

APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO PREDITIVA DE SISTEMAS ELÉTRICOS: UMA REVISÃO DA LITERATURA

APPLICATIONS OF ARTIFICIAL INTELLIGENCE IN PREDICTIVE
MAINTENANCE OF ELECTRICAL SYSTEMS: A LITERATURE REVIEW

Ciências Exatas e da Terra, Engenharias • 21/09/2026

REGISTRO DOI: [10.70773/revistatopicos/789917835](https://doi.org/10.70773/revistatopicos/789917835)

Emilly Sales Pessoa¹

Siomara Dias da Rocha²

RESUMO

A complexidade dos sistemas elétricos modernos exige estratégias de manutenção mais eficazes para garantir a continuidade energética, reduzir custos e minimizar interrupções. As abordagens corretiva e preventiva apresentam limitações como paradas não planejadas e intervenções desnecessárias. Nesse contexto, a manutenção preditiva apoiada por Inteligência Artificial surge como alternativa inovadora, possibilitando a antecipação de falhas pelo monitoramento contínuo e análise inteligente de dados. Este artigo analisou, via revisão sistemática, a aplicação de técnicas de Inteligência Artificial Aprendizado de Máquina e Aprendizado Profundo na manutenção preditiva de sistemas elétricos, abrangendo transformadores, motores, disjuntores e linhas de transmissão. A metodologia quali-quantitativa, exploratória e bibliográfica considerou publicações indexadas no *IEEE Xplore*, *Scopus*, *ScienceDirect* e *Google Scholar*. Os resultados indicam que modelos baseados em Redes Neurais Convolucionais, Redes Recorrentes de Memória Longa, Máquinas de Vetores de Suporte e Florestas Aleatórias alcançam acurácias entre 80% e 98% na predição de falhas, conforme o equipamento e a técnica empregada. A Análise de Gases Dissolvidos combinada com Inteligência Artificial destaca-se no diagnóstico de transformadores de potência. Conclui-se que a integração entre Inteligência Artificial e manutenção preditiva avança a Engenharia Elétrica em confiabilidade, economia e sustentabilidade, embora desafios como qualidade dos dados, custos de implementação e integração tecnológica ainda exijam atenção.

Palavras-chave: Inteligência Artificial; Manutenção Preditiva; Aprendizado de Máquina; Sistemas Elétricos; Diagnóstico de Falhas.

ABSTRACT

The complexity of modern electrical systems demands more effective maintenance strategies to ensure energy continuity, reduce costs, and minimize interruptions. Corrective and preventive approaches present limitations such as unplanned downtime and unnecessary interventions. In this context, predictive maintenance supported by Artificial Intelligence emerges as an innovative alternative, enabling fault anticipation through continuous monitoring and intelligent data analysis. This article analyzed, via systematic review, the application of Artificial Intelligence techniques, Machine Learning and Deep Learning in the predictive maintenance of electrical systems, covering transformers, motors, circuit breakers, and transmission lines. The qualitative-quantitative, exploratory, and bibliographic methodology considered publications indexed in IEEE Xplore, Scopus, ScienceDirect, and Google Scholar. Results indicate that models based on Convolutional Neural Networks, Long Short-Term Memory Networks, Support Vector Machines, and Random Forest achieve accuracies between 80% and 98% in fault prediction, depending on the equipment and technique employed. Dissolved Gas Analysis combined with Artificial Intelligence stands out in power transformer diagnostics. It is concluded that the integration between Artificial Intelligence and predictive maintenance advances Electrical Engineering in reliability, economy, and sustainability, although challenges such as data quality, implementation costs, and technological integration still require attention.

Keywords: Artificial Intelligence; Predictive Maintenance; Machine Learning; Electrical Systems; Fault Diagnosis.

1. INTRODUÇÃO

Os sistemas elétricos de potência constituem a infraestrutura crítica responsável pela geração, transmissão, distribuição e consumo de energia elétrica, cuja continuidade e confiabilidade são essenciais para o funcionamento da sociedade moderna. Nesses sistemas, equipamentos como transformadores de potência, motores de indução, disjuntores e linhas de transmissão estão sujeitos a condições operacionais adversas sobrecargas, oscilações de temperatura, umidade, vibrações mecânicas e degradação do isolamento que, ao longo do tempo, podem provocar falhas catastróficas, interrupções no fornecimento e prejuízos econômicos significativos (KUMAR e HATI 2021).

Tradicionalmente, a manutenção desses equipamentos tem sido realizada por meio de duas abordagens principais: a manutenção corretiva, que intervém após a ocorrência da falha, e a manutenção preventiva, que segue cronogramas predefinidos de intervenção, independentemente da condição real do equipamento. Embora amplamente utilizadas, ambas as abordagens apresentam limitações reconhecidas na literatura. A manutenção corretiva resulta em paradas inesperadas, custos elevados de reparo e riscos à segurança operacional, enquanto a manutenção preventiva pode gerar intervenções desnecessárias, substituição prematura de componentes e desperdício de recursos (DELOITTE, 2022; RANAWAKA, ALAHAKOON e HEWAPATHIRANA (2024).

Nesse cenário, a manutenção preditiva surge como alternativa estratégica, pois se baseia no monitoramento contínuo de parâmetros operacionais elétricos, térmicos, mecânicos e químicos permitindo a identificação de padrões irregulares que antecedem falhas. Diferentemente da abordagem preventiva, a preditiva intervém no momento adequado, com base na condição efetiva do

equipamento, otimizando recursos e reduzindo paradas não planejadas (NEGRI et al., 2024). No entanto, o volume de dados gerado por sensores, sistemas de automação e equipamentos inteligentes ultrapassa a capacidade de análise humana convencional, o que exige ferramentas avançadas para processamento e interpretação eficiente.

É nesse ponto que a Inteligência Artificial (IA) se destaca. Por meio de algoritmos de Aprendizado de Máquina (*Machine Learning* - ML), Aprendizado Profundo (*Deep Learning* - DL), redes neurais artificiais e técnicas de mineração de dados, a IA é capaz de identificar padrões complexos e não lineares que seriam imperceptíveis aos métodos estatísticos convencionais (YANG et al., 2023; ALHAMADI et al., 2024).

Modelos preditivos baseados em IA podem prever falhas em motores, transformadores, disjuntores e linhas de transmissão, otimizando o planejamento de manutenções e reduzindo custos operacionais. Além disso, a IA permite a integração com sistemas de monitoramento em tempo real, possibilitando ajustes automáticos e respostas rápidas diante de condições anormais de operação, o que representa avanço significativo em direção a sistemas elétricos mais autônomos, confiáveis e inteligentes, alinhados aos conceitos da Indústria 4.0 e das redes elétricas inteligentes (*smart grids*).

Apesar do reconhecido potencial da IA na manutenção preditiva, a literatura ainda apresenta lacunas importantes. Há necessidade de estudos que sistematizem e comparem as diferentes técnicas de IA aplicadas a equipamentos elétricos específicos, que avaliem os desafios práticos de implementação em larga escala e que

investiguem a integrabilidade dessas soluções com a infraestrutura existente no setor elétrico, especialmente no contexto brasileiro.

Diante do exposto, o problema de pesquisa que orienta este trabalho é: Como as técnicas de Inteligência Artificial podem ser aplicadas à manutenção preditiva de sistemas elétricos e quais são os benefícios, limitações e perspectivas dessa integração? Este artigo tem como objetivo geral analisar a aplicação de técnicas de Inteligência Artificial na manutenção preditiva de sistemas elétricos, destacando seus benefícios, desafios e perspectivas.

2. FUNDAMENTAÇÃO TEÓRICA OU REVISÃO DA LITERATURA

2.1. Evolução das Estratégias de Manutenção em Sistemas Elétricos

A manutenção de sistemas elétricos evoluiu significativamente ao longo das últimas décadas. Inicialmente, a manutenção corretiva era a prática predominante, caracterizando-se pela intervenção apenas após a falha do equipamento. Essa abordagem, embora simples, resulta em tempo médio de reparo elevado, custos não planejados e riscos à segurança, pois a falha já se manifestou e, frequentemente, causou danos colaterais (NEGRI et al., 2024).

Com o avanço da engenharia de confiabilidade, a manutenção preventiva baseada em tempo (*Time-Based Maintenance* - TBM) ganhou destaque, fundamentada na premissa de que intervenções periódicas podem reduzir a probabilidade de falha. No entanto, estudos como os de Ranawaka, Alahakoon e Hewapathirana (2024) demonstram que a manutenção preventiva por cronograma fixo tende a gerar intervenções desnecessárias estimando-se que até 30% das manutenções preventivas em equipamentos elétricos são

realizadas em componentes ainda operacionais, além de não eliminar completamente falhas inesperadas, uma vez que não considera a condição real do equipamento.

A manutenção preditiva baseada na condição (*Condition-Based Maintenance* - CBM) representa o estágio mais avançado dessa evolução. Ao monitorar variáveis como vibração, temperatura, corrente, tensão, gases dissolvidos no óleo isolante e assinaturas de descargas parciais, a CBM permite estimar o estado de saúde do equipamento (*health condition*) e prever o tempo residual de vida útil (*Remaining Useful Life* - RUL). Segundo Deloitte (2022), estratégias preditivas podem reduzir custos de manutenção em até 25% e o tempo de inatividade não planejado em 30% a 50%, quando comparadas às abordagens reativas.

A convergência entre CBM e tecnologias de IA potencializa a capacidade preditiva, pois algoritmos de aprendizado podem modelar relações complexas e não lineares entre as variáveis monitoradas e os modos de falha, superando as limitações dos métodos baseados em limiares fixos (*threshold-based methods*).

2.2. Técnicas de Inteligência Artificial Aplicadas à Manutenção Preditiva

As técnicas de IA aplicadas à manutenção preditiva em sistemas elétricos podem ser categorizadas em três grandes grupos: Aprendizado de Máquina supervisionado, Aprendizado Profundo e Aprendizado por Reforço.

2.2.1. Aprendizado de Máquina Supervisionado

Os modelos supervisionados são treinados com conjuntos de dados rotulados, nos quais as entradas (variáveis de monitoramento) estão associadas a saídas conhecidas (condição normal ou tipo de falha). As técnicas mais empregadas incluem:

Máquinas de Vetores de Suporte (SVM): Destacam-se na classificação de falhas em transformadores a partir de dados de Análise de Gases Dissolvidos (DGA). Benmahamed et al. (2021) demonstraram que classificadores SVM otimizados com algoritmos metaheurísticos alcançaram acurácia de até 93,75% no diagnóstico de falhas em transformadores de potência, superando métodos convencionais como Rogers e Duval. No entanto, a performance do SVM é sensível à escolha da função kernel e à dimensionalidade dos dados.

Florestas Aleatórias (*Random Forest*): Algoritmos de ensemble que combinam múltiplas árvores de decisão para melhorar a robustez e reduzir o sobreajuste (*overfitting*). Têm sido aplicados com sucesso na predição de falhas em motores de indução a partir de sinais de vibração e corrente, apresentando boa capacidade de generalização e interpretabilidade intermediária (KUMAR e HATI, 2021).

Redes Neurais Artificiais (RNA): Modelos inspirados na estrutura do cérebro humano, capazes de aproximar funções complexas. RNA tipo *Multilayer Perceptron* (MLP) são frequentemente empregadas como modelos de base (baseline) em estudos comparativos de manutenção preditiva (NEGRI et al., 2024).

2.2.2. Aprendizado Profundo (Deep Learning)

O Aprendizado Profundo emprega redes neurais com múltiplas camadas ocultas, capazes de extrair automaticamente

características hierárquicas dos dados brutos, dispensando a etapa manual de engenharia de atributos (*feature engineering*):

Redes Neurais Convolucionais (CNN): Originalmente desenvolvidas para processamento de imagens, as CNN têm sido adaptadas para o diagnóstico de falhas em equipamentos elétricos a partir de sinais unidimensionais (vibração, corrente, DGA). Taha, Ibrahim e Mansour (2021) propuseram um modelo CNN para diagnóstico de falhas em transformadores com base em dados DGA, alcançando acurácia de até 98,5% mesmo sob condições de ruído de medição de até $\pm 20\%$. Essa capacidade de lidar com dados ruidosos é particularmente relevante em ambientes industriais, onde sinais de sensores estão sujeitos a interferências eletromagnéticas.

Redes Recorrentes de Memória Longa (LSTM): Especialmente projetadas para modelar dependências temporais em dados sequenciais, as LSTM são adequadas para previsão de séries temporais de degradação de equipamentos elétricos. Yang et al. (2023) combinaram CNN e LSTM em uma arquitetura híbrida para diagnóstico de falhas em sistemas de corrente contínua, onde a CNN extraiu características espaciais dos dados brutos e a LSTM modelou as dependências temporais, alcançando desempenho superior aos modelos isolados.

Modelos Híbridos CNN-LSTM: A combinação das capacidades de extração de características da CNN com a modelagem temporal da LSTM tem demonstrado resultados promissores. Yang et al. (2023) verificaram que o modelo híbrido CNN-LSTM superou modelos isolados de CNN, LSTM, RNN, SVM e Árvore de Decisão em métricas como precisão, recall e F1-score.

2.2.3. Aprendizado por Reforço (Reinforcement Learning)

O Aprendizado por Reforço (RL) tem sido explorado para a otimização de estratégias de proteção cascata em sistemas elétricos. Nessa abordagem, um agente aprende por interação com o ambiente, ajustando suas ações para maximizar uma função de recompensa. Yang et al. (2023) empregaram RL para projetar estratégias de proteção cascata em sistemas DC, demonstrando que o agente de RL conseguia adaptar as estratégias de proteção em tempo real com base no estado do sistema, melhorando a confiabilidade e a estabilidade.

2.3. Aplicação da IA em Equipamentos Elétricos Específicos

2.3.1. Transformadores de Potência

Os transformadores de potência estão entre os ativos mais críticos e custosos do sistema elétrico. A Análise de Gases Dissolvidos (DGA) no óleo isolante é a técnica de monitoramento mais amplamente adotada para esses equipamentos, pois a presença e a concentração de gases como hidrogênio (H_2), metano (CH_4), acetileno (C_2H_2), etileno (C_2H_4) e etano (C_2H_6) estão associadas a modos de falha específicos descargas parciais, arcos elétricos e sobreaquecimento (BENMAHAMED et al. 2021).

A integração de DGA com algoritmos de IA tem demonstrado resultados expressivos. Benmahamed et al. (2021) alcançaram acurácia global de 93,75% no diagnóstico de falhas em transformadores utilizando classificadores SVM otimizados com Bat Algorithm, superando métodos convencionais como as razões de Rogers e o triângulo de Duval. Taha, Ibrahim e Mansour (2021) obtiveram acurácia de até 98,5% com modelo CNN aplicado a dados

DGA com tolerância a ruído de medição, evidenciando a robustez das redes convolucionais em condições reais de operação.

Pesquisas mais recentes têm explorado modelos leves baseados em destilação de conhecimento (*Knowledge Distillation*) para viabilizar a implantação de modelos de IA em dispositivos de borda (*edge devices*) com recursos computacionais limitados (ZHANG et al., 2021; GAO et al., 2022; LI et al., 2023).

2.3.2. Motores Elétricos de Indução

Os motores de indução trifásicos são os equipamentos mais abundantes em instalações industriais e estão sujeitos a falhas em rolamentos, estator, rotor e desbalanceamento. O diagnóstico preditivo de falhas em motores elétricos baseia-se na análise de sinais de vibração, corrente de estator (MCSA - *Motor Current Signature Analysis*) e temperatura.

Kumar e Hati (2021) compararam o desempenho de classificadores *Random Forest*, SVM e RNA na detecção de falhas em rolamentos de motores de indução, constatando que o *Random Forest* apresentou acurácia ligeiramente superior (acima de 96%) em conjuntos de dados públicos como o *Case Western Reserve University* (CWRU) - *Bearing Dataset*, enquanto o SVM alcançou desempenho comparável com menor custo computacional.

2.3.3. Disjuntores e Equipamentos de Manobra

Em disjuntores de média tensão, a predição de falhas baseia-se no monitoramento de sinais mecânicos (tempo de viagem, velocidade de operação) e elétricos (corrente e resistência de contato). Negri et al. (2024) demonstraram que redes neurais artificiais aplicadas a

dados de monitoramento distribuído de disjuntores podem melhorar significativamente a precisão da manutenção preditiva em redes de distribuição de média tensão.

2.4. Smart Grids e Indústria 4.0: O Papel Estratégico da IA

A integração da IA em sistemas elétricos insere-se no contexto mais amplo da Indústria 4.0 e das *smart grids*. As redes elétricas inteligentes empregam sensores avançados, medidores inteligentes e sistemas de comunicação bidirecional para monitorar e controlar o fluxo de energia em tempo real. Nesse cenário, a IA atua como camada analítica que transforma os dados coletados em conhecimento aplicável à tomada de decisão (ALHAMADI et al., 2024).

Bughin et al. (2017) destaca que a manutenção preditiva impulsionada por IA pode gerar economia global de até 630 bilhões de dólares por ano em setores de manufatura, com redução de 30% a 50% no tempo de inatividade não planejado. No setor elétrico especificamente, esses benefícios traduzem-se em maior confiabilidade do fornecimento, otimização de investimentos em infraestrutura e redução de perdas técnicas e não técnicas.

No contexto brasileiro, a Agência Nacional de Energia Elétrica (ANEEL) tem promovido a regulamentação de práticas de manutenção preditiva e o incentivo à digitalização do setor, enquanto o Governo Federal, por meio da Estratégia Brasileira de Inteligência Artificial (EBIA), busca estabelecer diretrizes para o desenvolvimento e uso responsável de IA no país (BRASIL, 2021). A aprovação do Projeto de Lei nº 2.338/2023 reforça a relevância desse debate regulatório.

2.5. Desafios e Limitações da IA na Manutenção Preditiva

Apesar dos resultados promissores, a implementação da IA na manutenção preditiva de sistemas elétricos enfrenta desafios significativos:

- **Qualidade e disponibilidade de dados:** Dados inconsistentes, incompletos ou ruidosos provenientes de sensores defeituosos comprometem a precisão dos modelos preditivos, gerando falsos positivos ou falsos negativos (AIVENTIC, 2025).
- **Eventos raros de falha:** A maioria dos equipamentos opera em condição normal durante a maior parte do tempo, resultando em conjuntos de dados intrinsecamente desbalanceados com poucos exemplos de falha para treinamento dos modelos RANAWAKA, ALAHAKOON e HEWAPATHIRANA (2024).
- **Custo de implementação:** A infraestrutura necessária sensores IoT, plataformas de análise, conectividade e pessoal qualificado representa investimento significativo, particularmente para pequenas e médias empresas do setor elétrico.
- **Integração com sistemas legados:** Muitas concessionárias de energia ainda operam com sistemas de gestão baseados em formatos de dados desatualizados, o que dificulta a sincronização em tempo real (AIVENTIC, 2025).
- **Explicabilidade e confiança:** Modelos de *deep learning* são frequentemente considerados caixas-pretas, cujas decisões são difíceis de interpretar por engenheiros de manutenção. A falta de explicabilidade pode limitar a confiança e a adoção em ambientes regulados.

- **Segurança cibernética:** A conectividade crescente entre sensores IoT e plataformas de IA amplia a superfície de ataque cibernético em infraestruturas críticas do setor elétrico (ALHAMADI et al., 2024).

3. METODOLOGIA

3.1. Abordagem de Pesquisa

A pesquisa adotou uma abordagem quali-quantitativa. A dimensão qualitativa voltou-se à interpretação de conceitos, teorias e aplicações práticas da IA na manutenção preditiva, enquanto a dimensão quantitativa considerou dados numéricos provenientes de estudos de caso, relatórios técnicos e indicadores de desempenho disponíveis nas publicações analisadas.

3.2. Tipo de Pesquisa

O estudo caracteriza-se como exploratório e bibliográfico. É exploratório por buscar ampliar a compreensão sobre o papel da IA na manutenção preditiva de sistemas elétricos, sintetizando evidências dispersas na literatura. É bibliográfico por fundamentarem-se na análise de livros, artigos científicos, teses e periódicos especializados publicados nos últimos cinco anos (2020–2025).

3.3. Estratégia de Busca e Seleção

As buscas foram realizadas nas bases *IEEE Xplore*, *Scopus*, *ScienceDirect*, *MDPI* e *Google Scholar*, utilizando combinações de descritores em português e inglês: "*artificial intelligence*" AND "*predictive maintenance*" AND "*electrical systems*"; "*machine*

learning" AND "fault diagnosis" AND "transformer"; "deep learning" AND "motor" AND "bearing fault"; "inteligência artificial" AND "manutenção preditiva" AND "sistemas elétricos".

Os critérios de inclusão foram: (i) artigos publicados em periódicos e conferências revisados por pares; (ii) publicações entre 2020 e 2025, com inclusão de trabalhos clássicos anteriores quando fundamentais; (iii) estudos que apresentassem resultados quantitativos ou aplicações práticas de IA na manutenção preditiva de equipamentos elétricos; (iv) publicações em português, inglês ou espanhol.

Os critérios de exclusão foram: (i) resumos expandidos sem metodologia clara; (ii) estudos cujo foco principal não fosse manutenção preditiva de sistemas elétricos; (iii) publicações duplicadas.

3.4. Procedimentos e Técnicas de Análise

Os procedimentos envolveram: (i) análise documental de relatórios técnicos e normativos relacionados a sistemas elétricos e manutenção preditiva; (ii) estudo comparativo entre métodos de manutenção corretiva, preventiva e preditiva com suporte de IA, considerando indicadores como MTBF (Tempo Médio Entre Falhas), custo de manutenção e percentual de redução de falhas; (iii) análise de dados secundários oriundos de casos práticos disponíveis em publicações acadêmicas.

Os dados coletados foram organizados e analisados por meio de análise de conteúdo (BARDIN, 2011), método que permitiu identificar padrões, técnicas mais recorrentes de IA aplicadas e resultados obtidos nas publicações selecionadas. Quando disponível, foram

considerados indicadores quantitativos como acurácia de classificação, sensibilidade, especificidade, F1-score e tempo de inferência dos modelos.

3.5. Universo e Amostra

Não foi realizada pesquisa de campo com coleta primária de dados. O universo analisado correspondeu a pesquisas científicas e estudos de caso já publicados, os quais foram selecionados como amostra a partir dos critérios de relevância, atualidade e pertinência ao tema.

4. RESULTADOS E DISCUSSÕES OU ANÁLISE DOS DADOS

4.1. Técnicas de IA e Desempenho Preditivo

A análise sistemática da literatura revelou que diferentes técnicas de IA apresentam desempenhos variados conforme o tipo de equipamento elétrico e a natureza dos dados de monitoramento disponíveis. A Tabela 1 sintetiza os principais resultados identificados.

Tabela 1. Comparação de técnicas de IA aplicadas à manutenção preditiva.

Referência	Equipamen to	Técnica de IA	Dados de Entrada	Acurácia (%)
Benmahamed et al. (2021)	Transforma dor	SVM + Bat Algorithm	DGA (6 gases)	93,75
Ibrahim et al. (2021)	Transforma dor	CNN	DGA (6 gases)	98,5
Yang et al. (2023)	Sistema DC	CNN-LSTM + RL	Sinais elétricos	*

Kumar e Hati (2021)	Motor de indução	Random Forest	Vibração	> 96
Negri et al. (2024)	Disjuntor MT	RNA	Mecânicos e elétricos	**
Ranawaka, Alahakoon e Hewapathirana (2024)	Sistemas elétricos	Múltiplas	Múltiplas	Variável

Fonte: Autoria Própria, 2026.

Legenda:

** Yang et al. (2023) reportaram desempenho superior do modelo híbrido, sem valor percentual único de acurácia global.*

*** Acurácia não reportada de forma isolada.*

Os resultados evidenciam que: (i) modelos de deep learning (CNN, LSTM) tendem a alcançar acurácias superiores quando há volumes adequados de dados de treinamento; (ii) técnicas de ML clássicas como SVM e Random Forest apresentam desempenho competitivo com menor custo computacional; (iii) a escolha da técnica deve considerar não apenas a acurácia, mas também a velocidade de inferência, a explicabilidade e os recursos computacionais disponíveis.

A aplicação da inteligência artificial na manutenção preditiva pode ser compreendida a partir da integração entre a aquisição de dados dos equipamentos, o processamento das informações, a aplicação de modelos de aprendizado de máquina, o diagnóstico de falhas e o planejamento das ações de manutenção, conforme apresentado na Figura 1.

Figura 1. Aplicação da inteligência artificial na manutenção preditiva de sistemas elétricos.



Fonte: Autoria Própria, 2026.

4.2. Análise por Categoria de Equipamento

4.2.1. Transformadores de Potência

Os transformadores de potência foram o equipamento mais estudado na literatura analisada, dado seu alto custo unitário e posição crítica na cadeia de transmissão e distribuição.

A DGA consolidou-se como a técnica de monitoramento predominante, combinada com diferentes algoritmos de classificação. Benmahamed et al. (2021) alcançaram 93,75% de acurácia com SVM otimizado, e Taha, Ibrahim e Mansour (2021) obtiveram 98,5% com CNN robusta ao ruído, demonstrando que a IA supera significativamente os métodos convencionais baseados em razões de gases, cujas acurácias variam entre 60% e 80%.

A superioridade do modelo CNN pode ser atribuída à capacidade das redes convolucionais de extrair automaticamente características discriminativas dos dados brutos de DGA, dispensando a seleção manual de atributos. O SVM, contudo, requer menor volume de dados de treinamento e é computacionalmente mais leve.

4.2.2. Motores Elétricos de Indução

A detecção de falhas em rolamentos de motores elétricos a partir de sinais de vibração e corrente consolida-se como uma aplicação madura na literatura. Segundo o estudo de Kumar e Hati (2021), o algoritmo Random Forest obteve desempenho superior às técnicas de SVM e RNA, vantagem impulsionada pela capacidade dos métodos de *ensemble* em reduzir a variância e aprimorar a generalização dos modelos. No entanto, embora a predominância do uso do *CWRU Bearing Dataset* favoreça a comparação direta entre diferentes pesquisas, essa padronização impõe uma limitação prática: o conjunto de dados pode não capturar com fidelidade a complexidade e a variabilidade típicas dos ambientes industriais reais.

4.2.3. Disjuntores e Equipamentos de Manobra

A aplicação de IA em disjuntores é menos explorada na literatura, possivelmente devido à menor disponibilidade de dados públicos. Negri et al. (2024) demonstraram a viabilidade de redes neurais no monitoramento distribuído, mas a acurácia não foi reportada isoladamente.

4.3. Benefícios Identificados

Os benefícios da IA na manutenção preditiva podem ser organizados em quatro dimensões:

1. Confiabilidade operacional: A antecipação de falhas permite intervenções programadas, aumentando o MTBF dos equipamentos.
2. Redução de custos: Deloitte (2022) estima redução de 25% nos custos de manutenção e 30% a 50% no tempo de inatividade não planejado. McKinsey (2017) projeta economia de até 630 bilhões de dólares/ano no setor de manufatura.
3. Sustentabilidade: A otimização da vida útil de equipamentos reduz substituições prematuras e impacto ambiental.
4. Segurança operacional: A detecção precoce de anomalias minimiza riscos de incêndios, explosões e choques elétricos.

4.4. Desafios e Limitações

- Qualidade de dados: Sensores defeituosos alimentam modelos de IA com dados incorretos, gerando falsos positivos ou negativos (AIVENTIC, 2025).
- Escassez de dados de falha: Equipamentos operam por décadas com baixa frequência de falha, resultando em conjuntos desbalanceados.
- Custo e complexidade de integração: Infraestrutura de IoT e necessidade de profissionais multidisciplinares representam barreiras significativas.

- Explicabilidade (XAI): A adoção em ambientes regulados exige decisões justificáveis.
- Segurança cibernética: A convergência *Operational Technology* e *Information Technology* (OT/IT) amplia riscos de ataques.

4.5. Perspectivas Futuras

Com base na literatura, identificam-se as seguintes tendências:

- Gêmeos digitais (*Digital Twins*): Réplicas virtuais dinâmicas para simulação de cenários de falha.
- Computação de borda (*Edge Computing*): Inferências em tempo real próximas aos sensores.
- Aprendizado federado (*Federated Learning*): Treinamento colaborativo preservando privacidade.
- IA explicável (XAI): Métodos como *Shapley Additive Explanations* (SHAP) e *Local Interpretable Model-agnostic Explanations* (LIME) para interpretação de modelos.
- Integração com renováveis: Manutenção preditiva adaptada à variabilidade operacional.

5. CONCLUSÃO/CONSIDERAÇÕES FINAIS

A manutenção preditiva de sistemas elétricos, tradicionalmente fundamentados em inspeções periódicas e limiares fixos, encontra na Inteligência Artificial um catalisador transformador capaz de elevar significativamente a precisão do diagnóstico e a antecipação

de falhas. Em resposta ao problema de pesquisa, constata-se que as técnicas de IA, em especial SVM, *Random Forest*, CNN, LSTM e CNN-LSTM podem ser aplicadas à manutenção preditiva de sistemas elétricos com acurácias entre 80% e 98,5%. A DGA combinada com IA demonstrou-se eficaz no diagnóstico de transformadores; sinais de vibração e corrente mostraram-se robustos para motores de indução.

Retomando o objetivo geral, conclui-se que essa integração representa avanço significativo para a engenharia elétrica, com benefícios em confiabilidade, economia, sustentabilidade e segurança. No entanto, desafios permanecem: qualidade de dados, custos de infraestrutura, integração com sistemas legados e explicabilidade dos modelos são questões abertas. Como limitações: (i) ausência de dados primários; (ii) impossibilidade de verificar reprodutibilidade dos estudos; (iii) sub-representação de disjuntores e linhas de transmissão na literatura.

Para trabalhos futuros: (i) validação experimental em condições reais do setor elétrico brasileiro; (ii) aprendizado federado entre concessionárias; (iii) XAI aplicado ao diagnóstico preditivo; (iv) análise de viabilidade econômica para pequenas distribuidoras; (v) avaliação do impacto regulatório. Por fim, a transformação do paradigma de manutenção depende não apenas do avanço tecnológico, mas também da capacitação profissional, de marcos regulatórios adequados e do compromisso institucional com a inovação responsável.

REFERÊNCIAS BIBLIOGRÁFICAS

AIVENTIC. AI challenges in predictive maintenance. 2025. Disponível em: <https://www.aiventica.ai/blog/ai-challenges-in-predictive-maintenance>. Acesso em: 20 mai. 2026.

BARDIN, Laurence. Análise de conteúdo. São Paulo: Edições 70, 2011. Disponível em: <https://pt.scribd.com/document/866438845/Analise-Conteudo-Bardin-1>. Acesso em: 20 mai. 2026.

BENMAHAMED, Youcef; KHERIF, Omar; TEGUAR, Madjid; BOUBAKEUR, Ahmed; GHONEIM, Sherif S. M. Accuracy improvement of transformer faults diagnostic based on DGA data using SVM-BA classifier. Energies, v. 14, n. 10, p. 2970, 2021. DOI: 10.3390/en14102970. Disponível em: <https://doi.org/10.3390/en14102970>. Acesso em: 5 jul. 2026.

BRASIL. Ministério da Ciência, Tecnologia e Inovações. Estratégia Brasileira de Inteligência Artificial (EBIA). Brasília, DF: MCTI, 2021. Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/estrategia-brasileira-de-inteligencia-artificial-ebia>. Acesso em: 8 ago. 2026.

BUGHIN, Jacques; HAZAN, Eric; RAMASWAMY, Sree; CHUI, Michael; ALLAS, Tera; DAHLSTRÖM, Peter; TRENCH, Martin. Artificial intelligence: the next digital frontier? New York: McKinsey Global Institute, 2017. Disponível em: <https://www.mckinsey.com/~media/McKinsey/Industries/Advanced%20Electronics/Our%20Insights/How%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/MGI-Artificial-Intelligence-Discussion-paper.ashx>. Acesso em: 19 jul. 2026.

DELOITTE. Using AI to elevate predictive maintenance. 2022. Disponível em: <https://www.deloitte.com/us/en/what-we>

[do/capabilities/applied-artificial-intelligence/articles/using-ai-in-predictive-maintenance.html](https://doi.org/10.56238/sevenlengineering-039). Acesso em: 18 jul. 2026.

FIGUEIREDO, Gustavo Molina. Inteligência artificial aplicada à manutenção preditiva em equipamentos elétricos. In: I SEVEN INTERNATIONAL ENGINEERING CONGRESS, 2024. Anais [...]. 2024. DOI: 10.56238/sevenlengineering-039. Disponível em: <https://doi.org/10.56238/sevenlengineering-039>. Acesso em: 20 jul. 2026.

GAO, R.; WANG, P.; TIAN, G. Y.; CHEN, X. Knowledge distillation for lightweight edge-computing-based fault diagnosis in rotating machinery. *IEEE Transactions on Industrial Informatics*, v. 18, n. 11, p. 7890-7900, 2022. Disponível em: <https://doi.org/10.1109/TII.2022.3151833>. Acesso em: 19 ago. 2026.

KUMAR, Prashant; HATI, Ananda Shankar. Review on machine learning algorithm based fault detection in induction motors. *Archives of Computational Methods in Engineering*, v. 28, p. 3661–3685, 2021. DOI: 10.1007/s11831-020-09446-w. Disponível em: <https://doi.org/10.1007/s11831-020-09446-w>. Acesso em: 9 ago. 2026.

LI, X.; ZHANG, W.; DING, Q.; SUN, C. Edge-guided knowledge distillation network for intelligent fault diagnosis of electrical equipment. *Reliability Engineering & System Safety*, v. 231, p. 108980, 2023. Disponível em: <https://doi.org/10.1016/j.ress.2022.108980>. Acesso em: 10 ago. 2026.

NEGRI, Virginia; IADAROLA, Grazia; MINGOTTI, Alessandro; SPINSANTE, Susanna; TINARELLI, Roberto; PERETTO, Lorenzo. Predictive maintenance based on artificial neural network for MV switchgears. *IEEE Sensors Journal*, v. 24, n. 21, p. 35448-35455, 2024.

DOI: 10.1109/JSEN.2024.3455755. Disponível em: <https://doi.org/10.1109/JSEN.2024.3455755>. Acesso em: 25 ago. 2026.

RANAWAKA, A., ALAHAKOON, D., SUN, Y., & HEWAPATHIRANA, K. (2024). Leveraging the Synergy of Digital Twins and Artificial Intelligence for Sustainable Power Grids: A Scoping Review. *Energies*, 17(21), 5342. <https://doi.org/10.3390/en17215342>. Disponível em: <https://doi.org/10.3390/en17215342>. Acesso em: 20 ago. 2026.

TAHA, I, B. M.; IBRAHIM, Saleh; MANSOUR, Diao-Eldin A. Power transformer fault diagnosis based on DGA using a convolutional neural network with noise in measurements. *IEEE Access*, v. 9, p. 111162-111170, 2021. DOI: 10.1109/ACCESS.2021.3102415. Disponível em: <https://doi.org/10.1109/ACCESS.2021.3102415>. Acesso em: 10 ago. 2026.

YANG, Yun; TU, Feng; HUANG, Shixuan; TU, Yuehai; LIU, Ti. Research on CNN-LSTM DC power system fault diagnosis and differential protection strategy based on reinforcement learning. *Frontiers in Energy Research*, v. 11, 1258549, 2023. DOI: 10.3389/fenrg.2023.1258549. Disponível em: <https://doi.org/10.3389/fenrg.2023.1258549>. Acesso em: 26 ago. 2026.

ZHANG, Y.; REN, H.; ZOU, J.; LIU, Y. Lightweight neural networks via knowledge distillation for embedded bearing fault diagnosis. *Measurement Science and Technology*, v. 32, n. 10, p. 105108, 2021. Disponível em: <https://doi.org/10.1088/1361-6501/ac0a11>. Acesso em: 8 set. 2026.

¹ Discente do Curso Superior de Engenharia Elétrica da Fundação Centro de Pesquisa e Inovação Tecnológica – FUCAPI, Manaus -AM.

E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Discente do Curso Superior de Engenharia Elétrica da Fundação Centro de Pesquisa e Inovação Tecnológica – FUCAPI, Manaus - AM. Doutora em Química (PPGQ/UFAM). E-mail: [acesse o artigo original para visualizar o e-mail](#)