do equipamento representa um avanço significativo em relação às técnicas convencionais de análise de motores.

A avaliação precisa do desempenho energético em condições reais de operação permite identificar oportunidades de economia de energia e otimização de processos. A capacidade de estimar parâmetros sob diferentes condições de carga facilita a análise do ponto de máxima eficiência operacional.

E em processos de modernização de sistemas de acionamento, a caracterização precisa dos motores existentes permite o dimensionamento adequado de conversores de frequência e sistemas de controle associados.

Por fim, é válido ressaltar que a capacidade de verificar parâmetros de motores recém-adquiridos contra especificações de projeto constitui uma ferramenta valiosa à garantia de qualidade em processos de aquisição de equipamentos.

Vantagens da Abordagem Proposta A metodologia desenvolvida apresenta vantagens distintivas em relação às técnicas convencionais, como por exemplo, a redução de custos operacionais, uma vez que elimina-se a necessidade de paradas produtivas para ensaios laboratoriais, reduzindo significativamente os custos associados à manutenção preventiva e corretiva.

Outro ponto é que, a natureza computacional da solução permite sua aplicação em

larga escala em plantas industriais com múltiplos motores, sem exigir investimentos adicionais em termos de instrumentação.

A capacidade de operar com dados nominais normalmente disponíveis em placas de identificação dos motores torna a solução aplicável mesmo em situações onde a documentação técnica se encontra incompleta.

Além disso, comprovou-se, frente a variações nos dados de entrada confiabilidade operacional em condições reais, onde incertezas de medição e tolerâncias de fabricação precisam ser consideradas.

Por fim, destaca-se também, que a metodologia alinha-se perfeitamente com os princípios da quarta revolução industrial, permitindo a digitalização de ativos rotativos e sua integração em sistemas de produção, o que permite o monitoramento e controle a distância de tais equipamentos.

Destaca-se então a oferta de uma alternativa à necessidade de ensaios em vazio e rotor bloqueado, que frequentemente exigem desacoplamento mecânico e parada produtiva.

Além disso, sua implementação permite a aplicação em larga escala com custo marginal reduzido. Um atributo particularmente vantajoso para plantas com centenas ou milhares de motores. A natureza computacional da solução facilita sua integração nativa com plataformas de Indústria 4.0, permitindo a incorporação em sistemas de gestão de ativos empresariais e de manutenção baseada em condição.

A combinação entre precisão técnica, viabilidade econômica e aplicabilidade prática estabelece a metodologia proposta como uma possível ferramenta para a indústria moderna, contribuindo para o aumento da confiabilidade, eficiência energética e competitividade dos processos industriais mediante a integração de ferramentas da Engenharia Elétrica e Inteligência Artificial.

5.5.3 Limitações e Considerações

Embora os resultados sejam promissores, algumas limitações devem ser consideradas:

- A validação experimental foi realizada para um motor de baixa potência (0,37 kW), sendo necessária verificação da aplicabilidade em motores de maior potência. Para isso, é preciso a construção de um banco de dados mais abrangente e numeroso, fornecendo ao modelo condições suficientes para captação das relações não-lineares presentes;
- Os testes foram conduzidos em condições controladas de laboratório, sabe-se que, em contextos industriais, inúmeros fatores podem apresentar novos desafios à solução desenvolvida;
- O banco de dados foi construído com informações considerando apenas parâmetros em regime permanente. Sabe-se que, em situações transitórias, os parâmetros e suas

propriedades elétricas podem apresentar variações, no entanto, estas não são investigadas no presente trabalho, cabendo portanto, uma investigação mais aprofundada em etapas subsequentes;

- Uma vez que a abordagem elaborada foi desenvolvida a partir dos trabalhos [5] e [6] que concluem que uma melhor performance é obtida a partir da representação dos motores com base no modelo de gaiola-dupla, não há informações que permitem a estimação dos parâmetros considerando o modelo de gaiola-simples, por exemplo.

Estas limitações representam oportunidades para trabalhos futuros, incluindo a expansão da validação experimental para diferentes faixas de potência e condições operacionais variadas.

6 Conclusão

Este trabalho apresentou uma investigação abrangente sobre a estimação de parâmetros do circuito equivalente de motores de indução trifásicos (MITs) de gaiola-dupla utilizando técnicas de Aprendizado de Máquina. A trajetória metodológica evoluiu desde a aplicação inicial de Redes Neurais Artificiais (RNAs) até uma análise comparativa robusta que incorporou algoritmos baseados em árvores de decisão, culminando na validação experimental em bancada com motor real.

6.1 Síntese dos Principais Resultados

Os resultados obtidos demonstraram claramente a superioridade dos algoritmos baseados em árvores de decisão (*Random Forest*, *XGBoost* e *CatBoost*) em comparação com as RNAs para esta aplicação específica. Enquanto as RNAs apresentaram erros percentuais que frequentemente ultrapassaram 100% para parâmetros como R'_2 e X'_2 , os modelos baseados em DTAs alcançaram erros consistentemente inferiores a 2% para a maioria dos parâmetros em motores das faixas de potência melhor representadas no *dataset*.

A análise de robustez revelou que a abordagem proposta mantém consistência mesmo com variações de até $\pm 5\%$ nos dados de entrada, contrastando fortemente com a sensibilidade do Método de Newton Modificado às mesmas variações. Esta característica é particularmente valiosa para aplicações práticas, onde incertezas de medição e tolerâncias de fabricação são inevitáveis.

A validação experimental em motor de 0,37 kW confirmou a eficácia da metodologia, com excelente concordância entre curvas experimentais e simuladas:

- Velocidade angular: erro de 1,12% em regime permanente
- Corrente do estator: erro de 0,32%-3,3% dependendo da condição operacional
- Potência ativa: erro de 1,6% em regime permanente
- Fator de potência: concordância excelente em regime permanente

6.2 Limitações e Trabalhos Futuros

Embora os resultados sejam promissores, algumas limitações devem ser reconhecidas:

A validação experimental foi realizada para um motor de baixa potência (0,37 kW), sendo necessária verificação para motores de maior potência. Adicionalmente, o desempenho inferior das RNAs sugere que arquiteturas mais avançadas ou volumes de dados expandidos podem ser necessários para explorar todo o potencial desses modelos.

Perspectivas para trabalhos futuros incluem a expansão do banco de dados, ou seja, a inclusão de mais motores de baixa potência (< 1 kW) e de altíssima potência (> 300 kW).

para melhor balanceamento das informações de entrada. Além disso, a investigação de novas arquiteturas de *deep learning* que possam maximizar os resultados e a capacidade de generalização dos modelos.

Também entende-se que é válida a condução de testes com motores operando com conversores de frequência e sob diferentes condições de desbalanceamento.

E por fim, é possível estender os estudos para a evolução dos parâmetros ao longo da vida útil do motor, uma vez que estes podem sofrer variações em decorrência de fenômenos físicos aos quais os motores estão constantemente submetidos

REFERÊNCIAS

- [1] **BOSE, B. K.** *Modern power electronics and AC drives*. Upper Saddle River: Prentice Hall PTR, 2002.
- [2] **MOHAN, N.; UNDELAND, T. M.; ROBBINS, W. P.** *Power electronics: converters, applications, and design*. 2. ed. New York: Wiley, 1995.
- [3] **SEN, P. C.** *Principles of electric machines and power electronics*. 3. ed. Hoboken: John Wiley & Sons, 2013.
- [4] **SILVEIRA, G.** *Estimação de parâmetros de modelos de gaiola simples, dupla e tripla de máquinas de indução a partir de dados de catálogos*. 2022. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2022.
- [5] **PEDRA, J.; CORCOLES, F.** *Estimation of induction motor double-cage model parameters from manufacturer data*. IEEE Transactions on Energy Conversion, v. 19, n. 2, p. 310–317, 2004.
- [6] **PEDRA, J.** *On the determination of induction motor parameters from manufacturer data for electromagnetic transient programs*. IEEE Transactions on Power Systems, v. 23, n. 4, p. 1709–1718, 2008.
- [7] **OLIVEIRA, E. F. R.** *Relatório parcial de iniciação científica: determinação dos parâmetros de motor de indução trifásico por meio de redes neurais artificiais*. Relatório técnico. Sorocaba: UNESP, 2023.
- [8] **BISHOP, C. M.** *Pattern recognition and machine learning*. New York: Springer, 2006.
- [9] **OLIVEIRA, E. F. R.** *Relatório final de iniciação científica: determinação dos parâmetros de motor de indução trifásico por meio de redes neurais artificiais*. Relatório técnico. Sorocaba: UNESP, 2024.
- [10] **SHWARTZ-ZIV, R.; ARMON, A.** *Tabular data: deep learning is not all you need*. Information Fusion, v. 81, p. 84–90, 2021.
- [11] **NATARAJAN, R.; MISRA, V. K.** *Parameter estimation of induction motors using a spreadsheet program on a personal computer*. Electric Power Systems Research, v. 16, n. 2, p. 157–164, 1989.
- [12] **BREIMAN, L. et al.** *Classification and regression trees*. Belmont: Wadsworth, 1984.

- [13] **QUINLAN, J. R. Induction of decision trees.** Machine Learning, v. 1, n. 1, p. 81–106, 1986.
- [14] **MIENYE, I. D.; JERE, N. A survey of decision trees: concepts, algorithms, and applications.** IEEE Access, v. 12, p. 12345-12367, 2024.
- [15] **SAGI, O.; ROKACH, L. Explainable decision forest: Transforming a decision forest into an interpretable tree.** Information Fusion, v. 61, p. 124-138, set. 2020. DOI: 10.1016/j.inffus.2020.03.013. Disponível em: <https://doi.org/10.1016/j.inffus.2020.03.013>. Acesso em: 15 out. 2024.
- [16] **BREIMAN, L. Random forests.** Machine Learning, v. 45, n. 1, p. 5–32, 2001.
- [17] **FRIEDMAN, J. H. Greedy function approximation: a gradient boosting machine.** Annals of Statistics, v. 29, n. 5, p. 1189–1232, 2001.
- [18] **MURPHY, K. P. Machine learning: a probabilistic perspective.** Cambridge: MIT Press, 2012.
- [19] **CHEN, T.; GUESTRIN, C. XGBoost: a scalable tree boosting system.** In: PROCEEDINGS OF THE 22ND ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING. San Francisco, 2016. p. 785–794.
- [20] **PROKHORENKOVA, L. et al. CatBoost: unbiased boosting with categorical features.** 2019. Disponível em: <https://arxiv.org/abs/1706.09516>. Acesso em: 15 out. 2024.
- [21] **ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain.** Psychological Review, v. 65, n. 6, p. 386–408, 1958.
- [22] **RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors.** Nature, v. 323, p. 533–536, 1986.
- [23] **GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning.** Cambridge: MIT Press, 2016.
- [24] **HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators.** Neural Networks, v. 2, n. 5, p. 359–366, 1991.

- [25] **MONTGOMERY, R. M. A Comparative Analysis of Decision Trees, Neural Networks, and Bayesian Networks: Methodological Insights and Practical Applications in Machine Learning.** 2024. DOI: 10.20944/preprints202410.1491.v1. Disponível em: <https://doi.org/10.20944/preprints202410.1491.v1>. Acesso em: 15 out. 2024.
- [26] **BERGSTRA, J. et al. Algorithms for hyper-parameter optimization.** In: **ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 24 (NIPS 2011).** [S.l.]: Curran Associates, Inc., 2011. Disponível em: <https://proceedings.neurips.cc>. Acesso em: 15 out. 2024.
- [27] **AKIBA, T. et al. Optuna: a hyperparameter optimization framework.** 2023. Disponível em: <https://optuna.org>. Acesso em: 15 out. 2024.
- [28] **KLAMBAUER, G. et al. Self-Normalizing Neural Networks.** arXiv:1706.02515, 2017. Disponível em: <https://arxiv.org/abs/1706.02515>. Acesso em: 15 out. 2024.
- [29] **OLIVEIRA, E. F. R.; SANTOS, R.; SIMÕES, M. G.; PAREDES, H. M. Estimation of the Double-Cage Model for Three-Phase Induction Machines Using Decision Tree-Based Algorithms.** IEEE Open Journal of the Industrial Electronics Society, v. 6, p. 915–926, 2025.
- [30] **PROKHORENKOVA, L. et al. CatBoost: unbiased boosting with categorical features.** 2025. Disponível em: <https://catboost.ai>. Acesso em: 15 out. 2024.