

DETECÇÃO DA FALHAS EM BARRAS DO ROTOR COM FREQUÊNCIAS DE MEL E ARQUITETURA EFFICIENTNET

JOÃO INÁCIO MOREIRA BEZERRA¹; NATÁSSIA MEDEIROS RAFAELLE SIQUEIRA²; RONEY MENEZES MEIRELLES JUNIOR²; SOFIA PAGLIARINI² ; OSCAR MAURÍCIO HERNANDEZ RODRIGUEZ⁴; MARLON MAURÍCIO HERNANDEZ CELY³

¹Universidade Federal de Pelotas – jimbezerra@inf.ufpel.edu.br

²Universidade Federal de Pelotas – natassiamsads@gmail.com, rjmeirelles999@gmail.com, sofia.pagliarini@ufpel.edu.br

³Universidade Federal de Pelotas – marlon.cely@ufpel.edu.br

⁴Universidade de São Paulo - oscar.mhr@sc.usp.br

1. INTRODUÇÃO

Os motores de indução (MIs) são amplamente utilizados na indústria devido à sua alta eficiência, baixo custo de fabricação e elevada capacidade de torque de partida. Estes motores são essenciais em setores como mineração, transporte e indústria têxtil, impactando diretamente a confiabilidade de sistemas produtivos (SHU, 2023). Apesar de sua robustez, os MIs estão sujeitos a falhas ao longo do tempo, sendo as mais comuns os defeitos nos mancais, falhas nos enrolamentos e barras quebradas no rotor. Entre essas, as falhas em barras do rotor representam aproximadamente 9% de todas as falhas (DİŞLİ, 2023) em motores de indução. Esse tipo de defeito geralmente se inicia com pequenas trincas que evoluem para quebras completas nas barras, resultando em aumento de vibração e ruído, perda de eficiência e, eventualmente, parada total do sistema. Diante disso, a detecção precoce e a classificação precisa dessas falhas tornam-se essenciais para a manutenção preditiva e a continuidade operacional.

Nos últimos anos, técnicas de processamento de sinais têm sido amplamente aplicadas na detecção de falhas nas mais variadas aplicações que tenham sinais de séries temporais como entrada (ZHANG, 2023). Métodos como a Transformada de Fourier de Tempo Curto (STFT), Transformada Wavelet (WT) e os coeficientes cepstrais na frequência de Mel (MFCC) de forma com que os sinais temporais sejam representados no domínio tempo-frequência, por meio de imagens que são chamadas de espectrogramas. Os espectrogramas obtidos a partir destas transformações são então utilizados como entrada para arquiteturas de Redes Neurais Convolucionais (CNN), que têm a capacidade de distinguir diferentes comportamentos com alta precisão (NGUYEN, 2024).

Neste contexto, este trabalho propõe um sistema de diagnóstico automático de falhas em motores de indução utilizando uma base de dados pública com condição normal de operação e diferentes números de barras do rotor quebradas. Sinais de corrente são analisados no domínio tempo-frequência por meio da extração dos coeficientes cepstrais na frequência de Mel (MFCC), gerando espectrogramas representativos de cada condição. Os espectrogramas, por sua vez, servem como entrada para a rede neural convolucional EfficientNet-B0, que é capaz de distinguir não só falha de condição normal, mas falhas com alta acurácia.

2. METODOLOGIA

A base de dados utilizada neste trabalho foi disponibilizada por Treml et al. (2020) através da plataforma IEEE DataPort. O objetivo da base é o diagnóstico de falhas em motores de indução trifásicos, sendo composta por cinco classes: condição normal e falhas com 1 a 4 barras de rotor quebradas. Os sinais foram adquiridos com uma taxa de amostragem de 50 kHz, abrangendo 11 variáveis, sendo três sinais de corrente (I_a , I_b e I_c), três sinais de tensão e cinco sinais de vibrações. Cada sinal foi registrado sob 10 condições de carga distintas, variando de transiente à estado estável.

Na etapa de pré-processamento, foi inicialmente calculada a média dos três sinais de corrente trifásica, resultando em um único sinal representativo da corrente elétrica. A partir desse sinal médio, foi extraído o conjunto de coeficientes cepstrais na frequência de Mel (MFCC), gerando espectrogramas que capturam as características tempo-frequência de cada condição operacional. O processo de obtenção do MFCC é descrito detalhadamente em Zhang (2023), e o uso do MFCC em contrapartida à transformada Wavelet se dá em virtude da capacidade de extrair características mais precisas dos sinais. Em comparação à Transformada de Fourier de tempo curto (STFT), a escolha se dá em virtude do MFCC iterar sobre o sinal temporal com janelas de tamanho variável, dependendo das múltiplas frequências do sinal. Na Figura 1, mostra-se o resultado deste procedimento, com um sinal temporal sendo transformado em um espectrograma tempo-frequência.

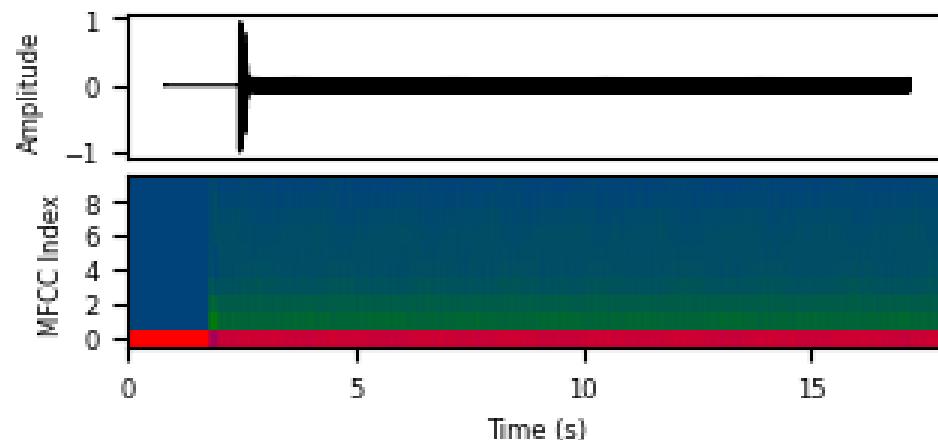


Figura 1: Sinal no domínio do tempo, e no domínio tempo-frequência, após a aplicação do MFCC.

A arquitetura EfficientNet-B0 foi escolhida por apresentar desempenho superior à outras arquiteturas do estado da arte de classificação de imagens, tais como Resnet50, ShuffleNet, GoogLeNet, DenseNet e Vision Transformer (BYERLY, 2022). Os experimentos foram realizados na linguagem de programação Python, com o modelo sendo importado da biblioteca `torchvision.models`.

3. RESULTADOS E DISCUSSÃO

A avaliação do desempenho do modelo foi realizada utilizando validação cruzada com 10 *folds*, a fim de verificar a capacidade de generalização da

arquitetura e reduzir a probabilidade de sobreajuste (*overfitting*). Para cada *fold*, os dados foram divididos em 70% para treinamento, 15% para validação e 15% para teste, de maneira estratificada, mantendo a proporção entre as classes. Em cada *fold*, a acurácia é obtida, em virtude da base de dados não possuir um alto desbalanceamento, sendo representada pelo número de previsões corretas dividido pelo número total de previsões. A acurácia final do modelo, obtida a partir da média da acurácia de cada um dos 10 *folds*, foi de 99.83%, evidenciando a capacidade do modelo de não só distinguir a classe normal das classes de falha, como distinguir as falhas entre si.

Na Tabela 1, é feita uma comparação do método deste trabalho com outros trabalhos do estado da arte da literatura. Diferentes variáveis da base de dados são usadas, assim como diferentes técnicas de processamento de sinais, técnicas de inteligência artificial e arquiteturas de redes neurais convolucionais para classificação. A acurácia de 99.83% obtida neste trabalho está de acordo com o estado da arte da literatura, mostrando a eficácia da técnica.

Referência	Comentários	Resultados
Este trabalho	Correntes: Ia, Ib, Ic, MFCC, EfficientNet.	Acurácia de 99.87%.
SHU (2023)	Corrente Ia, transformada de Hilbert, CNN.	Acurácia de 99.86%.
DISLI (2023)	Vibração acpi, corrente Ia. Filtro passa-baixa para remover ruído, transformada Wavelet. Resnet18 + SVM.	Acurácia de 100%.
BECHIRI et al. (2024)	Correntes: Ia, Ib, Ic. Transformada de Wavelet discreta, otimização Bayesiana, Random Forest.	Acurácia de 96.92%.

Tabela 1: comparação do trabalho com modelos do estado da arte da literatura.

4. CONCLUSÕES

A abordagem proposta, que combina espectrogramas obtidos a partir dos coeficientes cepstrais em frequências Mel (MFCC) com a arquitetura de rede neural convolucional EfficientNet, demonstrou alta eficácia na tarefa de classificação de diferentes condições de falha em motores de indução. Ao utilizar a média dos sinais de corrente trifásicos como base para a extração dos MFCCs, o método consegue capturar informações discriminativas relevantes do comportamento do motor em diferentes estados operacionais, o que é evidenciado pela acurácia de 99.83% obtida no experimento, um resultado de

acordo com o estado da arte da literatura para a base de dados utilizada. O uso de validação cruzada com 10 *folds* indica a baixa probabilidade de sobreajuste e a alta capacidade de generalização do modelo. Os resultados obtidos neste trabalho validam a combinação de técnicas de processamento de sinais para gerar espectrograma e a classificação com redes neurais convolucionais para a classificação de falhas em motores.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BECHIRI, Mohammed Bachir et al. Effective Diagnosis Approach for Broken Rotor Bar Fault Using Bayesian-based Optimization of Machine Learning Hyperparameters. **IEEE Access**, 2024.

BYERLY, Adam; KALGANOVA, Tatiana; OTT, Richard. The current state of the art in deep learning for image classification: A review. In: **Science and information conference**. Cham: Springer International Publishing, 2022. p. 88-105.

DIŞLI, Fırat; GEDIKPINAR, Mehmet; SENGUR, Abdulkadir. Deep transfer learning-based broken rotor fault diagnosis for Induction Motors. **Turkish Journal of Science and Technology**, v. 18, n. 1, p. 275-290, 2023.

NGUYEN, Duc C. et al. Vibration-based SHM of railway steel arch bridge with orbit-shaped image and wavelet-integrated CNN classification. **Engineering Structures**, v. 315, p. 118431, 2024.

SHU, Yuhui et al. DBF-CNN: A double-branch fusion residual CNN for diagnosis of induction motor broken rotor bar. **IEEE Transactions on Instrumentation and Measurement**, v. 72, p. 1-10, 2023.

TREML, Aline Elly et al. Experimental database for detecting and diagnosing rotor broken bar in a three-phase induction motor. **IEEE DataPort**, 2020.

ZHANG, Zhiyuan et al. MFCC-LSTM framework for leak detection and leak size identification in gas-liquid two-phase flow pipelines based on acoustic emission. **Measurement**, v. 219, p. 113238, 2023.