

Revisão sobre Técnicas para Diagnóstico de Falhas em Máquinas Elétricas na Indústria 4.0

DANIEL C. SILVA (PPGEE, IFPB, Campus João Pessoa), THYAGO V. LIMA (PPGEE, IFPB, Campus João Pessoa), RUAN D. GOMES (PPGEE, IFPB, Campus João Pessoa)

E-mails: carlos.silva.25@academico.ifpb.edu.br,

Área de conhecimento: (Tabela CNPq): Processamento de Sinais.

Palavras-Chave: motores indutivos trifásicos; detecção de falhas; método de assinatura de corrente MCSA e TMCSA; cloud-edge; aprendizado federado;

1 Introdução

Motores de indução trifásicos (MITs) são amplamente utilizados em ambientes industriais devido à sua robustez, eficiência e baixo custo. No entanto, falhas nesses motores podem comprometer significativamente a produtividade dos processos industriais. De acordo com um levantamento do IEEE, aproximadamente 41% das falhas em motores de indução são atribuídas a defeitos nos rolamentos, seguidas por problemas no estator (37%) e no rotor (10%) (IEEE Transactions on Industry Applications, 1985). Nesse contexto, o diagnóstico de falhas em máquinas utilizando dados de monitoramento de condições é de grande importância nas indústrias modernas, o que aumenta a confiabilidade dos dispositivos, aumenta a segurança da operação e reduz os custos de manutenção de acordo com (SHAO et al., 2019), (ZHOU et al., 2019) e (LI et al., 2017).

Nos últimos anos, com o rápido desenvolvimento de algoritmos de inteligência artificial, os métodos de diagnóstico de falhas baseados em dados alcançaram grande sucesso e foram amplamente adotados em diversas aplicações industriais, devido às vantagens de resposta rápida, alta precisão e fácil implementação. Contudo, essas soluções frequentemente requerem grandes volumes de dados rotulados para o treinamento supervisionado dos modelos, algo difícil de se obter em ambientes industriais reais, principalmente em situações de falha avançada, cuja replicação em campo é impraticável e indesejada (LI; ZHANG, 2020) e (YU et al., 2021). Essa limitação representa obstáculos notáveis para as aplicações dos algoritmos orientados por dados em cenários industriais. Uma solução intuitiva para esse problema é utilização de dados rotulados provenientes de várias máquinas semelhantes operando em diferentes plantas industriais. No entanto, essa abordagem envolve o compartilhamento de informações entre empresas, o que levanta preocupações quanto à privacidade, segurança e interoperabilidade dos dados. Tais desafios são amplamente conhecidos como o problema das ilhas de dados, caracterizado pela dificuldade em integrar dados heterogêneos e descentralizados pertencentes a diferentes entidades. Para contornar essas restrições, o Aprendizado Federado (Federated Learning – FL) tem ganhado destaque como uma abordagem promissora. Essa técnica permite o treinamento colaborativo de modelos globais de diagnóstico sem a necessidade de centralização dos dados, preservando a privacidade das informações e promovendo maior escalabilidade (PRIGENT et al., 2024). Diante desse cenário, a presente revisão tem como objetivo analisar criticamente as abordagens recentes para o diagnóstico de falhas em máquinas elétricas no contexto da Indústria 4.0, com foco na integração entre MCSA/TMCSA, aprendizado de máquina e técnicas distribuídas como o Aprendizado Federado. A lacuna científica abordada nesta revisão refere-se à escassez de estudos que combinem de forma estruturada técnicas de análise de sinais elétricos com arquiteturas de aprendizado distribuído, voltadas para ambientes industriais reais, onde os dados são descentralizados, sensíveis e heterogêneos.

2 Materiais e Métodos

O presente trabalho está sendo conduzido por meio de uma revisão bibliográfica e exploratória, com foco em métodos de diagnóstico de falhas em motores de indução trifásicos (MITs), abordagens de monitoramento baseadas na análise da corrente elétrica — MCSA (*Motor Current Signature Analysis*) e TMCSA (*Transient Motor Current Signature Analysis*) —, arquiteturas de computação em nuvem e borda (*Cloud-Edge Computing*) e aplicações de Aprendizado Federado (*Federated Learning* – FL) no contexto industrial. A metodologia adotada visa identificar lacunas técnicas e oportunidades de inovação na integração dessas tecnologias emergentes.

Foram selecionadas publicações científicas recentes, indexadas em bases como IEEE Xplore e ScienceDirect, utilizando critérios de relevância, impacto e atualidade. Os artigos foram analisados quanto às estratégias de extração de características da corrente elétrica, aos algoritmos de aprendizado de máquina aplicados ao diagnóstico de falhas, aos modelos federados utilizados em aplicações industriais e aos desafios de implementação em ambientes distribuídos.

Dentre os estudos revisados, destacam-se os trabalhos de Lei et al. (LEI et al., 2016) e Li et al. (LI; ZHANG; DING, 2019), que demonstram o potencial do aprendizado profundo para diagnóstico de falhas. Esse tipo de rede neural, com múltiplas camadas e transformações não lineares, apresenta alta capacidade de reconhecimento de padrões (ZHANG; LI; LI, 2020; LI et al., 2020).

Yang et al. (YANG et al., 2016) propuseram uma abordagem baseada em FFT, ICA, SWPT e DAG-SVM para detecção de falhas em mancais via MCSA. Morales-Pérez et al. (MORALES-PEREZ et al., 2018) utilizaram o Teste de Kolmogorov–Smirnov (KS) para detectar falhas em rolamentos por meio de desvios estatísticos. Garcia et al. (GARCIA-BRACAMONTE et al., 2019) aplicaram ICA sobre espectros de Fourier visando à identificação de falhas em barras de rotores.

No contexto de arquiteturas colaborativas, He et al. (HE; LIANG; YANG, 2023) propuseram o uso de Aprendizado Mútuo Profundo (DML) em uma configuração nuvem-borda, combinando redes neurais de diferentes portes para diagnóstico em caixas de engrenagens, com validação por simulações na plataforma DPS.

Prigent et al. (PRIGENT et al., 2024) reforçam a viabilidade do Aprendizado Federado na indústria, ressaltando seus benefícios frente à latência, privacidade e heterogeneidade. Zhu et al. (JIANG et al., 2024) estendem essa aplicação ao setor eólico, com uma proposta federada robusta (DKFLWT) voltada à preservação de privacidade e compartilhamento de conhecimento diagnóstico, sendo igualmente aplicável a sistemas industriais com motores de indução trifásicos.

3 Resultados e Discussão

Os resultados obtidos referem-se à análise crítica de estudos recentes da literatura científica, que evidenciam tanto os avanços quanto os desafios nas técnicas de diagnóstico de falhas em motores de indução trifásicos. A revisão mostrou que métodos baseados em MCSA (*Motor Current Signature Analysis*) e TMCSA (*Transient Motor Current Signature Analysis*) têm sido amplamente empregados, apresentando altos índices de acurácia, sensibilidade e especificidade na detecção de diferentes tipos de falhas.

Apesar dos resultados promissores, as publicações revisadas apontam limitações relacionadas à capacidade de generalização dos modelos, sobretudo em aplicações reais, marcadas por variabilidade operacional, interferências e ruídos nos sinais adquiridos. Nesse cenário, destaca-se uma tendência crescente de integração entre técnicas de diagnóstico e arquiteturas de computação em nuvem e borda (*Cloud–Edge Computing*), visando permitir diagnósticos em tempo real, ampliar a escalabilidade, preservar a privacidade dos dados e otimizar o desempenho computacional em ambientes industriais distribuídos.

No que diz respeito ao Aprendizado Federado (FL), os estudos analisados indicam seu elevado potencial para aplicações industriais descentralizadas, permitindo a construção colaborativa de modelos entre dispositivos e unidades sem necessidade de centralizar os dados. Essa abordagem é especialmente relevante em contextos que exigem altos níveis de privacidade, segurança e conformidade com restrições operacionais. Ainda assim, desafios significativos persistem, como a heterogeneidade dos dados, a sincronização eficiente dos modelos locais, as limitações computacionais dos dispositivos de borda e a resiliência frente a instabilidades de rede.

A comparação entre arquiteturas centralizadas e federadas revela que, embora o FL envolva maior complexidade de gerenciamento e orquestração, oferece vantagens substanciais em termos de preservação da privacidade, redução do tráfego de dados, mitigação de riscos relacionados à exposição de informações sensíveis e maior robustez frente a falhas operacionais e ataques cibernéticos.

4 Considerações Finais

Este trabalho, fundamentado em uma revisão bibliográfica exploratória, mapeou o estado da arte em técnicas de diagnóstico de falhas em motores de indução trifásicos, com ênfase nas abordagens MCSA (*Motor Current Signature Analysis*) e TMCSA (*Transient Motor Current Signature Analysis*), bem como na aplicação de algoritmos de aprendizado de máquina em arquiteturas Cloud–Edge. O Aprendizado Federado (*Federated Learning* – FL) destaca-se como uma alternativa promissora para diagnósticos colaborativos, especialmente em ambientes industriais com restrições de comunicação, recursos computacionais limitados e altos requisitos de privacidade.

Embora a implementação prática esteja em fase de planejamento, o levantamento, a análise crítica e a síntese da literatura forneceram uma base conceitual sólida. As lacunas identificadas apontam uma oportunidade concreta para aplicar FL ao diagnóstico de falhas em motores trifásicos, sobretudo em ambientes industriais que exigem sigilo e baixa sobrecarga de dados reforçando a atualidade e a relevância desta pesquisa.

Na etapa seguinte, será modelado um sistema de diagnóstico colaborativo em FL. Sensores de corrente, instalados nos motores, enviarão sinais analógicos de 4–20 mA a Controladores Lógicos Programáveis (CLPs), que os lerão, escalarão e repassarão via Modbus TCP a computadores locais. Esses computadores executarão o pré-processamento (FFT) e treinarão modelos de diagnóstico com seus próprios dados. Apenas os parâmetros dos modelos, serão encaminhados a um servidor em nuvem, responsável por agregar os pesos e atualizar um modelo global. Dessa forma, preserva-se a confidencialidade das informações industriais, enquanto se constrói um modelo robusto, capaz de generalizar entre diferentes linhas de produção e apoiar estratégias de manutenção preditiva alinhadas à Indústria 4.0.

Referências

- GARCIA-BRACAMONTE, J. E. et al. An approach on mcsa-based fault detection using independent component analysis and neural networks. *IEEE Transactions on Instrumentation and Measurement*, v. 68, n. 5, p. 1353–1361, 2019.
- HE, Z.; LIANG, D.; YANG, Y. Fault diagnosis scheme for the rotary machine group: A deep mutual learning-based approach with cloud–edge–end collaboration. *IEEE Transactions on Circuits and Systems II: Express Briefs*, v. 70, n. 8, p. 3209–3213, 2023.
- IEEE Transactions on Industry Applications. Report of large motor reliability survey of industrial and commercial installations, part i. *IEEE Transactions on Industry Applications*, IA-21, n. 4, p. 853–864, 1985.
- JIANG, G. et al. A federated learning framework for cloud–edge collaborative fault diagnosis of wind turbines. *IEEE Internet of Things Journal*, v. 11, n. 13, p. 23170–23185, 2024.
- LEI, Y. et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. *IEEE Transactions on Industrial Electronics*, v. 63, n. 5, p. 3137–3147, 2016.
- LI, C. et al. A bayesian approach to consequent parameter estimation in probabilistic fuzzy systems and its application to bearing fault classification. *Knowledge-Based Systems*, v. 129, p. 39–60, 2017.
- LI, C.; ZHANG, W. Deep learning-based partial domain adaptation method on intelligent machinery fault diagnostics. *IEEE Transactions on Industrial Electronics*, p. 1, 2020.
- LI, X.; ZHANG, W.; DING, Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering & System Safety*, v. 182, p. 208–218, 2019.
- LI, X. et al. Partial transfer learning in machinery cross-domain fault diagnostics using class-weighted adversarial networks. *Neural Networks*, v. 129, p. 310–319, 2020.
- MORALES-PEREZ, C. et al. Bearing fault detection in induction motors using mcsa and statistical analysis. In: *2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. Houston, TX, USA: [s.n.], 2018. p. 1–5.
- PRIGENT, C. et al. Enabling federated learning across the computing continuum: Systems, challenges and future directions. *Future Generation Computer Systems*, v. 160, p. 767–783, 2024.
- SHAO, H. et al. Enhanced deep gated recurrent unit and complex wavelet packet energy moment entropy for early fault prognosis of bearing. *Knowledge-Based Systems*, v. 183, p. 105022, 2019.
- YANG, T. et al. Feature knowledge based fault detection of induction motors through the analysis of stator current data. *IEEE Transactions on Instrumentation and Measurement*, v. 65, n. 3, p. 549–558, 2016.
- YU, K. et al. A multi-stage semi-supervised learning approach for intelligent fault diagnosis of rolling bearing using data augmentation and metric learning. *Mechanical Systems and Signal Processing*, v. 146, p. 107043, 2021.
- ZHANG, W.; LI, X.; LI, X. Deep learning-based prognostic approach for lithium-ion batteries with adaptive time-series prediction and on-line validation. *Measurement*, v. 164, p. 108052, 2020.
- ZHOU, F. et al. Deep learning fault diagnosis method based on global optimization gan for unbalanced data. *Knowledge-Based Systems*, v. 183, p. 104899, 2019.