

ARTIGO DE PESQUISA/RESEARCH PAPER

# PRIMUS: um modelo convolucional para manutenção preditiva de motores indutivos

## PRIMUS: A convolutional model for predictive maintenance of induction motors

Anderson Vinicius Ribeiro [Universidade Federal do Amapá | [dev.anderson.vribeiro@gmail.com](mailto:dev.anderson.vribeiro@gmail.com) ]

Joelden Lopes [Universidade Federal do Amapá | [joelden.ap@gmail.com](mailto:joelden.ap@gmail.com) ]

Gilmar Paixão [Universidade Federal do Amapá | [gilmar.paixao@unifap.br](mailto:gilmar.paixao@unifap.br) ]

Cláudio Gomes [Universidade Federal de Pernambuco | [claudiorogério@unifap.br](mailto:claudiorogério@unifap.br) ]

✉ Bacharelado em Ciência da Computação, Universidade Federal do Amapá, Rodovia Josmar Chaves Pinto - KM 02, Macapá, AP, 68903-419, Brasil.

**Resumo.** Na Quarta Revolução Industrial, é crescente o emprego de tecnologias digitais para o monitoramento contínuo de equipamentos industriais, com o objetivo de antecipar falhas, prevenir paradas não programadas e aumentar a eficiência na execução de manutenções. Porém, os métodos tradicionais de monitoramento frequentemente se mostram insuficientes para evitar a ocorrência de falhas elétricas ou mecânicas, resultando em prejuízos financeiros e estratégicos significativos para grandes indústrias. Motores de indução trifásicos são de extrema importância em inúmeros processos industriais, sendo responsáveis pela conversão de energia elétrica em movimento mecânico em esteiras transportadoras, sistemas de ventilação, bombas e compressores. Sua robustez, simplicidade construtiva e baixo custo de manutenção consolidaram sua presença massiva no parque industrial global. Contudo, a operação contínua sob condições variáveis de carga e ambiente os torna suscetíveis a falhas progressivas, como desgaste de rolamentos, desalinhamento, desequilíbrio elétrico e curto-circuitos nos enrolamentos. A detecção precoce dessas anomalias é um desafio crítico para a garantia da confiabilidade operacional. Neste contexto, este trabalho apresenta o PRIMUS (*PRedictive maintenance for Induction Motors Using Sound*), um modelo baseado em uma Rede Neural Convolucional Profunda (CNN) projetado para manutenção preditiva em motores de indução industriais. O sistema é capaz de monitorar o funcionamento do equipamento em diferentes arquiteturas de partida e operação, especificamente nas ligações delta e estrela, configuradas tanto em série quanto em paralelo, utilizando exclusivamente sinais acústicos como fonte de diagnóstico. As gravações de áudio que compõem a base de dados foram realizadas em um formato circular tridimensional, com o microfone posicionado a uma distância constante de 15 centímetros do eixo do motor, garantindo padronização na captura dos sinais sonoros característicos de cada condição operacional. A principal contribuição desta pesquisa é o desenvolvimento de um método de monitoramento para motores de indução industriais que, em comparação com as técnicas tradicionais, não necessita de sensores intrusivos ou de múltiplas fontes de dados para seu funcionamento. O sistema proposto utiliza uma única fonte de informação, os sinais acústicos do motor, aliada a métodos avançados de aprendizagem profunda. Essa abordagem resulta em uma solução de baixo custo, tanto para implementação quanto para manutenção operacional, oferecendo uma alternativa prática e escalável para a manutenção preditiva na Indústria 4.0.

**Abstract.** In the Fourth Industrial Revolution, there is a growing use of digital technologies for the continuous monitoring of industrial equipment, aiming to anticipate failures, prevent unplanned shutdowns, and increase the efficiency of maintenance execution. However, traditional monitoring methods often prove insufficient to prevent the occurrence of electrical or mechanical failures, resulting in significant financial and strategic losses for large industries. Three-phase induction motors are extremely important in numerous industrial processes, being responsible for converting electrical energy into mechanical motion in conveyor belts, ventilation systems, pumps, and compressors. Their robustness, constructive simplicity, and low maintenance cost have consolidated their massive presence in the global industrial landscape. Nevertheless, continuous operation under variable load and environmental conditions makes them susceptible to progressive failures, such as bearing wear, misalignment, electrical imbalance, and winding short-circuits. The early detection of these anomalies is a critical challenge for ensuring operational reliability. In this context, this work presents PRIMUS (*PRedictive maintenance for Induction Motors Using Sound*), a model based on a Deep Convolutional Neural Network (CNN) designed for predictive maintenance in industrial induction motors. The system is capable of monitoring the equipment's operation in different starting and operating architectures, specifically in delta and star connections, configured in both series and parallel, using exclusively acoustic signals as a diagnostic source. The audio recordings that compose the database were performed in a three-dimensional circular format, with the microphone positioned at a constant distance of 15 centimeters from the motor shaft, ensuring standardization in the capture of characteristic sound signals for each operational condition. The main contribution of this research is the development of a monitoring method for industrial induction motors that, compared to traditional techniques, does not require intrusive sensors or multiple data sources for its operation. The proposed system uses a single source of information, the motor's acoustic signals, combined with advanced deep machine learning methods. This approach results in a low-cost solution, both for implementation and operational maintenance, offering a practical and scalable alternative for predictive maintenance in Industry 4.0.

**Palavras-chave:** Aprendizado de máquina, Processamento de sinais, Motor industrial

**Keywords:** Machine learning, signal processing, industrial motor

# 1 Introdução

A Indústria 4.0, também conhecida como a Quarta Revolução Industrial é fundamentada na integração de tecnologias de internet com objetos inteligentes, como sensores, em maquinários industriais Lasi *et al.* [2014]. Nesse contexto, Quarta Revolução Industrial tem empregado técnicas de aprendizado de máquina para otimizar processos produtivos, aumentando a capacidade operacional e reduzindo custos. Parâmetros industriais críticos, como a qualidade do produto, condições térmicas, estado dos componentes e eficiência energética dos equipamentos, são frequentemente supervisionados por meio de métodos tradicionais, como a medição de vibração e temperatura. No entanto, esse monitoramento costuma gerar resultados limitados ou pouco eficazes, resultando em baixa eficiência operacional, manutenções corretivas não planejadas, redução da capacidade de produção e aumento do consumo energético Thirugnanam [2023].

As máquinas elétricas desempenham um papel fundamental nos processos produtivos industriais, atuando tanto como fontes de energia quanto como sistemas de acionamento para movimentação de cargas. Considerando a importância econômica desses equipamentos e a crescente competitividade do mercado, as indústrias buscam cada vez maior confiabilidade e disponibilidade operacional, visando minimizar interrupções não programadas nos processos produtivos e os custos associados a manutenções emergenciais Biot-Monterde *et al.* [2022].

Nesse contexto, diversos modelos analíticos têm sido desenvolvidos para avaliar o estado de máquinas industriais por meio de variáveis físicas mensuráveis, estabelecendo correlações para diferentes aplicações. Porém, as abordagens baseadas em aprendizado de máquina demonstram superioridade na análise de padrões complexos e não lineares, apresentando maior eficácia em tarefas de previsão, identificação de anomalias e classificação de estados operacionais quando comparadas a modelos puramente físicos ou estatísticos tradicionais Aggogeri *et al.* [2021]; Merizalde *et al.* [2017]; Sheikh *et al.* [2022]. Dessa forma, os sistemas baseados em aprendizado de máquina podem oferecer soluções robustas e adaptáveis, já que são capazes de aprender com dados históricos e se ajustar a diferentes cenários operacionais.

Partindo da premissa de que os motores de indução são amplamente utilizados na indústria devido à sua robustez e confiabilidade, é de conhecimento que esses equipamentos estão sujeitos a falhas tanto de natureza elétrica quanto mecânica, podendo comprometer significativamente sua operação e disponibilidade Borré *et al.* [2023]. Nesse cenário, a análise acústica surge como uma abordagem promissora para o desenvolvimento de sistemas de diagnóstico, apresentando vantagens comparativas em relação às técnicas tradicionais baseadas em medições de corrente elétrica ou vibração. Esse sistema é mais econômico por utilizar hardwares mais acessíveis, diferente do tradicional que necessita de equipamentos mais sofisticados. Além de ser capaz de detectar falhas específicas, através das técnicas de inteligência artificial, como curto circuito e desbalanceamento Abdo *et al.* [2020].

Este trabalho apresenta o **PRIMUS** (*PRedictive maintenance for Induction Motors Using Sound*), um modelo baseado em Redes Neurais Convolucionais (CNN) para manuten-

ção preditiva em motores de indução trifásicos. O sistema foi desenvolvido para diagnosticar condições operacionais em configurações estrela e delta, tanto em ligações série quanto paralela, utilizando exclusivamente dados acústicos. Para a construção do conjunto de dados, realizaram-se gravações de áudio em formato circular tridimensional em motores operando em faixas de rotação entre 1500 e 1650 RPM.

Este artigo está organizado da seguinte forma: A seção 2 apresenta uma revisão de trabalhos semelhantes. A seção 3 descreve a coleta dos dados, extração de características e modelo de aprendizado de máquina utilizado. Os resultados obtidos são discutidos na seção 4 e A seção 5 trata das conclusões.

# 2 Trabalhos relacionados

Esta seção apresenta uma revisão dos trabalhos que embasam a proposta, abordando desde técnicas clássicas de partida e diagnóstico até as abordagens mais modernas baseadas em aprendizado de máquina e sensoriamento avançado.

O trabalho de Hardine *et al.* [2022] analisa o impacto do sistema de partida estrela-triângulo na atenuação do pico de corrente durante a partida de motores de indução trifásicos. O problema central abordado é o elevado surto de corrente inicial (*inrush current*), que pode causar danos térmicos e mecânicos aos enrolamentos do motor, comprometendo sua vida útil. O sistema inicia na configuração estrela, que possui apenas um terço (1/3) da potência máxima do motor. Após um intervalo controlado por um temporizador, a conexão é alterada para a configuração triângulo, permitindo que o motor opere com tensão plena e torque nominal. Essa transição suave reduz não apenas o pico de corrente, mas também o torque de partida, minimizando impactos mecânicos e elétricos no sistema.

Os autores de Thorsen and Dalva [2002] revisam e analisam diversas técnicas de detecção de falhas, incluindo métodos mecânicos (análise de vibrações, pulsos de choque, acústica e flutuações de velocidade), eletromecânicos (análise de correntes, surtos, descargas parciais e fluxos de fuga), além de monitoramento térmico, análise de partículas em óleo e gases, e métodos visuais e de desempenho. Os autores demonstram que diferentes tipos de falhas geram componentes de frequência específicos nos espectros de vibração, corrente elétrica, torque e campo magnético, permitindo a identificação precisa de problemas como barras quebradas no rotor e falhas em mancais por meio da análise da forma de onda da corrente. Ao final, enfatizam a importância de uma abordagem multifacetada para o diagnóstico, combinando dados elétricos, mecânicos e químicos, e sugerem que avanços futuros devem focar na integração de técnicas para aumentar a confiabilidade e a segurança operacional desses equipamentos críticos.

O trabalho de Abdo *et al.* [2020] investigou métodos de detecção de falhas elétricas em motores de indução trifásicos utilizando análise acústica. Os autores propuseram que sinais acústicos captados durante o funcionamento do motor podem ser analisados para identificar padrões associados a diferentes tipos de falhas, como curto-circuito nas bobinas ou desequilíbrio de fases. A coleta dos sinais de áudio foi realizada com o microfone interno de um iPhone X, posicionado a uma distância constante do eixo do motor. Foram

coletados 40 trechos de áudio de 4 segundos com e sem ruído, sendo 20 referentes a um motor saudável em operação e outros 20 a um motor com uma falha simulada por meio do desligamento de uma das fases. Como características para análise, utilizaram o *Root Mean Square (RMS)* no domínio do tempo e a potência média do espectro obtido pela Transformada Rápida de Fourier (*FFT*) no domínio da frequência. Para validação estatística dos resultados, os autores aplicaram o teste de hipótese *t de Student (t-Test)*. O estudo demonstrou que a análise acústica apresenta boa eficiência para distinguir entre condições saudáveis e com falha elétrica com precisão, mesmo em ambientes ruidosos.

Tran *et al.* [2021] propõem uma abordagem para o diagnóstico de falhas em motores de indução, combinando a transformada *wavelet* para extração de características com uma rede neural convolucional dotada de um mecanismo de atenção. Essa combinação permite capturar informações temporais e frequenciais dos sinais de vibração e corrente do motor, aprimorando a sensibilidade e a precisão na identificação de falhas, como defeitos em rolamentos, rotor e estator. A integração da análise *wavelet* com a rede convolucional de atenção possibilita um diagnóstico mais precoce e confiável, essencial para manutenção preditiva e redução de paradas não planejadas em ambientes industriais. No entanto, o uso da transformada *wavelet* é extremamente sensível a ruídos, exigindo um pré-processamento especializado para que o modelo de rede neural convolucional possa efetivamente realizar o diagnóstico específico de falhas.

A abordagem de Tran *et al.* [2023] implementa um sistema de reconhecimento e correção de falhas em motores de indução, integrando conceitos da Internet das Coisas (IoT) com técnicas de aprendizagem profunda. Sensores instalados no motor coletam dados de vibração do equipamento, armazenados no formato de séries temporais. O modelo de inteligência artificial empregado é uma CNN com camada de entrada unidimensional (1D), apropriada para processar sequências de dados. O principal diferencial do sistema proposto é um esquema de verificação de integridade projetado para detectar possíveis injeções de dados falsos (*false data injection*) que poderiam manipular o diagnóstico. Essa verificação é realizada pela comparação dos dados de entrada com padrões conhecidos de sinais de falha e operação normal. Caso o resultado esteja fora do padrão esperado, o sistema executa técnicas de reconstrução de dados para corrigir a anomalia antes de emitir um alerta ao operador. Este modelo foi capaz de detectar falhas com alta precisão e assertividade, alcançando acurácia acima de 99% tanto no caso de funcionamento real quanto no caso de injeção de dados. A infraestrutura de IoT é empregada para a comunicação e o monitoramento em larga escala dos motores, permitindo identificar pontualmente qual unidade apresenta uma possível falha ou possui os maiores índices de ineficiência operacional.

Em contraste com os métodos tradicionais e estatísticos de detecção de falhas, o PRIMUS introduz uma abordagem mais abrangente e sofisticada. O sistema não se limita à identificação de defeitos, mas é capaz de diagnosticar também a configuração operacional do motor (Delta/Estrela, Série/Paralelo). Para isso, emprega uma técnica inovadora de captura de sinais acústicos em um esquema tridimensional circular, que se demonstra mais eficaz na aquisição das nuan-

ces espaciais do som do motor do que métodos estáticos de gravação convencionais.

### 3 PRIMUS

O PRIMUS é um modelo de inteligência artificial baseado em redes neurais profundas desenvolvido para a identificação do estado operacional de motores de indução industriais, com foco nas configurações de ligação delta e estrela, tanto em arranjos série quanto paralelo. O sistema tem como finalidade diagnosticar a condição do motor, identificando a necessidade de manutenção preditiva ou atestando seu funcionamento dentro dos parâmetros ideais.

Inicialmente foi realizado a captação dos sinais acústicos, realizado em ambiente controlado. Em seguida a arquitetura da rede neural foi projetada e implementada. Por fim, o modelo foi submetido às etapas de aprendizagem de máquina de treinamento, validação para ajustes de hiperparâmetros e testes para avaliação em dados não conhecidos.

A coleta dos sinais de áudio foi realizada em laboratório de máquinas industriais, o que permitiu um controle preciso das variáveis operacionais e a simulação de diferentes condições de funcionamento nos equipamentos monitorados.

#### 3.1 Motores indutivos


Os motores de indução trifásicos representam uma das principais fontes de acionamento em ambientes industriais, devido à sua robustez, simplicidade construtiva, baixo custo de manutenção e elevada confiabilidade operacional. São amplamente utilizados em sistemas que demandam torque constante ou variável, como em compressores, bombas, ventiladores, transportadores e sistemas de automação em geral. Sua popularidade também se deve à compatibilidade com redes elétricas trifásicas e à capacidade de operar de forma eficiente sob diferentes condições de carga Chapman [2013].

No contexto de acionamento e partida desses motores, as configurações de ligação dos enrolamentos do estator, notadamente as conexões estrela e triângulo (*delta*), desempenham um papel fundamental no controle das variáveis elétricas durante a operação. A escolha da configuração adequada está diretamente relacionada à tensão de alimentação da rede e ao desempenho esperado do motor em regimes distintos, como partida e regime permanente.

Para garantir o funcionamento seguro e eficiente do motor, torna-se essencial o correto ajuste da ligação estrela ou triângulo conforme as características nominais do equipamento e as especificações da rede elétrica disponível. Por exemplo, motores com placas de identificação 220/380 V devem ser ligados em estrela em redes de 380 V e em triângulo para redes de 220 V. A aplicação incorreta dessas configurações pode resultar em problemas como subalimentação, sobrecorrente, perda de torque, aquecimento excessivo e até falha completa do equipamento.

A Figura 1 ilustra as configurações de ligação estrela e triângulo para os enrolamentos do estator de um motor de indução trifásico tanto na configuração em série quanto na paralela. A forma como esses enrolamentos estão conectados é crucial para o desempenho da máquina, afetando diretamente características como torque, tensão, corrente e eficiência.

As nomenclaturas dos terminais dos motores de indução



**Figura 1.** Configurações típicas de ligação (estrela e triângulo) para os enrolamentos do estator de um motor de indução trifásico.

trifásicos seguem convenções padronizadas. Em conformidade com normas como a NBR e a IEC, as designações mais comuns para os enrolamentos do estator são:

1. U1, V1, W1: inícios dos enrolamentos das fases A, B e C, respectivamente;
2. U2, V2, W2: finais dos enrolamentos das fases A, B e C, respectivamente.

Para realizar as ligações:

- **Ligação estrela (Y):** os terminais U2, V2 e W2 são interligados para formar o ponto neutro (comum), enquanto U1, V1 e W1 são conectados às fases da rede de alimentação.
- **Ligação triângulo ( $\Delta$ ):** os finais de um enrolamento são conectados ao início do próximo, ou seja: U2 com V1, V2 com W1 e W2 com U1. Os pontos de junção (U1, V1, W1) são então conectados às três fases da rede.

### 3.2 Coleta de sinais de áudio e extração de características

A aquisição de sinais acústicos tem como objetivo identificar, através de padrões sonoros característicos, diferentes condições de operação e falhas em motores de indução trifásicos, servindo como base para um sistema de monitoramento preditivo baseado em áudio.

Para a coleta dos sinais de áudio foi usado um microfone condensador pois ele possui alta sensibilidade, baixo ruído e consegue manter uma fidelidade sonora, que é o ideal para esse tipo de captação. A tabela 1 descreve as especificações do microfone utilizado.

**Tabela 1.** Especificações do sistema de aquisição acústica


| Parâmetro           | Especificação   |
|---------------------|-----------------|
| Modelo do microfone | Fifine A2       |
| Sensibilidade       | -40dB $\pm$ 2dB |
| Faixa de frequência | 60Hz - 18kHz    |
| Taxa de amostragem  | 44.1kHz         |
| Resolução           | 16 bits         |

Essa tarefa foi realizada movendo manualmente o microfone em uma trajetória circular em volta do motor, para

se obter uma gravação tridimensional do funcionamento do equipamento e conseguir capturar possíveis padrões sons de diferentes partes do motor. Cada gravação foi realizada com a duração de dez segundos em máquinas em pleno funcionamento, para simular um ambiente real de trabalho industrial.

Para a coleta dos sinais de áudio foi utilizado um microfone condensador devido à sua alta sensibilidade, baixo ruído intrínseco e capacidade de manter a fidelidade sonora, características ideais para esta aplicação. As gravações foram realizadas em ambiente industrial controlado com ruído de fundo inferior a 60 dB(A).

A estratégia de captação envolveu a movimentação do microfone em trajetória circular a uma distância fixa de aproximadamente 15 cm do eixo principal do motor, realizando uma volta completa durante os dez segundos de gravação. Este procedimento permitiu obter uma amostragem acústica tridimensional do funcionamento do equipamento, capturando padrões sonoros provenientes de diferentes partes do motor (estator, rotor, ventilação e mancais). Cada gravação foi realizada com as máquinas em pleno funcionamento nominal para simular condições reais de operação industrial.



**Figura 2.** Estratégia de gravação do sinal acústico.

A coleta dos sinais acústicos foi sistematicamente realizada para todas as combinações possíveis entre configurações de ligação e estados de funcionamento do motor. Foram considerados dois parâmetros de configuração elétrica: (1) a ligação do estator (estrela - Y ou triângulo -  $\Delta$ ) e (2) o tipo de conexão (série ou paralelo). Adicionalmente, foram avaliados dois estados operacionais: “ideal” (funcionamento pleno e correto) e “manutenção” (condição de falha simulada).

As oito combinações avaliadas estão demonstradas na Tabela 2:

Como ilustrado na Figura 2, para cada uma das oito configurações listadas na Tabela 2, foram captadas oito amostras independentes, totalizando 64 gravações na base de dados (8 configurações  $\times$  8 repetições).

Para transformar os sinais de áudio temporais em representações espectrais adequadas para análise e classificação, realizou-se a extração de mel espectrogramas utilizando a biblioteca librosa McFee *et al.* [2015]. O processo consistiu nas seguintes etapas:

**Tabela 2.** Configurações elétricas e estados operacionais testados para coleta de sinais acústicos.

| Ligação                | Conexão  | Estado     |
|------------------------|----------|------------|
| Triângulo ( $\Delta$ ) | Série    | Ideal      |
| Triângulo ( $\Delta$ ) | Série    | Manutenção |
| Triângulo ( $\Delta$ ) | Paralelo | Ideal      |
| Triângulo ( $\Delta$ ) | Paralelo | Manutenção |
| Estrela (Y)            | Série    | Ideal      |
| Estrela (Y)            | Série    | Manutenção |
| Estrela (Y)            | Paralelo | Ideal      |
| Estrela (Y)            | Paralelo | Manutenção |

1. **Transformada de Fourier de Curto Termo (STFT):** Aplicou-se a STFT com os seguintes parâmetros:

- **n\_fft:** 2048
- **win\_length:** 1728
- **hop\_length:** 656

2. **Conversão para escala Mel:** Os espectrogramas de magnitude foram convertidos para a escala Mel utilizando 224 bandas de frequência Mel, que mapeia a frequência linear para uma escala perceptual baseada na resposta do ouvido humano.

3. **Normalização:** O mel espectrograma resultante foi normalizado para o intervalo dinâmico de 0 a 512, conforme a equação.

O processo resultou em representações espectrais de dimensão  $224 \times 672$ , onde 224 corresponde ao número de bandas Mel e 672 ao número de frames temporais. Esta representação bidimensional captura tanto as características espectrais quanto temporais dos sinais de áudio, sendo adequada para análise através de redes neurais convolucionais.

### 3.3 Rede Neural Convolucional

As CNNs são uma classe de arquiteturas de aprendizagem profunda especialmente projetadas para processar dados com estrutura de matriz, como imagens. Sua eficácia deriva da utilização de camadas convolucionais que aplicam filtros locais para extrair características hierárquicas espaciais ou espectro-temporais, seguida de camadas de *pooling* que reduzem dimensionalidade mantendo informações essenciais Géron [2019].


A entrada do modelo proposto consiste nos espectrogramas extraídos com dimensões de 224 bandas Mel  $\times$  672 frames temporais.

A arquitetura detalhada da CNN é composta pelas seguintes camadas sequenciais:

1. **Camada de Entrada:** Tensor de dimensões  $224 \times 672 \times 1$  (escala de cinza)
2. **Camada Convolucional 1:** 256 filtros com kernel  $5 \times 5$ , *stride*  $2 \times 2$ , ativação ReLU
3. **Camada de MaxPooling 1:** *Pool size*  $2 \times 2$
4. **Camada Convolucional 2:** 256 filtros com kernel  $5 \times 5$ , ativação ReLU
5. **Camada de Dropout 1:** Taxa de 0.5
6. **Camada Convolucional 3:** 128 filtros com kernel  $5 \times 5$ , ativação ReLU
7. **Camada de MaxPooling 2:** *Pool size*  $2 \times 2$
8. **Camada Dense 1:** 128 neurônios, ativação ReLU

9. **Camada de Dropout 2:** Taxa de 0.3

10. **Camada Dense 2:** 8 neurônios, ativação *softmax* (saída)

**Figura 3.** Arquitetura detalhada do modelo PRIMUS para classificação de estados de motores a partir de espectrogramas Mel.

A arquitetura foi implementada utilizando a biblioteca TensorFlow Abadi *et al.* [2015] e otimizada através de um processo de seleção empírica que avaliou diferentes configurações de hiperparâmetros. A escolha dos parâmetros específicos resultou do compromisso entre capacidade de modelagem e prevenção de sobreajuste, considerando o tamanho limitado do conjunto de dados.

Para o treinamento do modelo, o conjunto de dados foi dividido em dois subconjuntos: 50% para treinamento e 50% para teste. Durante o desenvolvimento, diversos otimizadores foram avaliados para maximizar a acurácia de classificação. A Tabela 3 apresenta os resultados comparativos dos principais otimizadores testados:

| Otimizador     | Acurácia      |
|----------------|---------------|
| Adam           | 80.25%        |
| Adamax         | 79.28%        |
| AdamW          | 76.27%        |
| FTRL           | 65.67%        |
| Nadam          | 69.31%        |
| <b>RMSprop</b> | <b>81.25%</b> |

**Tabela 3.** Desempenho comparativo de otimizadores no conjunto de validação para o modelo PRIMUS.


O otimizador *RMSprop* demonstrou superioridade com acurácia de 81.25%, atribuída à sua estabilidade em cenários com dados limitados e sensibilidade equilibrada a ruídos Tieleman and Hinton [2012]. Em contraste, otimizadores da família Adam (Adam, Adamax, AdamW, Nadam) apresentaram maior propensão a sobreajuste (*overfitting*) e oscilações durante o treinamento, possivelmente devido à adaptação excessiva de taxas de aprendizagem individuais em um conjunto de dados de tamanho moderado Wilson *et al.* [2017].

## 4 Resultados

A Figura 4 apresenta a matriz de confusão resultante da avaliação do modelo PRIMUS no conjunto de teste, utilizando o otimizador RMSprop, que obteve o melhor resultado durante a fase.

A análise da matriz de confusão revela que a maioria dos erros de classificação ocorre entre estados operacionais da mesma configuração elétrica mas com diferentes condições de funcionamento do motor. Observa-se que não há erros cruzados significativos entre diferentes configurações de ligação, indicando que o modelo aprendeu características distintivas robustas para estas classes. As principais confusões ocorrem entre condições “ideal” e “manutenção” dentro da mesma configuração elétrica. A melhor acurácia no conjunto de teste





**Figura 4.** Matriz de confusão do modelo PRIMUS no conjunto de teste. As classes correspondem às oito configurações operacionais dos motores.

foi de 81.25% com o otimizador *RMSprop*, indicando boa generalização do modelo.

## 5 Conclusão

Este trabalho apresentou o PRIMUS, um modelo de rede neural convolucional para identificação automática de falhas em motores de indução trifásicos com relação aos fechamentos delta e estrela nas configurações série e paralelo. A abordagem proposta demonstrou ser viável para classificação baseada em análise acústica, atingindo acurácia de 81.25% com o otimizador *RMSprop* no conjunto de teste.

Os resultados indicam que o modelo é particularmente eficaz na distinção entre diferentes configurações de ligação (estrela vs. triângulo) e tipos de conexão (série vs. paralelo), apresentando alta confiabilidade nestas categorizações. No entanto, observou-se maior desafio na discriminação entre condições “ideal” e “manutenção” dentro da mesma configuração elétrica, sugerindo que as assinaturas acústicas desses estados são mais sutis e requerem características mais refinadas para sua distinção precisa.

Como trabalhos futuros, ampliar o conjunto de dados implementando técnicas de aumento de dados (*data augmentation*) para espectrogramas, como variações de pitch, adição de ruído controlado e distorções temporais; incorporar mais variáveis experimentais que aproximem as condições de laboratório das encontradas em ambientes industriais reais; Investigar a combinação de múltiplas fontes de dados (acústica, corrente elétrica, vibração e temperatura) em abordagens multimodais, que podem proporcionar diagnósticos mais abrangentes; Estender a análise para outros tipos de falhas comuns em motores, como desalinhamento mecânico, danos em rolamentos, e desbalanceamento rotórico.

A arquitetura proposta demonstra potencial como componente fundamental para sistemas automatizados de monitoramento preditivo em ambientes industriais. A integração desta técnica a sistemas de gestão de manutenção pode contribuir significativamente para a redução de paradas não programadas, otimização de custos operacionais e aumento da vida útil dos equipamentos, representando um avanço em direção à Indústria 4.0 e manutenção baseada em condição.

## Declarações complementares

### Agradecimentos

Agradecemos ao Laboratório de Conversão e Máquinas Elétricas da UNIFAP pela disponibilidade e apoio na captação dos sinais sonoros utilizados neste projeto.

### Contribuições dos autores

Claudio Rogerio: Conceitualização, Supervisão, Metodologia, Validação. Anderson Ribeiro: Revisão Bibliográfica, Redação – Revisão e Edição. Joelden Lopes: Curadoria de Dados, Metodologia, Investigação, Revisão Bibliográfica, Redação – Rascunho original. Gilmar Paixão: Curadoria de Dados, Metodologia, Investigação, Revisão Bibliográfica, Redação – Rascunho original. Todos os autores leram e aprovaram o manuscrito final.

### Conflitos de interesse

Os autores declaram que não têm nenhum conflito de interesses

### Disponibilidade de dados e materiais

Os conjuntos de dados (e/ou softwares) gerados e/ou analisados durante o estudo atual serão feitos mediante solicitação

## Referências

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., Mané, D., Monga, R., Moore, S., Murray, D., Olah, C., Schuster, M., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viégas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y., and Zheng, X. (2015). TensorFlow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org.
- Abdo, A., Siam, J., Abdou, A., Mustafa, R., and Shehadeh, H. (2020). Electrical fault detection in three-phase induction motor based on acoustics. In *2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)*, pages 1–5. IEEE.
- Aggogeri, F., Pellegrini, N., and Tagliani, F. L. (2021). Recent advances on machine learning applications in machining processes. *Applied sciences*, 11(18):8764.
- Biot-Monterde, V., Navarro-Navarro, A., Zamudio-Ramirez, I., Antonino-Daviu, J. A., and Osornio-Rios, R. A. (2022). Automatic classification of rotor faults in soft-started induction motors, based on persistence spectrum and convolutional neural network applied to stray-flux signals. *Sensors*, 23(1):316.
- Borré, A., Seman, L. O., Camponogara, E., Stefenon, S. F., Mariani, V. C., and Coelho, L. d. S. (2023). Machine fault detection using a hybrid cnn-lstm attention-based model. *Sensors*, 23(9):4512.
- Chapman, S. J. (2013). *Fundamentos de máquinas elétricas*. AMGH editora.
- Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly, Sebastopol, 2 edition.
- Hardine, L., Santoso, D. B., and Hadikusuma, R. S. (2022). Analysis of the influence of star delta system in reduce elec-

- tric starting surge in 3 phase motors. *Electrician: Jurnal Rekayasa Dan Teknologi Elektro*, 16(2):208–214.
- Lasi, H., Fettke, P., Kemper, H.-G., Feld, T., and Hoffmann, M. (2014). Industry 4.0. *Business & information systems engineering*, 6(4):239–242.
- McFee, B., Raffel, C., Liang, D., Ellis, D. P., McVicar, M., Battenberg, E., and Nieto, O. (2015). librosa: Audio and music signal analysis in python. In *Proceedings of the 14th python in science conference*, volume 8.
- Merizalde, Y., Hernández-Callejo, L., and Duque-Perez, O. (2017). State of the art and trends in the monitoring, detection and diagnosis of failures in electric induction motors. *Energies*, 10(7):1056.
- Sheikh, M. A., Bakhsh, S. T., Irfan, M., Nor, N. b. M., and Nowakowski, G. (2022). A review to diagnose faults related to three-phase industrial induction motors. *Journal of Failure Analysis and prevention*, 22(4):1546–1557.
- Thirugnanam, P. (2023). Advances, new perspective and applications in induction motors. In *Induction Motors-Recent Advances, New Perspectives and Applications*. IntechOpen.
- Thorsen, O. V. and Dalva, M. (2002). Failure identification and analysis for high-voltage induction motors in the petrochemical industry. *IEEE transactions on industry applications*, 35(4):810–818.
- Tieleman, T. and Hinton, G. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural Networks for Machine Learning*, 4(2):26–31.
- Tran, M.-Q., Amer, M., Abdelaziz, A. Y., Dai, H.-J., Liu, M.-K., Elsis, M., et al. (2023). Robust fault recognition and correction scheme for induction motors using an effective iot with deep learning approach. *Measurement*, 207:112398.
- Tran, M.-Q., Liu, M.-K., Tran, Q.-V., and Nguyen, T.-K. (2021). Effective fault diagnosis based on wavelet and convolutional attention neural network for induction motors. *IEEE Transactions on Instrumentation and Measurement*, 71:1–13.
- Wilson, A. C., Roelofs, R., Stern, M., Srebro, N., and Recht, B. (2017). The marginal value of adaptive gradient methods in machine learning. *Advances in neural information processing systems*, 30.