

PRIMUS: um modelo CNN para manutenção Preditiva em motores indutores industriais

Gilmar Paixão¹, Cláudio Gomes^{1,2}

¹Grupo de pesquisa de COmputação mUsical e Tecnologias Emergentes
Ciências da Computação – Universidade Federal do Amapá (UNIFAP)

²Pós-graduação em Ciência da Computação – Universidade Federal de Pernambuco (UFPE)

{gilmar.paixao, claudiorogério}@unifap.br

Abstract. *The demand for monitoring industrial motors has progressively increased as a means to prevent failures, unplanned downtimes, and to improve maintenance efficiency. A lack of proper planning regarding these machines can exacerbate setbacks related to financial and strategic costs in various industrial sectors. This study introduces PRIMUS, a Convolutional Neural Network (CNN) based model for PRedictIve Maintenance of indUstrial induction motorS configured in delta and star connections, operating in both series and parallel modes. Audio recordings of the motors were collected under rotational speed variations ranging from 1500 to 1650 rpm. The motor's acoustic properties were analyzed using a three-dimensional circular recording setup, maintaining a fixed distance of 15 cm relative to the motor's main axis.*

Keywords — machine learning, signal processing, industrial motor

Resumo. *A demandas por monitoramento de motores industriais está progressivamente aumentando na busca de prevenir falhas, paradas não programadas e manutenções com maior efetividade. Assim, a falta de planejamento nessas máquinas pode agravar contratempos com relação a custos financeiros e estratégicos em diversos setores industriais. Este trabalho apresenta o PRIMUS, um modelo CNN para manutenção PReditIva em Motores indUtores industriais para fechamentos delta e estrela nos modos série e paralelo. Realizou-se gravações sonoras dos motores com variações de 1500 a 1650 rpm. Analisou-se a propriedade do motor com o modelo de gravação em formato circular tridimensional com distância constante de 15 cm relativa ao eixo principal do motor.*

Palavras-chave — aprendizado de máquina, signal processing, motor industrial

1. Introdução

A quarta revolução industrial tem utilizado o uso de aprendizado de máquina para melhoria de produção, capacidade, redução de custos. Ações industriais como a qualidade de produção pelo processo vibracional do maquinário, condições térmicas, estado de componentes e eficiência de equipamento, geralmente são monitoradas, porém com baixa ou ineficiente resultados, causando de forma geral: baixa eficiência, manutenções ou reparos não-agendados, diminuição de produção e aumento de custo energético [1].

As máquinas elétricas desempenham um papel imprescindível no processo produtivo industrial, pois podem se comportar como uma fonte de energização ou como fonte de movimento para elevação/declinação de cargas. Mediante a isto, aos

fatores econômicos e aos altos índices de competitividade no mercado, as indústrias estão buscando cada vez mais confiabilidade e disponibilidade de equipamentos para minimizar as interrupções indesejadas nos processos produtivos e os custos não programados de manutenção[2].

Nesse cenário, há modelos que analisam os diversos fatores em máquinas industriais pelas variáveis de condições físicas, analisando correlações em diversas aplicações. No entanto, as abordagens com o uso de aprendizado de máquina apresentam maior eficiência para atos não possíveis em modelos físicos ou estatísticos aplicados em: previsões, identificações ou classificações [3, 4, 5]. Assim, aprendizado de máquina pode apresentar resultados e condições favoráveis a robustez uma vez que são treinados e adaptados a diferentes cenários e aplicações.

Parte-se da premissa de que motores de indução são amplamente empregados na indústria em razão de sua robustez e confiabilidade. No entanto, estão sujeitos a falhas elétricas e mecânicas que podem comprometer significativamente sua operação[6]. Nesse contexto, a análise acústica surge como uma alternativa promissora para a construção de modelos diagnósticos não invasivos e de baixo custo, em comparação com abordagens tradicionais baseadas em medições de corrente ou vibração.

Este trabalho apresenta o PRIMUS, um modelo CNN para manutenção PReditIva em Motores indUtores industriais para fechamentos delta e estrela nos modos série e paralelo a partir de dados sonoros. Realizou-se gravações de áudio dos motores com variações de 1500 a 1650 rpm analisando a propriedade do motor com o modelo de gravação em formato circular tridimensional.

2. Trabalhos relacionados

A seguir, apresenta-se uma sequência de trabalhos que abordam motores de indução industrial, com foco no desempenho das máquinas, bem como em estratégias de controle e manutenção preventiva.

O trabalho de L. Hardine [7] analisa o impacto do sistema estrela-triângulo na redução do pico de corrente elétrica durante a partida de motores de indução trifásicos. O problema central abordado é o alto surto de corrente que ocorre no momento da partida, o qual pode causar danos aos enrolamentos do motor e comprometer sua vida útil. Durante a operação, após um intervalo controlado por temporizador, a conexão é alterada para a configuração triângulo, permitindo que o motor opere com a 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.

O trabalho de Ali Abdo et. al.[8] investigou métodos de detecção de falhas elétricas em motores de indução trifásico utilizando a análise acústica. Dessa forma proporam que sinais

acústicos captados durante o funcionamento do motor podem ser analisados para a identificação de padrões associados a diferentes tipos de falhas, como curto-circuito nas bobinas ou desequilíbrio de fases.

Utilizaram a abordagem envolve a coleta de sinais acústicos de motores em condições operacionais diferentes, ou seja, em estado normal ou falhas simuladas. Esses sinais foram convertidos em mel spectrograma para funcionar como entradas em modelos em redes convolucionais para classificar o tipo de falha presente no motor. Apresentaram que a abordagem acústica possui boa eficiência para distinguir entre falhas elétricas com precisão em ambientes ruidosos.

O trabalho de M. Q. Tran et. al. [9] propõe uma abordagem para o diagnóstico de falhas em motores de indução, combinando a transformada *wavelet* para extração de características com uma rede neural convolucional com mecanismo de atenção. Essa combinação permite capturar informações temporais e frequenciais dos sinais de vibração e corrente do motor, melhorando a sensibilidade e precisão na identificação de falhas como defeitos no rolamento, rotor e estator. A integração da análise *wavelet* com a rede convolucional de atenção possibilita um diagnóstico mais precoce e confiável, essencial para a manutenção preditiva e a redução de paradas não planejadas em ambientes industriais. No entanto, o uso de transformada *wavelet* é extremamente sensível a variações ruidosas necessitando de pré-processamento especializado para que o modelo CNN possam efetivamente identificar o diagnóstico específico de falhas de motores.

O trabalho de O.V. Thorsen e M. Dalva [10] revisa e analisa diversas técnicas de detecção de falhas, incluindo métodos mecânicos (vibrações, pulsos de choque, acústica, flutuações de velocidade), eletromecânicos (análise de correntes, surtos, descargas parciais, fluxos de fuga), além de monitoramento térmico, análise de partículas de óleo e gases, e métodos visuais e de desempenho. Os autores demonstram que diferentes tipos de falhas geram componentes de frequência específicos em 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, os autores enfatizam a importância de uma abordagem multifacetada para diagnóstico, combinando dados elétricos, mecânicos e químicos, e sugere que avanços futuros devem focar na integração de técnicas para aumentar a confiabilidade e segurança operacional desses equipamentos críticos.

O trabalho de [11] trata de um modelo de reconhecimento e esquema de correção em motores indutivos utilizando IoT com abordagem de aprendizado de máquina profundo. Utiliza informações de sinais de vibração como entrada no modelo de IA para a identificação de possíveis falhas. IoT é utilizado em grande escala na comunicação e informação dos motores para identificar pontualmente qual motor apresenta a possível falha ou quais apresentam a maior efetividade de ineficiência de utilização.

3. PRIMUS

O PRIMUS é um modelo de identificação de motores indutivos industriais com relação aos fechamentos delta e estrela nas configurações série e paralelo. Além disso, o PRIMUS identifica a possível necessidade de manutenção ou perfeito uso do motor indutivo industrial. Inicialmente, coletou-se os sinais de áudio para em seguida a confecção da arquitetura do modelo PRIMUS e por fim, a realização do treino, validação e teste. Vale ressaltar

que este projeto foi desenhado em estrutura piloto de bancada de testes no laboratório de máquinas industriais.

3.1. Motores de indução

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. Eles são amplamente utilizados em aplicações 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 [12].

No contexto de acionamento e partida desses motores, as configurações de ligação dos enrolamentos do estator notadamente nas conexões estrela e 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 delta 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 delta 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.




Figure 1: Configurações dos motores indutores com as variações dos estatores.

A figura 1 apresenta os tipos de configurações dos motores indutores industriais. As bobinas desempenham papéis variados, como a geração de campos magnéticos (bobinas de campo) ou a produção de energia elétrica (bobinas de armadura). A forma como essas bobinas estão conectadas e dispostas é crucial para o desempenho das máquinas, essas diferentes maneiras de conexão afetam diretamente o desempenho das máquinas, determinando características como torque, tensão, corrente e eficiência.

As nomenclaturas dos terminais dos motor-geradores de energia elétrica variam de acordo com o tipo de gerador, na configuração elétrica trifásica, o padrão de ligação (estrela,

triângulo, etc.), em conformidade com as normas como NBR, IEC e práticas industriais estão as mais comuns utilizadas em sistemas de geradores trifásicos 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
3. Em ligação estrela: os terminais U2, V2, W2 são interligados no ponto neutro.
4. Em ligação triângulo: os finais de uma fase se ligam aos inícios da próxima: U2-V1, V2-W1, W2-U1.

3.2. Coleta de sinais de áudio

Utilizou-se um microfone condensador para captação dos sinais de áudio motor por 10s conforme a figura 2. Assim, como neste projeto não se obteve recursos para a utilização de vários microfones, o eixo tridimensional do motor foi captado com a movimentação do microfone ao longo do seu eixo. Captou-se os áudios dos motores em um ambiente de trabalho, ou seja, com nível de ruído abaixo de 60 dB simulando condições normais de trabalho industrial.




Figure 2: Estratégia de gravação sonora do motor indutor.

Assim, para cada tipo de fechamento há 8 gravações de 10 segundos. E ainda, considerando que o teste de bancada foi realizado em modo que o motor possui o estado ideal de funcionamento e de manutenção, há 8 possíveis possibilidades de gravações do motor: delta-série-ideal, delta-série-manutenção, delta-paralelo-ideal, delta-paralelo-manutenção, estrela-série-ideal, estrela-série-manutenção, estrela-paralelo-ideal e estrela-paralelo-manutenção. Dessa forma, há o total de 64 gravações (8 identificadores x 8 gravações).

3.3. Modelo CNN

A partir dos áudios coletados, extraiu-se o mel espectrograma sendo a entrada do modelo convolucional. A figura 3, apresenta o modelo CNN composto pela entrada mel espectrograma do áudio de dimensão 224 mels por 672 amostragens para a saída das 8 possibilidades citadas acima. Utilizou-se fft, windows e hop de 2048, 1728, 656, respectivamente. Aplicou-se normalização do mel espectrograma entre 0 a 512. Dessa forma, o dataset criou-se

Otimizador	Acurácia
Adam	80.25%
Adamax	79.28%
Adamw	76.27%
Ftrl	65.67%
Nadam	69.31%
Rmsprop	81.25%

Table 1: Acurácia de treinamento do PRIMUS.

um dataset contendo anotações de tipo de motor-configurações-condição de uso e mel espectrograma. Com base utilizou-se a abordagem de 50% para treino-validação e 50% de testes.

O modelo da figura 3, foi o mais indicado dentre várias possibilidades. Dessa forma, analisou-se a melhoria pela acurácia variando o otimizador. Utilizou-se a biblioteca do LibRosa para exportar os sinais de áudio em mel espectrograma, e o Tensorflow para a criação do modelo convolucional.

A tabela 1 apresenta os resultados de treinamento com base nos otimizadores *adam*, *adamax*, *adamw*, *ftrl*, *nadam*, *rm-sprop*. Percebe-se que o melhor resultado de treinamento foi de 81.25% com o otimizador rmsprop. O Rmsprop obteve melhores resultados comparados aos demais por ter maior estabilidade com sensibilidade a ruídos, desempenho melhor com poucas entradas. Os otimizadores Adam, Adamax, Adamw e Nadam apresentam possíveis convergências para overfit e não possuem boa parametrização com poucas amostras e ainda com oscilações com ruídos.




Figure 3: Arquitetura do modelo PRIMUS.

A figura 4 apresenta a matriz de confusão dos testes realizados com o modelo PRIMUS. De modo geral, os erros de identificação aconteceram entre motor em perfeito estado e motor em estado de manutenção. Não houve problemas na identificação do motor nas configurações base, ou seja, o modelo acerta o fechamento delta-estrela na configuração série-paralelo.

4. Conclusão

Apresentou-se o PRIMUS, um modelo de identificação de motores indutivos industriais com relação aos fechamentos delta e estrela nas configurações série e paralelo considerando condições ideais ou de manutenção dos motores. Como trabalhos futuros, ampliar o conjunto de dados adicionando variáveis ao experimento contendo condições mais próximas do ambiente de trabalho industrial. Além disso, pretende-se combinar ações com diferentes fontes de dados (acústica, corrente, vibração) para aprimorar a robustez e a confiabilidade dos sistemas de diagnóstico dos motores. Dessa forma, a técnica pode ser integrada a sistemas automatizados de monitoramento, contribuindo para a redução de paradas não programadas e custos de manutenção.

Acknowledgement

Agradecemos ao laboratório de máquinas industriais da UNIFAP pela disponibilidade e apoio na aquisição de sinais sonoros uti-




Figure 4: Matriz de confusão de testes.

lizados neste projeto.

References

- [1] Prabhu Thirugnanam. Advances, new perspective and applications in induction motors. In *Induction Motors-Recent Advances, New Perspectives and Applications*. IntechOpen, 2023.
- [2] Vicente Biot-Monterde, Angela Navarro-Navarro, Israel Zamudio-Ramirez, Jose A Antonino-Daviu, and Roque A Osornio-Rios. 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, 2022.
- [3] Francesco Aggogeri, Nicola Pellegrini, and Franco Luis Tagliani. Recent advances on machine learning applications in machining processes. *Applied sciences*, 11(18):8764, 2021.
- [4] Yuri Merizalde, Luis Hernández-Callejo, and Oscar Duque-Perez. State of the art and trends in the monitoring, detection and diagnosis of failures in electric induction motors. *Energies*, 10(7):1056, 2017.
- [5] Muhammad Aman Sheikh, Sheikh Tahir Bakhsh, Muhammad Irfan, Nursyarizal bin Mohd Nor, and Grzegorz Nowakowski. A review to diagnose faults related to three-phase industrial induction motors. *Journal of Failure Analysis and prevention*, 22(4):1546–1557, 2022.
- [6] Andressa Borré, Laio Oriel Seman, Eduardo Camponogara, Stefano Frizzo Stefenon, Viviana Cocco Mariani, and Leandro dos Santos Coelho. Machine fault detection using a hybrid cnn-lstm attention-based model. *Sensors*, 23(9):4512, 2023.
- [7] Linkha Hardine, Dian Budhi Santoso, and Ridwan Satrio Hadikusuma. Analysis of the influence of star delta system in reduce electric starting surge in 3 phase motors. *Electrician: Jurnal Rekayasa Dan Teknologi Elektro*, 16(2):208–214, 2022.
- [8] Ali Abdo, Jamal Siam, Ahmed Abdou, Rashad Mustafa, and Hakam Shehadeh. 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, 2020.
- [9] Minh-Quang Tran, Meng-Kun Liu, Quoc-Viet Tran, and Toan-Khoa Nguyen. Effective fault diagnosis based on wavelet and convolutional attention neural network for induction motors. *IEEE Transactions on Instrumentation and Measurement*, 71:1–13, 2021.
- [10] Olav Vaag Thorsen and Magnus Dalva. Failure identification and analysis for high-voltage induction motors in the petrochemical industry. *IEEE transactions on industry applications*, 35(4):810–818, 2002.
- [11] Minh-Quang Tran, Mohammed Amer, Almoataz Y Abdelaziz, Hong-Jie Dai, Meng-Kun Liu, Mahmoud Elsis, et al. Robust fault recognition and correction scheme for induction motors using an effective iot with deep learning approach. *Measurement*, 207:112398, 2023.
- [12] Stephen J Chapman. *Fundamentos de máquinas elétricas*. AMGH editora, 2013.