www.revistaft.com.br

Revista FT | ISSN 1678-0817 | v. 30, n. 164, 2026 | DOI: 10.69849/g9rz2188

A influência da inteligência artificial na indústria elétrica: uma revisão bibliográfica

The influence of artificial intelligence on the electrical industry: a literature review

Luiz Henrique de Oliveira Rocha
Layse Oliveira Batista
Glaucivan Barroso da Cunha

RESUMO

Este artigo analisa a influência da inteligência artificial (IA) na Engenharia Elétrica, considerando aplicações, benefícios, limitações e implicações profissionais. Realizou-se revisão bibliográfica qualitativa e exploratória de estudos nacionais e internacionais sobre manutenção e diagnóstico, previsão de carga e geração renovável, proteção, redes inteligentes e cibersegurança. O conjunto analisado reuniu 47 trabalhos, sendo 22 estudos originais e 25 revisões ou análises. Manutenção e diagnóstico (14 estudos) e previsão de carga e geração (12) concentraram 55,3% da amostra. Os resultados não indicam superioridade universal de algoritmos: o desempenho depende do problema, dos dados e da validação. A adoção industrial exige instrumentação e dados adequados, interpretabilidade, segurança cibernética e viabilidade econômica. Conclui-se que a IA complementa práticas tradicionais e amplia competências profissionais, sem substituir a validação nem a responsabilidade técnica.

Palavras-chave: Inteligência Artificial; Engenharia Elétrica; Aprendizado de Máquina; Manutenção Preditiva; Sistemas Elétricos.

ABSTRACT

This paper analyzes the influence of artificial intelligence (AI) on Electrical Engineering, considering applications, benefits, limitations, and professional implications. A qualitative and exploratory literature review examined Brazilian and international studies on maintenance and diagnosis, load and renewable generation forecasting, protection, smart grids, and cybersecurity. The analyzed collection comprised 47 works: 22 original studies and 25 reviews or analytical papers. Maintenance and diagnosis (14 studies) and load and generation forecasting (12) accounted for 55.3% of the sample. Findings do not indicate universal algorithmic superiority; performance depends on the task, data, and validation. Industrial adoption requires adequate instrumentation and data, interpretability, cybersecurity, and economic feasibility. AI is concluded to complement established engineering practices and expand professional skills without replacing validation or technical responsibility.
Keywords: Artificial Intelligence; Electrical Engineering; Machine Learning; Predictive Maintenance; Power Systems.

1 INTRODUÇÃO

A digitalização dos processos industriais e dos sistemas de geração, transmissão e distribuição de energia elétrica tem ampliado a disponibilidade de dados operacionais. Nesse contexto, técnicas de inteligência artificial (IA) podem auxiliar na identificação de padrões, na previsão de condições futuras e no apoio à tomada de decisão técnica. A integração entre sensores, automação, comunicação e métodos computacionais está associada à transformação digital dos sistemas elétricos (AHMAD et al., 2021; GOUDARZI et al., 2022).

Na manutenção de ativos elétricos, modelos orientados por dados têm sido investigados para diagnóstico de falhas e monitoramento de condição; na operação dos sistemas, são empregados em previsões de carga, geração renovável e classificação de eventos. Entretanto, resultados promissores em um equipamento ou base de dados não demonstram, por si só, desempenho equivalente em outras condições de operação (MOLĘDA et al., 2023; PORAWAGAMAGE et al., 2024).

A incorporação da IA também exige considerar a disponibilidade e a qualidade dos dados, os custos de instrumentação, a segurança cibernética, a interpretabilidade dos modelos e a qualificação profissional. Assim, a questão que orienta esta pesquisa é: de que maneira a IA

influencia as aplicações e as práticas da Engenharia Elétrica, e quais condições limitam sua adoção confiável?

O objetivo geral é analisar a influência da IA na indústria elétrica, entendida neste trabalho como o setor de energia e as aplicações industriais da Engenharia Elétrica, identificando aplicações, benefícios, desafios e impactos sobre a atuação profissional. Especificamente, busca-se caracterizar as principais aplicações, comparar técnicas de aprendizado de máquina e profundo, discutir condições de implantação e examinar as competências requeridas do engenheiro eletricista.

Para delimitar o objeto, o estudo considera tanto o setor elétrico geração, transmissão e distribuição, quanto aplicações industriais da Engenharia Elétrica em que motores, acionamentos, automação e monitoramento sustentam os processos produtivos. Essa definição evita restringir a discussão à fabricação de componentes elétricos e permite reunir aplicações que compartilham problemas de confiabilidade, eficiência, operação e gestão de ativos, embora ocorram em ambientes distintos.

2 METODOLOGIA

A pesquisa foi conduzida como revisão bibliográfica qualitativa e exploratória. O levantamento contemplou artigos científicos relacionados à inteligência artificial na indústria e na Engenharia Elétrica, com buscas em bases científicas e acadêmicas por combinações de termos como “Inteligência Artificial”, “Engenharia Elétrica”, “Machine Learning”, “Deep Learning”, “automação industrial”, “manutenção preditiva”, “smart grid” e “sistemas elétricos”. O intervalo inicialmente previsto foi de 2016 a 2026, com prioridade para aplicações e estudos relacionados ao contexto brasileiro. O artigo preservou uma publicação de 2017 por sua pertinência à previsão de geração eólica no Nordeste. Como o documento-base não registra os nomes das bases consultadas, as strings completas, as datas de cada busca nem o número de registros recuperados e excluídos, esses dados não foram reconstruídos por suposição. Consequentemente, o procedimento não é caracterizado como revisão sistemática nem como levantamento integralmente reproduzível.

O corpus foi formado em duas etapas documentadas: uma seleção inicial de 33 trabalhos e uma ampliação posterior de 14 publicações, totalizando 47 estudos. A classificação final reuniu

22 trabalhos originais, empíricos ou propositivos e 25 revisões ou análises. Os critérios de pertinência considerados foram a relação direta com aplicações de IA em sistemas elétricos ou industriais, a contribuição para ao menos um objetivo da pesquisa e a disponibilidade de informações sobre aplicação, técnica, resultado ou limitação. A seleção, portanto, deve ser entendida como amostra bibliográfica temática, e não como amostragem probabilística ou exaustiva.

A leitura e a síntese foram organizadas por aplicação, origem e natureza da evidência. Para cada publicação, foram considerados, quando informados, o equipamento ou sistema, a tarefa (classificação, diagnóstico, previsão ou apoio à decisão), a técnica computacional, a natureza dos dados, os indicadores reportados e as limitações declaradas. A classificação temática foi feita pelo autor, atribuindo cada trabalho ao segmento predominante para evitar dupla contagem na Tabela 1. Resultados numéricos foram mantidos como reportados pelas fontes e interpretados em seu contexto; não foram recalculados nem comparados como se derivassem de bases e protocolos equivalentes. Parte das 14 fontes adicionadas na etapa de aprofundamento foi examinada por resumos e registros bibliográficos, e não por leitura integral, o que restringe o nível de inferência possível.

3 REVISÃO DA LITERATURA

A IA reúne métodos computacionais voltados à percepção, classificação, previsão e apoio à decisão. No recorte desta revisão, destacam-se o aprendizado supervisionado, que utiliza exemplos rotulados para estimar classes ou valores; o não supervisionado, que procura estruturas em dados sem rótulos prévios; e o aprendizado por reforço, no qual decisões sequenciais são ajustadas a partir de recompensas. A escolha não deve começar pelo algoritmo, mas pela formulação do problema, pelo tipo de saída necessário e pelas consequências de um erro. Em sistemas energéticos, essa distinção é decisiva porque prever uma grandeza, reconhecer uma falha e recomendar uma ação são tarefas diferentes (PERERA; KAMALARUBAN, 2021; SURUCU; GADSDEN; YAWNEY, 2023).

A literatura reúne redes neurais artificiais, árvores e ensembles, máquinas de vetores de suporte e arquiteturas convolucionais ou recorrentes. LSTM e GRU são utilizadas para explorar dependências temporais; CNNs podem extrair padrões locais de sinais; e modelos baseados em

árvores constituem alternativas em dados tabulares. Estudos de previsão e diagnóstico, entretanto, mostram que modelos estatísticos e técnicas mais simples continuam pertinentes quando os dados são limitados ou apresentam sazonalidade bem definida. A complexidade computacional, o custo de treinamento, a estabilidade e a interpretabilidade devem ser considerados juntamente com o desempenho (YANG et al., 2021; GONÇALVES, 2025; JANG; KIM; KIM, 2024).

A seleção do método deve partir da pergunta técnica. Modelos de regressão estimam grandezas contínuas, classificadores atribuem categorias, técnicas de agrupamento organizam observações sem rótulos e métodos de detecção de anomalias identificam desvios em relação ao comportamento esperado. Redes recorrentes e arquiteturas convolucionais podem explorar dependências temporais ou padrões locais, enquanto métodos baseados em árvores oferecem alternativas úteis em dados tabulares. Não há algoritmo superior em todas as situações: complexidade, quantidade de dados, custo computacional, possibilidade de explicação e facilidade de manutenção também integram a decisão.

A qualidade dos dados é central para o desempenho: falhas raras produzem desbalanceamento de classes, enquanto ruído, valores ausentes, diferenças de resolução e vazamento de dados podem comprometer a avaliação. Resultados de classificação devem considerar precisão, revocação e F1-score, e previsões devem utilizar métricas compatíveis com a escala e o horizonte de interesse (LOPES; FLAUZINO; ALTAFIM, 2021; SURUCU; GADSDEN; YAWNEY, 2023).

O processo de preparação dos dados é parte substantiva do desenvolvimento. Registros podem conter lacunas, ruído, valores fora de escala, diferentes taxas de amostragem ou mudanças de configuração dos sensores. A normalização e a seleção de atributos precisam ser realizadas de modo consistente entre treinamento e aplicação. Também é necessário evitar o vazamento de dados, situação em que informações do conjunto de teste influenciam o treinamento ou a escolha do modelo e produzem estimativas artificialmente otimistas. Em séries temporais, a divisão aleatória pode ser inadequada; a separação cronológica tende a representar melhor a aplicação futura.

Em ativos elétricos, a manutenção preditiva articula aquisição de sinais, avaliação de condição, identificação de padrões e planejamento de intervenção. Em transformadores, a análise de gases dissolvidos (DGA) oferece indicadores de processos internos e pode ser combinada a

classificadores; em motores, sinais de corrente, vibração, temperatura e velocidade contribuem para reconhecer alterações; e, em turbinas hidráulicas, medições de vibração e variáveis de operação permitem investigar condições como cavitação. A IA amplia a capacidade de relacionar variáveis, mas a interpretação deve permanecer vinculada aos princípios físicos e aos procedimentos de manutenção (WANI et al., 2021; ALI et al., 2023; ACIKGOZ; SAZLI; KOSALAY, 2025; PEREIRA JUNIOR et al., 2023; GONZALEZ-JIMENEZ et al., 2021; SOUZA et al., 2024).

A passagem do diagnóstico para o prognóstico representa uma diferença importante. Diagnosticar significa reconhecer ou classificar uma condição presente; prognosticar envolve estimar sua evolução ou o tempo até que determinado limite seja atingido. A segunda tarefa requer dados longitudinais e definição explícita do que se considera degradação ou falha. Quando essas informações não estão disponíveis, o modelo pode ser útil para detectar anomalias, mas não deve ser apresentado como capaz de prever com precisão a vida útil restante do equipamento.

No planejamento e na operação, as aplicações incluem previsão de carga e geração renovável, classificação de eventos, apoio à proteção, estimação de indicadores de segurança e gerenciamento de recursos energéticos distribuídos. A digitalização de redes amplia a observabilidade, mas também torna a operação mais dependente de interoperabilidade, integridade dos dados e segurança. Revisões sobre redes inteligentes e proteção mostram que o desempenho algorítmico precisa ser avaliado em relação à função operacional, ao tempo de resposta e às consequências dos erros (ALMEIDA; SCHUMACHER; AOKI, 2022; GOUDARZI et al., 2022; PORAWAGAMAGE et al., 2024; SOUZA; FERREIRA; NETO, 2022).

Nas redes inteligentes, técnicas de IA podem apoiar previsão de demanda, identificação de padrões de consumo, análise de perdas, coordenação de recursos distribuídos e detecção de anomalias. A integração de medidores, sensores, sistemas supervisórios e comunicação favorece maior observabilidade, mas exige interoperabilidade e consistência dos registros. No tema das perdas não técnicas, estudos brasileiros investigaram identificação de clientes suspeitos de fraude por aprendizado de máquina e testes estatísticos; tais resultados devem ser considerados apoio à priorização de inspeções, não comprovação automática de irregularidade, pois decisões afetam consumidores e demandam evidência e procedimento regulatório (RIBEIRO; MARTINEZ, 2023; SAU et al., 2023).

4 RESULTADOS E DISCUSSÃO

4.1 Distribuição temática dos estudos

Tabela 1 – Distribuição dos 47 estudos por segmento de aplicação

Segmento de aplicação	Estudos	Participação
Manutenção e diagnóstico	14	29,8%
Previsão de carga e geração	12	25,5%
Operação, proteção e segurança	5	10,6%
Redes inteligentes e distribuição	5	10,6%
Sistemas fotovoltaicos	1	2,1%
Cibersegurança	3	6,4%
Panorama e temas transversais	7	14,9%
Total	47	100%

Fonte: Elaborado pelos autores (2026).

Os resultados mostram que manutenção e diagnóstico e previsão de carga e geração concentram 26 estudos, correspondentes a aproximadamente 55,3% do conjunto. Essa proporção descreve a amostra bibliográfica construída, sem permitir inferir a distribuição da pesquisa científica mundial. A ampliação de 33 para 47 estudos também acrescentou evidências sobre transformadores, classificação de eventos, explicabilidade e perdas não técnicas.

A distribuição temática permite observar também uma assimetria entre áreas. Embora a manutenção e a previsão concentrem maior quantidade de registros, temas como proteção, redes inteligentes, cibersegurança e aplicações fotovoltaicas aparecem em menor número na amostra. Essa diferença deve ser entendida como característica do levantamento e dos critérios de seleção, não como prova de menor relevância tecnológica dessas áreas. Além disso, estudos de revisão e trabalhos experimentais cumprem funções distintas: os primeiros sintetizam tendências e lacunas; os segundos demonstram resultados em condições e bases delimitadas.

4.2 Manutenção preditiva e diagnóstico de equipamentos

No monitoramento de turbinas Francis, Souza et al. (2024) investigaram modelos de aprendizado de máquina para manutenção preditiva e distinção entre estados cavitante e não cavitante, reportando precisão de 95% a 100% nas condições experimentais descritas pelos autores. A referência correta para esse resultado é Souza et al. (2024), e não Gawde et al. (2023), cuja publicação é uma revisão sobre diagnóstico de máquinas rotativas. O indicador deve ser lido

como resultado localizado no experimento, não como garantia de desempenho em outras unidades, regimes hidráulicos ou condições de instrumentação.

Em motores elétricos, o monitoramento pode combinar corrente, tensão, temperatura, vibração e velocidade para reconhecer alterações associadas a desgaste, desequilíbrio ou condições anormais. O valor da abordagem está em relacionar sinais que, isoladamente, podem não ser conclusivos. Nas turbinas hidráulicas, sinais vibracionais e parâmetros de operação permitem investigar estados de cavitação e outras condições que afetam desempenho e integridade. A análise baseada em dados complementa inspeções, medições convencionais e conhecimento do equipamento, sem dispensar a confirmação técnica quando o diagnóstico implica intervenção.

Em transformadores, a literatura reúne abordagens convencionais de DGA e modelos de aprendizado de máquina. Lopes, Flauzino e Altafim (2021) investigaram modelos baseados em dados com sobreamostragem; Gifalli et al. (2024) empregaram redes neurais para reconhecer condições normais e falhas; Dladla e Thango (2025) avaliaram algoritmos otimizados; e Thavasilingam e Sivaraju (2026) estudaram diagnóstico com DGA reamostrada. Os valores reportados no corpus, por exemplo, 92,478% para k-vizinhos mais próximos em 282 amostras e 98,7% para uma configuração com SVM, pertencem a bases e protocolos diferentes. Não constituem comparação controlada e não autorizam concluir que um método seja universalmente superior (ALI et al., 2023; ACIKGOZ; SAZLI; KOSALAY, 2025).

Esses resultados devem ser interpretados com cautela: acurácia elevada em uma base específica não equivale automaticamente a desempenho em campo. O tamanho e a composição das amostras, a proporção de falhas, a forma de divisão entre treino e teste e a representatividade dos dados influenciam os indicadores. Em equipamentos de potência, a ocorrência de falhas é relativamente rara, de modo que a capacidade de detectar a classe minoritária e o custo de alarmes indevidos são tão importantes quanto a taxa global de acertos. A validação deve contemplar diferentes condições de operação e, quando possível, dados independentes do conjunto usado no desenvolvimento.

4.3 Previsão de carga e geração renovável

Os estudos de previsão trabalham com horizontes e variáveis explicativas distintos. Hammerschmitt et al. (2022) abordaram previsão de carga de longo prazo; Soares (2021) estudou

arquitetura BiGRU-CNN para demanda de curto prazo; Gonçalves (2025) comparou ARIMA e LSTM no consumo da região Sudeste; e Jang, Kim e Kim (2024) analisaram técnicas profundas simples e híbridas. Revisões de Akhtar et al. (2023) e Waheed e Xu (2024) destacam desafios relacionados à seleção de variáveis, sazonalidade, horizonte e avaliação. O método deve ser confrontado com uma linha de base adequada e escolhido segundo a finalidade da previsão, e não apenas pela arquitetura mais recente.

A previsão de carga também precisa distinguir horizonte e uso. Estimativas de curto prazo apoiam programação diária, operação e resposta à demanda; previsões de médio e longo prazo subsidiam planejamento de expansão, contratação e avaliação de cenários. O comportamento da demanda é afetado por calendário, temperatura, atividade econômica, perfil dos consumidores e mudanças tecnológicas. Modelos que incorporam essas variáveis podem capturar relações complexas, mas exigem séries históricas consistentes e validação temporal, isto é, treinamento em períodos anteriores e avaliação em períodos posteriores para evitar que informações futuras contaminem o teste.

Na geração eólica, Camelo, Lucio e Leal Junior (2017) compararam ARIMA, Holt-Winters e redes neurais no Nordeste brasileiro; Oliveira e Santos (2023) examinaram redes neurais para previsão de geração; e revisões de Wang et al. (2021), Benti, Chaka e Semie (2023) e Valdivia-Bautista et al. (2023) sintetizaram abordagens com redes profundas e IA. Para geração fotovoltaica, Wu, Huang, Phan e Li (2022) organizaram técnicas de previsão sob diferentes perspectivas, enquanto Maia (2024) investigou diagnóstico inteligente de falhas em sistemas fotovoltaicos. Diferenças de localização, clima, período, resolução e métrica impedem um ranking geral dos métodos.

A previsão de geração renovável apresenta desafios adicionais porque a produção depende de variáveis meteorológicas, sazonalidade, localização e características do equipamento. Para a fonte eólica, a velocidade do vento não se converte linearmente em potência em toda a faixa operacional: limites de partida, potência nominal e desligamento por segurança alteram a relação. Na geração fotovoltaica, irradiância, temperatura, sombreamento e condições dos módulos influenciam o resultado. Assim, previsões devem ser avaliadas considerando o horizonte, a resolução temporal e a finalidade operacional, e não apenas um indicador agregado de erro.

4.4 Operação, proteção, redes inteligentes e cibersegurança

Aplicações em operação e proteção incluem classificação de eventos, análise de dados sincrofasoriais e estimação de indicadores de segurança. Santos et al. (2022) analisaram um classificador DNN para eventos de sistemas de potência com método de interpretabilidade; Almeida, Schumacher e Aoki (2022) propuseram apoio à operação por identificação de sistemas e aprendizado de máquina; e Souza, Ferreira e Neto (2022) investigaram estimação de indicadores de segurança estática e dinâmica. Em funções críticas, acurácia agregada é insuficiente: falsos alarmes, falhas de detecção, latência e comportamento em situações raras também precisam ser avaliados.

A interpretabilidade constitui outra dimensão relevante neste domínio. Técnicas como SHAP podem indicar quais variáveis contribuíram para determinada classificação, permitindo confrontar a explicação do modelo com o conhecimento físico do sistema. Essa análise não prova, por si só, causalidade nem garante que o algoritmo esteja correto; funciona como instrumento de inspeção, identificação de comportamento inesperado e apoio à discussão entre especialistas. Em proteção e operação, a explicação deve ser acompanhada de testes em cenários representativos e da avaliação dos efeitos de falsos positivos e falsos negativos.

A digitalização das redes amplia a exposição a riscos cibernéticos, incluindo ameaças à confidencialidade, integridade e disponibilidade de dados e serviços. Berghout, Benbouzid e Muyeen (2022) e Ding et al. (2022) discutem taxonomias e mecanismos de defesa para smart grids; Paula (2022) propôs arquitetura de automação adaptada para enfrentar ataques. A proteção deve envolver segmentação de redes, controle de acesso, atualizações, registro de eventos, avaliação de fornecedores e planos de contingência. Tais medidas reduzem riscos, mas não eliminam vulnerabilidades nem substituem a validação de segurança das aplicações de IA.

Do ponto de vista organizacional, a proteção cibernética deve ser tratada desde o desenho da solução. A conexão de sensores, gateways, plataformas de análise e sistemas de controle cria novas interfaces e possíveis pontos de entrada. A segmentação de redes, o controle de acesso, a atualização de componentes, o registro de eventos e a avaliação de fornecedores reduzem a exposição, mas não eliminam o risco. Em aplicações críticas, recomenda-se que a saída algorítmica seja submetida a regras de segurança e validação independente, evitando que uma classificação incorreta se converta diretamente em comando de controle sem salvaguardas.

4.5 Limitações de aplicabilidade e competências profissionais

Tabela 2 – Condições de aplicabilidade da IA em sistemas elétricos

Dimensão	Implicação para implantação
Dados e instrumentação	Verificar representatividade, integridade, calibração e sincronismo das medições.
Validação	Evitar vazamento de dados; comparar com métodos convencionais e testar em condições reais.
Interpretabilidade	Exigir saídas auditáveis e coerentes com os fenômenos físicos.
Segurança cibernética	Avaliar ameaças à infraestrutura, aos dados e ao próprio modelo.
Viabilidade econômica	Estimar custo total e benefícios operacionais antes da expansão.
Capacitação	Integrar fundamentos elétricos, análise de dados e avaliação crítica dos modelos.

Fonte: Elaborado pelos autores (2026).

A síntese indica que a viabilidade depende de fatores anteriores e posteriores ao treinamento: instrumentação, representatividade dos dados, integração com sistemas existentes, validação, explicabilidade, proteção cibernética e custo total. A IA generativa e os modelos de linguagem também aparecem como possibilidades de apoio à consulta técnica, documentação e análise, mas as revisões de Ghafari et al. (2025) e Majumder et al. (2024) apontam limitações de confiabilidade, contextualização e segurança, recomendando supervisão humana e restrição de uso em decisões operacionais críticas. No plano profissional, ampliam-se as competências em programação, análise de dados, instrumentação, avaliação crítica e comunicação interdisciplinar, sem deslocar a responsabilidade técnica do engenheiro.

A adoção responsável também pressupõe monitoramento após a implantação. Mudanças no regime de operação, no equipamento, no ambiente ou nos sensores podem alterar a distribuição dos dados e reduzir a confiabilidade do modelo. Por isso, indicadores de desempenho devem ser acompanhados ao longo do tempo, com critérios definidos para reavaliação, retreinamento, retorno ao procedimento convencional e registro das decisões. A solução não se encerra na obtenção de uma métrica satisfatória durante o desenvolvimento: sua utilidade depende de permanecer válida no contexto real de operação.

Uma implantação gradual: diagnóstico de ativos e dados; seleção de caso de uso; definição de linha de base; desenvolvimento de piloto; operação assistida; validação antes da expansão; e governança contínua. Esse roteiro constitui uma proposta de organização derivada da análise bibliográfica, não um protocolo experimental testado pelo artigo. Para evitar adoção baseada apenas em demonstrações, cada etapa deve prever critérios de sucesso, responsáveis, riscos, custos e condições de interrupção ou retorno ao procedimento convencional.

As lacunas também se distribuem por aplicação. A revisão identificou oportunidades para bases abertas e padronizadas de falhas, validação externa e longitudinal, comparação de modelos em condições equivalentes, explicabilidade orientada ao domínio e avaliação econômica do ciclo de vida. Para o contexto brasileiro, são relevantes estudos sobre perdas não técnicas, microrredes e sistemas isolados, inclusive em regiões com restrições de infraestrutura e acesso. Essas agendas decorrem da leitura do conjunto e devem ser entendidas como recomendações, não como resultados empíricos adicionais.

Esse roteiro pode ser compreendido como um ciclo de melhoria contínua, e não como uma implantação única. Na etapa de diagnóstico, a equipe identifica ativos críticos, histórico de ocorrências, sensores disponíveis e sistemas que armazenam registros. A priorização deve considerar a consequência da falha, a frequência de ocorrência, a possibilidade de medir o fenômeno e a existência de uma decisão operacional que possa ser apoiada pelo modelo. O piloto, por sua vez, precisa ser comparado a uma linha de base por exemplo, procedimento convencional, regra de alarme ou método estatístico já utilizado para que o ganho atribuído à IA seja demonstrado e não apenas presumido.

5 CONCLUSÃO

A revisão bibliográfica permitiu identificar aplicações da inteligência artificial em manutenção e diagnóstico de equipamentos, previsão de carga e geração, operação e proteção de sistemas elétricos, redes inteligentes e cibersegurança. No conjunto de 47 estudos reunidos, manutenção e diagnóstico (14) e previsão de carga e geração (12) representaram aproximadamente 55,3% das publicações classificadas, indicando concentração temática dentro do material analisado.

A análise comparativa mostrou que não existe técnica de aprendizado de máquina universalmente superior. Os resultados dependem da natureza do problema, das bases utilizadas, da qualidade da instrumentação, das métricas e dos procedimentos de validação. Evidências favoráveis a algoritmos específicos devem ser interpretadas nas condições dos estudos originais, especialmente quando os resultados não são diretamente comparáveis.

O levantamento apresenta limitações: não foi sistemático, não registrou integralmente bases, strings, datas e fluxo de seleção, reuniu estudos heterogêneos e utilizou resumos ou registros bibliográficos para parte das publicações adicionais. Essas restrições reduzem a reprodutibilidade e a profundidade de algumas comparações. Pesquisas futuras devem registrar protocolo de busca, ampliar leitura integral, disponibilizar critérios e dados de extração e conduzir avaliações de campo, custo-benefício e monitoramento longitudinal.

Conclui-se que a IA pode transformar dados operacionais em informação útil à engenharia, desde que integrada ao conhecimento físico, à qualidade dos dados, à validação e à governança. Sua contribuição é complementar: apoia análise e priorização, mas não substitui a decisão fundamentada nem a responsabilidade profissional.

Em síntese, a contribuição prática da IA não reside somente na automatização de tarefas, mas na capacidade de transformar dados operacionais em informação útil, verificável e integrada à decisão. Para que essa contribuição se concretize, é necessário articular conhecimento do sistema elétrico, qualidade de dados, avaliação metodológica, governança e responsabilidade profissional. A agenda de pesquisa inclui bases mais representativas, validação em ambientes reais, comparação transparente de métodos e estudos de custo-benefício que considerem o ciclo de vida da solução.

REFERÊNCIAS

ACIKGOZ, Nurullah; SAZLI, Murat Husnu; KOSALAY, Ilhan. A comprehensive review of transformer fault diagnosis studies based on dissolved gas analysis: classical methods, historical development of the devices used, artificial intelligence based methods, accuracy of classifications of predictions. Elektronika ir Elektrotechnika, v. 31, n. 3, 2025. Disponível em: https://eejournal.ktu.lt/index.php/elt/article/view/39824. Acesso em: 28 set. 2026.

AHMAD, T.; ZHANG, D.; HUANG, C.; ZHANG, H.; DAI, N.; SONG, Y.; CHEN, H. Artificial intelligence in sustainable energy industry: status quo, challenges and opportunities. Journal of

Cleaner Production, v. 289, art. 125834, 2021. DOI: 10.1016/j.jclepro.2021.125834. Acesso em: 28 set. 2026.

AKHTAR, Saima; SHAHZAD, Sulman; ZAHEER, Asad; ULLAH, Hafiz Sami; KILIC, Heybet; GONO, Radomir; JASIŃSKI, Michał; LEONOWICZ, Zbigniew. Short-term load forecasting models: a review of challenges, progress, and the road ahead. Energies, v. 16, n. 10, art. 4060, 2023. DOI: 10.3390/en16104060. Acesso em: 28 set. 2026.

ALI, Mohd Syukri; BAKAR, Ab Halim Abu; OMAR, Azimah; JAAFAR, Amirul Syafiq Abdul; MOHAMED, Siti Hajar. Conventional methods of dissolved gas analysis using oil-immersed power transformer for fault diagnosis: a review. Electric Power Systems Research, v. 216, art. 109064, 2023. DOI: 10.1016/j.epsr.2022.109064. Acesso em: 28 set. 2026.

ALMEIDA, Ricardo R.; SCHUMACHER, Ricardo; AOKI, Alexandre R. Metodologia de apoio à operação de sistemas elétricos de potência baseada em identificação de sistemas com aprendizado de máquina. Simpósio Brasileiro de Sistemas Elétricos - SBSE, v. 2, n. 1, 2022. DOI: 10.20906/sbse.v2i1.2929. Disponível em: https://ojs.sba.org.br/index.php/sbse/article/view/2929. Acesso em: 12 set. 2026.

BENTI, Natei Ermias; CHAKA, Mesfin Diro; SEMIE, Addisu Gezahegn. Forecasting renewable energy generation with machine learning and deep learning: current advances and future prospects. Sustainability, v. 15, n. 9, art. 7087, 2023. DOI: 10.3390/su15097087. Acesso em: 28 set. 2026.

BERGHOUT, Tarek; BENBOUZID, Mohamed; MUYEEN, S. M. Machine learning for cybersecurity in smart grids: a comprehensive review-based study on methods, solutions, and prospects. International Journal of Critical Infrastructure Protection, v. 38, art. 100547, 2022. DOI: 10.1016/j.ijcip.2022.100547. Acesso em: 28 set. 2026.

CAMELO, Henrique do Nascimento; LUCIO, Paulo Sérgio; LEAL JUNIOR, João Verçosa. Modelagem da velocidade do vento usando metodologias ARIMA, Holt- Winters e RNA na previsão de geração eólica no Nordeste brasileiro. Revista Brasileira de Climatologia, v. 21, 2017. DOI: 10.5380/abclima.v21i0.48565. Disponível em: https://revistas.ufpr.br/revistaabclima/article/view/48565. Acesso em: 22 set. 2026.

CASTRO, Nivalde de; MASSENO LEAL, Luiza; BRITO, Kalyne. Inteligência artificial no futuro do setor elétrico. Rio de Janeiro: GESEL-UFRJ, 2025. Disponível em: https://gesel.ie.ufrj.br/publicacao/inteligencia-artificial-no-futuro-do-setor-eletrico/. Acesso em: 18 set. 2026.

DING, Jianguo; QAMMAR, Attia; ZHANG, Zhimin; KARIM, Ahmad; NING, Huansheng. Cyber threats to smart grids: review, taxonomy, potential solutions, and future directions. Energies, v. 15, n. 18, art. 6799, 2022. DOI: 10.3390/en15186799. Acesso em: 28 set. 2026.

DLADLA, Vuyani M. N.; THANGO, Bonginkosi A. Fault classification in power transformers using dissolved gas analysis and optimized machine learning algorithms. Machines, v. 13, n. 8, art. 742, 2025. DOI: 10.3390/machines13080742. Acesso em: 28 set. 2026.

EL RHATRIF, Abderrahmane; BOUIHI, Bouchra; MESTARI, Mohammed. Challenges and limitations of artificial intelligence implementation in modern power grid. Procedia Computer Science, v. 236, p. 83-92, 2024. DOI: 10.1016/j.procs.2024.05.008. Acesso em: 10 set. 2026.

GAWDE, Shreyas; PATIL, Shruti; KUMAR, Satish; KAMAT, Pooja; KOTECHA, Ketan; ABRAHAM, Ajith. Multi-fault diagnosis of industrial rotating machines using data-driven approach: a review of two decades of research. Engineering Applications of Artificial Intelligence, v. 123, art. 106139, 2023. DOI: 10.1016/j.engappai.2023.106139. Acesso em: 16 set. 2026.

GHAFARI, M. et al. A comprehensive review on the application of large language models (LLMs) in power systems. IEEE Access, v. 13, p. 209450-209486, 2025. DOI: 10.1109/ACCESS.2025.3637226. Acesso em: 28 set. 2026.

GIFALLI, André; BONINI NETO, Alfredo; SOUZA, André Nunes de; MELLO, Renan Pinal de; IKESHOJI, Marco Akio; GARBELINI, Enio; NETO, Floriano Torres. Fault detection and normal operating condition in power transformers via pattern recognition artificial neural network. Applied System Innovation, v. 7, n. 3, art. 41, 2024. DOI: 10.3390/asi7030041. Acesso em: 28 set. 2026.

GONÇALVES, Iago Gomes. Previsão do consumo de energia elétrica na região Sudeste: aplicação de modelos ARIMA e LSTM. Revista Brasileira de Estudos Regionais e Urbanos, v. 19, n. 3, p. 310-340, 2025. DOI: 10.54766/rberu.v19i3.1158. Disponível em: https://revistaaber.org.br/rberu/article/view/1158. Acesso em: 20 set. 2026.

GONZALEZ-JIMENEZ, David; DEL-OLMO, Jon; POZA, Javier; GARRAMIOLA, Fernando; SARASOLA, Izaskun. Machine learning-based fault detection and diagnosis of faulty power connections of induction machines. Energies, v. 14, n. 16, art. 4886, 2021. DOI: 10.3390/en14164886. Acesso em: 28 set. 2026.

GOUDARZI, A.; GHAYOOR, F.; WASEEM, M.; FAHAD, S.; TRAORE, I. A survey on IoT-enabled smart grids: emerging, applications, challenges, and outlook. Energies, v. 15, n. 19, art. 6984, 2022. DOI: 10.3390/en15196984. Acesso em: 28 set. 2026.

HAMMERSCHMITT, Bruno K.; LUCCHESE, Felipe C.; GUARDA, Fernando G. K.; ABAIDE, Alzenira R. Modelo regressivo e inteligência artificial para previsão de carga no longo prazo: um estudo de caso. Simpósio Brasileiro de Sistemas Elétricos - SBSE, v. 2, n. 1, 2022. DOI: 10.20906/sbse.v2i1.2911. Disponível em: https://www.ojs.sba.org.br/index.php/sbse/article/view/2911. Acesso em: 19 set. 2026.

JANG, Jiyeon; KIM, Beopsoo; KIM, Insu. Comparative analysis of deep learning techniques for load forecasting in power systems using single-layer and hybrid models. International Transactions on Electrical Energy Systems, v. 2024, art. 5587728, 2024. DOI: 10.1155/2024/5587728. Acesso em: 17 set. 2026.

LOPES, Sofia Moreira de Andrade; FLAUZINO, Rogério Andrade; ALTAFIM, Ruy Alberto Corrêa. Incipient fault diagnosis in power transformers by data-driven models with over-sampled dataset. Electric Power Systems Research, v. 201, art. 107519, 2021. DOI: 10.1016/j.epsr.2021.107519. Disponível em: https://www.sciencedirect.com/science/article/pii/S0378779621005009. Acesso em: 16 set. 2026.

MACHLEV, Ram; HEISTRENE, L.; PERL, M.; LEVY, K. Y.; BELIKOV, Juri; MANNOR, S.; LEVRON, Yoash. Explainable artificial intelligence (XAI) techniques for energy and power systems: review, challenges and opportunities. Energy and AI, v. 9, art. 100169, 2022a. DOI: 10.1016/j.egyai.2022.100169. Acesso em: 28 set. 2026.

MACHLEV, Ram; PERL, Michael; BELIKOV, Juri; LEVY, Kfir Yehuda; LEVRON, Yoash. Measuring explainability and trustworthiness of power quality disturbances classifiers using XAI: explainable artificial intelligence. IEEE Transactions on Industrial Informatics, v. 18, n. 8, p. 5127-5137, 2022b. DOI: 10.1109/TII.2021.3126111. Acesso em: 28 set. 2026.

MAIA, Amanda Costa. Estratégia de diagnóstico inteligente de falhas para sistemas fotovoltaicos de alta potência. 2024. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pampa, Alegrete, 2024. Disponível em: https://dspace.unipampa.edu.br/jspui/handle/riu/9715. Acesso em: 13 set. 2026.

MAJUMDER, Subir; DONG, Lin; DOUDI, Fatemeh; CAI, Yuting; TIAN, Chao; KALATHIL, Dileep; DING, Kevin; THATTE, Anupam A.; LI, Na; XIE, Le. Exploring the capabilities and limitations of large language models in the electric energy sector. Joule, v. 8, n. 6, p. 1544-1549, 2024. DOI: 10.1016/j.joule.2024.05.009. Acesso em: 28 set. 2026.

MOLĘDA, Marek; MAŁYSIAK-MROZEK, Bożena; DING, Weiping; SUNDERAM, Vaidy; MROZEK, Dariusz. From corrective to predictive maintenance: a review of maintenance approaches for the power industry. Sensors, v. 23, n. 13, art. 5970, 2023. DOI: 10.3390/s23135970. Acesso em: 25 set. 2026.

OLIVEIRA, Leandro de; SANTOS, José Airton Azevedo dos. Um estudo comparativo da aplicação de redes neurais artificiais na previsão de geração eólica. Revista Cereus, v. 15, n. 1, p. 105-119, 2023. DOI: 10.18605/2175-7275/cereus.v15n1p105- 119. Disponível em: https://www.ojs.unirg.edu.br/index.php/1/article/view/4067. Acesso em: 14 set. 2026.

PAULA, Alexandro de Oliveira. Uma arquitetura de automação adaptada para Smart Grids contra ataques cibernéticos. 2022. 78 f. Dissertação (Mestrado Profissional em Engenharia Elétrica) – Universidade de Brasília, Brasília, 2022. Disponível em: https://repositorio.unb.br/handle/10482/44132. Acesso em: 10 set. 2026.

PEREIRA JUNIOR, Milton Carlos Soares et al. Estudo da aplicação de algoritmos de machine learning na manutenção preditiva de motores elétricos. Revista de Gestão e Secretariado, São Paulo, v. 14, n. 10, p. 16542-16561, 2023. DOI: 10.7769/gesec.v14i10.2754. Disponível em: https://ojs.revistagesec.org.br/secretariado/article/view/2754. Acesso em: 12 set. 2026.

PERERA, A. T. D.; KAMALARUBAN, Parameswaran. Applications of reinforcement learning in energy systems. Renewable and Sustainable Energy Reviews, v. 137, art. 110618, 2021. DOI: 10.1016/j.rser.2020.110618. Acesso em: 28 set. 2026.

PORAWAGAMAGE, Gayashan; DHARMAPALA, Kalana; CHAVES, J. Sebastian; VILLEGAS, Daniel; RAJAPAKSE, Athula. A review of machine learning applications in power system protection and emergency control: opportunities, challenges, and future directions. Frontiers in Smart Grids, v. 3, art. 1371153, 2024. DOI: 10.3389/frsgr.2024.1371153. Acesso em: 14 set. 2026.

RIBEIRO, Thiago de Almeida; MARTINEZ, Luciana. Utilização de técnicas de aprendizado de máquina para identificação de fraudes na distribuição de energia elétrica. Anais do SBAI-SBSE 2023, 2023. DOI: 10.20906/SBAI-SBSE-2023/3957. Disponível em: https://www.sba.org.br/open_journal_systems/index.php/sbai/article/view/3957. Acesso em: 28 set. 2026.

SANTOS, Orlem L. D.; DOTTA, Daniel; WANG, Meng; CHOW, Joe H.; DECKER, Ildemar C. Performance analysis of a DNN classifier for power system events using an interpretability

method. International Journal of Electrical Power & Energy Systems, v. 136, art. 107594, 2022. DOI: 10.1016/j.ijepes.2021.107594. Acesso em: 28 set. 2026.

SAU, Rodrigo F. G.; GARCIA, Tailan R.; TRINDADE, Fernanda C. L.; ALMEIDA, Madson C. de; VENKATESH, Bala. Identification and ranking of customers with energy theft using hypothesis tests. Electric Power Systems Research, v. 225, 2023. Disponível em: https://bv.fapesp.br/en/publicacao/274128. Acesso em: 28 set. 2026.

SILVA, Maycky Kennedy da. Aprendizado de máquina aplicado a sistemas de distribuição de energia: um estudo para auxiliar na gestão de manutenção do sistema. 2022. 69 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Pernambuco, Caruaru, 2022. Disponível em: https://repositorio.ufpe.br/handle/123456789/45407. Acesso em: 17 set. 2026.

SOARES, Lucas Duarte. Redes neurais artificiais BiGRU-CNN aplicadas à previsão de demanda de energia elétrica de curto prazo. 2021. 118 f. Dissertação (Mestrado em Engenharia Elétrica e Computação) – Universidade Estadual do Oeste do Paraná, Foz do Iguaçu, 2021. Disponível em: https://tede.unioeste.br/handle/tede/5712. Acesso em: 13 set. 2026.

SOUZA, Daniela C. R.; FERREIRA, Vitor H.; NETO, Carlos A. S. Aplicação de redes neurais artificiais para estimação de indicadores de segurança estática e dinâmica de sistemas elétricos de potência. Simpósio Brasileiro de Sistemas Elétricos - SBSE, v. 2, n. 1, 2022. DOI: 10.20906/sbse.v2i1.2960. Disponível em: https://ojs.sba.org.br/index.php/sbse/article/view/2960. Acesso em: 12 set. 2026.

SOUZA, Júlio César Silva de et al. Application of machine learning models in predictive maintenance of Francis hydraulic turbines. RBRH, Porto Alegre, v. 29, e48, 2024. DOI: 10.1590/2318-0331.292420240056. Disponível em: https://www.scielo.br/j/rbrh/a/jBsScJ6G4QYvxT5G5YJBvbz/. Acesso em: 11 set. 2026.

SURUCU, Onur; GADSDEN, Stephen Andrew; YAWNEY, John. Condition monitoring using machine learning: a review of theory, applications, and recent advances. Expert Systems with Applications, v. 221, art. 119738, 2023. DOI: 10.1016/j.eswa.2023.119738. Acesso em: 10 set. 2026.

THAVASILINGAM, Sudhakar; SIVARAJU, Selligoundanur Subramaniam. Fault diagnosis in power transformers using resampled dissolved gas analysis and machine learning. Revue Roumaine des Sciences Techniques - Électrotechnique et Énergétique, v. 71, n. 2, p. 247-252, 2026. DOI: 10.59277/RRST-EE.2026.2.13. Acesso em: 28 set. 2026.

VALDIVIA-BAUTISTA, Sandra Minerva; DOMÍNGUEZ-NAVARRO, José Antonio; PÉREZ-CISNEROS, Marco; VEGA-GÓMEZ, Carlos Jesahel; CASTILLO-TÉLLEZ, Beatriz. Artificial intelligence in wind speed forecasting: a review. Energies, v. 16, n. 5, art. 2457, 2023. DOI: 10.3390/en16052457. Acesso em: 28 set. 2026.

WAHEED, Waqar; XU, Qingshan. Data-driven short term load forecasting with deep neural networks: unlocking insights for sustainable energy management. Electric Power Systems Research, v. 232, art. 110376, 2024. DOI: 10.1016/j.epsr.2024.110376. Acesso em: 25 set. 2026.

WANG, Yun; ZOU, Runmin; LIU, Fang; ZHANG, Lingjun; LIU, Qianyi. A review of wind speed and wind power forecasting with deep neural networks. Applied Energy, v. 304, art. 117766, 2021. DOI: 10.1016/j.apenergy.2021.117766. Acesso em: 28 set. 2026.

WANI, Shufali Ashraf; RANA, Ankur Singh; SOHAIL, Shiraz; RAHMAN, Obaidur; PARVEEN, Shaheen; KHAN, Shakeb A. Advances in DGA based condition monitoring of transformers: a review. Renewable and Sustainable Energy Reviews, v. 149, art. 111347, 2021. DOI: 10.1016/j.rser.2021.111347. Acesso em: 28 set. 2026.

WU, Yuan-Kang; HUANG, Cheng-Liang; PHAN, Quoc-Thang; LI, Yuan-Yao. Completed review of various solar power forecasting techniques considering different viewpoints. Energies, v. 15, n. 9, art. 3320, 2022. DOI: 10.3390/en15093320. Acesso em: 28 set. 2026.

YANG, Yuanyuan; HAQUE, Md Muhie Menul; BAI, Dongling; TANG, Wei. Fault diagnosis of electric motors using deep learning algorithms and its application: a review. Energies, v. 14, n. 21, art. 7017, 2021. DOI: 10.3390/en14217017. Acesso em: 28 set. 2026.

ZAHRAOUI, Younes; KORÕTKO, Tarmo; ROSIN, Argo; MEKHILEF, Saad; SEYEDMAHMOUDIAN, Mehdi; STOJCEVSKI, Alex; ALHAMROUNI, Ibrahim. AI applications to enhance resilience in power systems and microgrids: a review. Sustainability, v. 16, n. 12, art. 4959, 2024. DOI: 10.3390/su16124959. Acesso em: 28 set. 2026.