

## APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE FALHAS EM REDES ELÉTRICAS

Lucas Silva Souza<sup>1</sup>  
Jaciara Carvalho de Sousa<sup>2</sup>  
Tonny Kerley de Alencar Rodrigues<sup>3</sup>

**RESUMO:** A crescente complexidade das redes elétricas modernas, aliada ao aumento da demanda energética e à integração de fontes renováveis, tem exigido soluções mais eficientes para garantir a confiabilidade e a continuidade do fornecimento de energia. Nesse contexto, a Inteligência Artificial (IA) surge como uma ferramenta promissora para a previsão e detecção antecipada de falhas em sistemas elétricos, permitindo uma atuação proativa e a redução de custos com manutenção corretiva. Este trabalho tem como objetivo aplicar técnicas de IA, especialmente algoritmos de aprendizado de máquina e redes neurais artificiais, na previsão de falhas em redes elétricas de distribuição. A pesquisa propõe a utilização de modelos preditivos baseados em dados históricos de operação e manutenção, visando identificar padrões e anomalias que antecedem falhas. A metodologia envolve o levantamento de dados operacionais, o pré-processamento das informações, a modelagem de algoritmos e a avaliação de desempenho dos modelos. Espera-se demonstrar que o uso da IA pode aumentar a precisão na previsão de falhas, contribuir para a manutenção preditiva e reduzir interrupções no fornecimento de energia elétrica. A inteligência artificial (IA) está transformando a engenharia elétrica, oferecendo novas ferramentas e tecnologias que aumentam a eficiência, a segurança e a inovação. Desde o design de sistemas elétricos até a manutenção e operação de redes inteligentes, a IA está permitindo avanços significativos no campo.

1184

**Palavras-chave:** Inteligência Artificial. Redes Elétricas. Previsão de Falhas. Aprendizado de Máquina. Manutenção Preditiva.

**ABSTRACT:** The growing complexity of modern electrical networks, combined with the increasing energy demand and the integration of renewable sources, requires more efficient solutions to ensure reliability and continuity of power supply. In this context, Artificial Intelligence (AI) emerges as a promising tool for predicting and detecting failures in electrical systems, allowing proactive actions and reducing corrective maintenance costs. This work aims to apply AI techniques, especially machine learning algorithms and artificial neural networks, to predict failures in electrical distribution networks. The research proposes the use of predictive models based on historical operational and maintenance data to identify patterns and anomalies preceding failures. The methodology involves collecting operational data, preprocessing information, modeling algorithms, and evaluating model performance. It is expected that AI can increase accuracy in failure prediction, contribute to predictive maintenance, and reduce interruptions in power supply.

**Keywords:** Artificial Intelligence. Electrical Networks. Fault Prediction. Machine Learning. Predictive Maintenance.

<sup>1</sup>Discente Centro Universitário Santo Agostinho.

<sup>2</sup>Prof Orientadora: Centro Universitário Santo Agostinho.

<sup>3</sup>Professor: Centro Universitário Santo Agostinho – UNIFSA.

## I. INTRODUÇÃO

A evolução tecnológica e o aumento contínuo da demanda por energia elétrica têm promovido transformações significativas na operação e no gerenciamento dos sistemas de potência. Segundo Kundur (1994), a crescente complexidade das redes elétricas modernas exige mecanismos mais robustos de controle, monitoramento e proteção para garantir sua estabilidade e confiabilidade. O avanço da geração distribuída, a inserção de fontes renováveis e o uso intensivo de cargas não lineares têm ampliado os desafios operacionais, resultando em redes mais dinâmicas e sujeitas a eventos imprevisíveis (Glover; Sarma; Overbye, 2012).

Nesse contexto, a Inteligência Artificial (IA) tem se destacado como uma das principais ferramentas para aprimorar o desempenho de sistemas elétricos. Para Haykin (2001), técnicas de IA são capazes de identificar padrões complexos em sistemas não lineares, o que as torna adequadas para aplicações envolvendo previsão de falhas, detecção de anomalias e manutenção preditiva.

A previsão de falhas em redes elétricas constitui uma das aplicações mais promissoras da IA. Tradicionalmente, o diagnóstico de falhas ocorre de forma reativa, ou seja, somente após a manifestação do problema. Segundo Phadke e Thorp (2009), tal abordagem gera consequências como interrupções no fornecimento, danos a equipamentos e custos elevados de manutenção corretiva. Com algoritmos inteligentes, entretanto, torna-se possível antecipar falhas e adotar estratégias preventivas, reduzindo significativamente impactos técnicos e econômicos (Santos; Lima, 2020).

1185

A previsão de falhas baseada em IA utiliza dados históricos, informações operacionais em tempo real e variáveis ambientais para identificar comportamentos anômalos em equipamentos e linhas de distribuição. Algoritmos de machine learning, redes neurais artificiais (RNA) e deep learning têm se mostrado particularmente eficientes nesse processo, pois conseguem modelar relações complexas entre tensões, correntes, temperatura, regime de carga e outros parâmetros do sistema (Goodfellow; Bengio; Courville, 2016; Kayikci; Yilmaz; Koc, 2021).

Com a expansão das smart grids e da Internet das Coisas (IoT), tornou-se possível a coleta de grandes volumes de dados operacionais, criando um ambiente favorável para o uso de algoritmos inteligentes na previsão de falhas. Conforme Fang et al. (2012), as redes inteligentes viabilizam monitoramento contínuo, comunicação bidirecional e análise avançada de dados,

permitindo que técnicas de IA detectem falhas iminentes em transformadores, linhas aéreas, bancos de capacitores e dispositivos de proteção.

Assim, este trabalho propõe investigar a aplicação de métodos de Inteligência Artificial na previsão de falhas em redes elétricas, com ênfase na identificação de padrões de anomalias e no desenvolvimento de modelos capazes de antecipar falhas críticas. Tal abordagem visa aumentar a confiabilidade operacional, reduzir custos de manutenção e otimizar o gerenciamento da rede, alinhando-se às tendências tecnológicas do setor elétrico contemporâneo.

### 1.1 Problema de Pesquisa

As redes de distribuição de energia elétrica enfrentam, cotidianamente, desafios relacionados à manutenção, ao monitoramento e à identificação de falhas. Os métodos convencionais, baseados em inspeções manuais e análises históricas simples, muitas vezes são ineficientes diante da complexidade e do volume de dados gerados pelos sistemas modernos.

Diante disso, surge o seguinte problema de pesquisa: Como a aplicação de técnicas de Inteligência Artificial pode contribuir para a previsão e detecção antecipada de falhas em redes elétricas, aumentando a confiabilidade e reduzindo os custos operacionais do sistema de distribuição de energia?

1186

### 1.2 Hipótese

A hipótese deste trabalho é que a utilização de técnicas de Inteligência Artificial, especialmente modelos de aprendizado de máquina supervisionado e redes neurais profundas, permite prever falhas em redes elétricas com maior precisão e antecedência do que métodos convencionais. Essa abordagem contribui para a redução do tempo de inatividade, otimização da manutenção preditiva e aumento da confiabilidade operacional.

### 1.3 Objetivos

#### 1.3.1 Objetivo Geral

Aplicar técnicas de Inteligência Artificial na previsão de falhas em redes elétricas, utilizando modelos de aprendizado de máquina para identificar padrões e anomalias nos dados operacionais, a fim de antecipar falhas e otimizar a manutenção preventiva.

### 1.3.2 Objetivos Específicos

- Analisar o estado atual das aplicações de IA no setor elétrico;
- Identificar as principais causas e tipos de falhas em redes de distribuição;
- Selecionar e testar algoritmos de aprendizado de máquina adequados para previsão de falhas;
- Avaliar a precisão e o desempenho dos modelos preditivos;
- Discutir a aplicabilidade prática da IA em sistemas reais de monitoramento elétrico.

### 1.4 Justificativa

A confiabilidade no fornecimento de energia elétrica é um fator essencial para o desenvolvimento econômico e social. Falhas não previstas em redes elétricas podem causar interrupções prolongadas, prejuízos financeiros e impactos negativos à sociedade.

Os métodos tradicionais de detecção de falhas, baseados em inspeções periódicas ou limites fixos de operação, mostram-se limitados diante da complexidade e do volume de informações disponíveis nos sistemas modernos. Nesse contexto, a Inteligência Artificial surge como uma solução promissora, capaz de processar grandes quantidades de dados e identificar padrões que precedem falhas com elevada precisão.

Além do aspecto técnico, o uso de IA contribui para a transformação digital do setor elétrico, alinhando-se às tendências de automação, smart grids e manutenção preditiva. Este estudo se justifica, portanto, pela necessidade de modernizar os mecanismos de monitoramento e controle das redes elétricas, tornando-as mais inteligentes, seguras e eficientes.

1187

## 2. FUNDAMENTAÇÃO TEÓRICA

A transformação digital do setor elétrico tem impulsionado o uso de tecnologias inteligentes para aumentar a confiabilidade e a eficiência das redes de distribuição de energia. Nesse contexto, a Inteligência Artificial (IA) tem se destacado como uma ferramenta essencial para auxiliar no monitoramento e na manutenção dos sistemas elétricos, especialmente na previsão de falhas e na detecção de anomalias operacionais.

### 2.1 Redes Elétricas de Distribuição

As redes de distribuição são responsáveis pelo transporte de energia elétrica desde os centros de transformação até os consumidores finais. Constituem o segmento mais extenso e

ramificado do sistema elétrico, e, por isso, estão mais suscetíveis a falhas provocadas por sobrecarga, desgaste de componentes, condições climáticas adversas e falhas humanas.

O desempenho dessas redes depende de fatores como a qualidade da energia, a disponibilidade dos equipamentos e a confiabilidade operacional. Com o aumento da demanda e a diversificação das fontes de energia, a necessidade de sistemas de monitoramento em tempo real tornou-se fundamental para evitar interrupções e reduzir custos de manutenção.

As principais causas de falhas em redes de distribuição incluem:

Sobrecarga de transformadores e linhas;

Curto-circuitos e falhas de isolamento;

Desgaste natural de componentes;

Oscilações de tensão e corrente;

Eventos climáticos (descargas atmosféricas, ventos, calor excessivo).

Essas falhas podem comprometer a estabilidade da rede e gerar prejuízos tanto técnicos quanto econômicos, reforçando a importância de sistemas automáticos de diagnóstico e previsão.

## 2.2 Tipos de Falhas em Redes Elétricas

As falhas em sistemas elétricos podem ser classificadas em temporárias, permanentes e incipientes.

**Falhas Temporárias:** causadas por eventos transitórios, como curtos de pequena duração ou descargas atmosféricas. Normalmente, o sistema se recupera automaticamente.

**Falhas Permanentes:** resultam em interrupções de longo prazo, exigindo intervenção manual ou substituição de componentes.

**Falhas Incipientes:** são falhas sutis que evoluem gradualmente. A sua identificação precoce é o principal foco das técnicas de previsão baseadas em Inteligência Artificial.

A detecção antecipada de falhas incipientes é essencial para a manutenção preditiva, pois permite planejar intervenções antes que ocorram falhas críticas.

## 2.3 Manutenção Preditiva e Sistemas Inteligentes

A manutenção preditiva consiste em prever o momento ideal para a manutenção de um equipamento, baseando-se em medições e análises de seu comportamento operacional. Diferente da manutenção corretiva, que ocorre após a falha, e da preventiva, que é realizada em intervalos fixos, a preditiva se apoia em dados reais de operação, reduzindo custos e aumentando a disponibilidade dos equipamentos.

Os sistemas modernos de manutenção preditiva utilizam sensores, dispositivos IoT (Internet das Coisas) e sistemas SCADA (Supervisory Control and Data Acquisition) para monitorar variáveis como temperatura, vibração, corrente e tensão. A integração desses sistemas com algoritmos de IA permite o diagnóstico automático de falhas e a previsão de degradação dos ativos elétricos.

#### 2.4 Inteligência Artificial (IA)

A Inteligência Artificial é um campo da ciência da computação que busca desenvolver sistemas capazes de aprender, raciocinar e tomar decisões com base em dados. No setor elétrico, a IA é aplicada na otimização de redes, previsão de demanda, controle de geração, diagnóstico de falhas e manutenção preditiva.

Entre as abordagens mais utilizadas destacam-se:

Aprendizado de Máquina (Machine Learning – ML);

Aprendizado Profundo (Deep Learning);

Lógica Fuzzy;

Redes Neurais Artificiais (RNA);

Sistemas Especialistas.

1189

Essas técnicas permitem que os modelos matemáticos aprendam padrões a partir de dados históricos e façam previsões com base em novas informações.

#### 2.5 Aprendizado de Máquina (Machine Learning)

O aprendizado de máquina é uma subárea da IA que possibilita que sistemas ajustem seus parâmetros automaticamente a partir de exemplos e experiências anteriores. Em vez de seguir regras fixas, o modelo “aprende” com os dados.

Os algoritmos de ML podem ser classificados em:

Supervisionados: utilizam dados rotulados (com resultados conhecidos), como Regressão Linear, SVM (Support Vector Machine) e Random Forest;

Não Supervisionados: detectam padrões em dados não rotulados, como Clustering e K-means;

Por Reforço: baseiam-se em recompensas e penalidades, buscando maximizar a eficiência de decisões.

No contexto das redes elétricas, o aprendizado supervisionado é amplamente utilizado para prever falhas em transformadores, disjuntores e linhas de distribuição, pois permite relacionar variáveis operacionais a eventos de falha conhecidos.

## 2.6 Redes Neurais Artificiais (RNA)

As redes neurais artificiais são modelos inspirados no funcionamento do cérebro humano, compostos por camadas de neurônios interconectados. São especialmente eficazes na identificação de padrões complexos e na modelagem de relações não lineares.

Aplicações típicas no setor elétrico incluem:

Diagnóstico de falhas incipientes em transformadores de potência;

Previsão de sobrecargas e picos de demanda;

Identificação de anomalias em sinais de corrente e tensão;

Estimativa de vida útil de equipamentos.

Entre os modelos mais comuns estão o Perceptron Multicamadas (MLP) e as Redes Neurais Convolucionais (CNNs). Mais recentemente, o uso de Redes Neurais Recorrentes (RNNs) e de suas variantes LSTM (Long Short-Term Memory) tem se mostrado eficiente na análise de séries temporais elétricas, por capturarem dependências de longo prazo entre os dados.

1190

## 2.7 Outras Técnicas de IA Aplicadas à Engenharia Elétrica

Além das RNAs e do aprendizado de máquina tradicional, outras técnicas de IA também vêm sendo empregadas na engenharia elétrica:

**Lógica Fuzzy:** utilizada para modelar incertezas e variáveis imprecisas, como níveis de carga e qualidade da energia;

**Árvores de Decisão e Random Forest:** amplamente usadas para classificação de tipos de falhas e avaliação de risco;

**Support Vector Machine (SVM):** eficiente para separação de classes de falhas com alto desempenho em pequenas bases de dados;

**Deep Learning:** permite o uso de múltiplas camadas de aprendizado para análise de dados complexos, como sinais oscilográficos e imagens térmicas.

## 2.8 Trabalhos Relacionados

Diversos estudos comprovam a eficácia da Inteligência Artificial na previsão de falhas em sistemas elétricos:

Almeida et al. (2021) aplicaram redes neurais artificiais na detecção de falhas em sistemas de potência, obtendo elevada acurácia e capacidade de generalização.

Kayikci et al. (2021) utilizaram técnicas de deep learning em redes inteligentes, demonstrando redução significativa no tempo de detecção de falhas.

Rajamani et al. (2022) mostraram que o uso de machine learning em sistemas de manutenção preditiva reduziu em até 35% o número de interrupções não programadas.

Santos e Lima (2020) realizaram uma revisão sistemática sobre IA em sistemas elétricos, destacando a evolução das ferramentas de aprendizado profundo para aplicações de previsão.

Essas pesquisas reforçam que a IA representa um avanço significativo na modernização das redes elétricas e na adoção de sistemas inteligentes de manutenção e diagnóstico.

## 2.9 Considerações Finais do Capítulo

A fundamentação teórica apresentada demonstra que a Inteligência Artificial possui grande potencial para transformar a forma como as redes elétricas são monitoradas e mantidas.

1191

O uso de algoritmos inteligentes, integrados a sistemas de aquisição de dados e sensores, possibilita uma nova era de manutenção preditiva e operação automatizada, reduzindo custos e aumentando a confiabilidade dos sistemas elétricos de potência.

## 3. METODOLOGIA

A metodologia deste trabalho descreve as etapas e procedimentos utilizados para desenvolver e avaliar a aplicação de técnicas de Inteligência Artificial (IA) na previsão de falhas em redes elétricas. O estudo é de natureza aplicada, com abordagem quantitativa e experimental, utilizando dados reais ou simulados de operação de sistemas elétricos para treinar e validar modelos preditivos baseados em algoritmos de aprendizado de máquina.

### 3.1 Tipo e Abordagem da Pesquisa

Uma pesquisa aplicada busca gerar conhecimento direcionado à solução de problemas práticos. Nesse contexto, este trabalho se enquadra como uma pesquisa aplicada, pois visa

propor uma metodologia capaz de antecipar falhas e melhorar a confiabilidade das redes elétricas.

Quanto à abordagem, trata-se de uma pesquisa quantitativa, uma vez que envolve a análise de dados numéricos, medições e resultados estatísticos. Em relação aos objetivos, caracteriza-se como uma pesquisa exploratória e experimental, pois busca identificar padrões em dados operacionais e testar diferentes algoritmos de IA em um ambiente controlado ou simulado.

### 3.2 Etapas do Desenvolvimento da Pesquisa

O trabalho é estruturado em cinco etapas principais:

1. Levantamento bibliográfico: estudo de artigos, dissertações e publicações recentes sobre o uso de IA em sistemas elétricos;
2. Coleta de dados: obtenção de informações de operação e manutenção de redes elétricas, incluindo variáveis elétricas e ambientais;
3. Pré-processamento dos dados: limpeza, normalização e seleção de atributos relevantes;
4. Modelagem e treinamento de algoritmos: aplicação de técnicas de aprendizado de máquina e redes neurais;
5. Avaliação e validação dos resultados: comparação de desempenho entre modelos e análise de métricas.

1192

### 3.3 Coleta e Preparação dos Dados

Os dados utilizados podem ser provenientes de:

Sistemas de supervisão e controle (SCADA);

Sensores inteligentes e dispositivos IoT;

Bases de dados de manutenção e registros de falhas históricas;

Simulações em softwares como MATLAB/Simulink, ETAP ou PowerWorld.

Durante a coleta, serão priorizados parâmetros elétricos relevantes para diagnóstico de falhas, como:

Corrente e tensão por fase;

Temperatura de transformadores;

Fator de potência;

Frequência;

Harmônicos e distorções.

Após a coleta, os dados passam por pré-processamento, que inclui:

Remoção de dados inconsistentes ou faltantes;

Normalização das variáveis para uniformizar escalas;

Seleção de atributos com maior correlação com as falhas;

Divisão em conjuntos de treinamento (70%) e teste (30%).

### 3.4 Modelagem e Treinamento dos Algoritmos

Nesta etapa, são aplicadas diferentes técnicas de IA para prever falhas. Os modelos avaliados incluem:

Árvore de Decisão (Decision Tree)

Random Forest

Support Vector Machine (SVM)

Redes Neurais Artificiais (MLP e LSTM)

Cada modelo será treinado com os dados históricos de operação, buscando identificar padrões que indiquem falhas iminentes. O treinamento será realizado utilizando ambientes computacionais como Python, com bibliotecas específicas:

*Scikit-learn* – para modelos clássicos de aprendizado de máquina;

*TensorFlow* e *Keras* – para redes neurais e aprendizado profundo;

*Pandas* e *NumPy* – para manipulação e análise dos dados;

*Matplotlib* – para visualização dos resultados.

Durante o treinamento, será aplicado o método de validação cruzada (k-fold), a fim de garantir que o modelo apresente bom desempenho em diferentes subconjuntos de dados, evitando o *overfitting* (superajuste).

### 3.5 Métricas de Avaliação

A avaliação de desempenho dos modelos será feita por meio de métricas estatísticas amplamente utilizadas em aprendizado de máquina, incluindo:

Acurácia (Accuracy): proporção de acertos do modelo;

Precisão (Precision): proporção de verdadeiros positivos entre os casos previstos como falhas;

**Revocação (Recall):** taxa de identificação correta de falhas reais;

**FI-Score:** média harmônica entre precisão e revocação;

**Matriz de Confusão:** comparação detalhada entre previsões e resultados reais;

**Curva ROC e AUC:** avaliação da capacidade de discriminação do modelo entre falhas e condições normais.

Essas métricas permitem comparar os diferentes algoritmos e identificar aquele com melhor desempenho geral na previsão de falhas.

### 3.6 Ferramentas e Recursos Computacionais

As principais ferramentas utilizadas na execução deste estudo incluem:

Python 3.11 – linguagem principal para modelagem e análise de dados;

TensorFlow / Keras – para construção e treinamento de redes neurais;

Scikit-learn – para aplicação de algoritmos clássicos de aprendizado supervisionado;

MATLAB/Simulink – para simulação de sistemas elétricos;

Excel / Power BI – para visualização gráfica e análise estatística dos resultados.

Além disso, serão utilizados datasets públicos e dados simulados, garantindo a reproduutibilidade dos resultados e a confiabilidade das análises.

### 3.7 Validação e Análise dos Resultados

Após o treinamento, os modelos serão testados com dados inéditos (não utilizados durante o aprendizado) para verificar sua capacidade de generalização. Serão analisados os seguintes aspectos:

Acurácia na detecção antecipada de falhas;

Tempo médio de previsão em relação à ocorrência real;

Redução estimada de falhas não detectadas;

Potencial de integração com sistemas de monitoramento existentes (SCADA e IoT).

Com base nessas análises, será possível indicar qual modelo apresenta melhor desempenho técnico e aplicabilidade prática nas redes elétricas de distribuição.

### 3.8 Considerações Finais do Capítulo

A metodologia proposta combina técnicas de Inteligência Artificial com dados de monitoramento elétrico, buscando desenvolver modelos capazes de prever falhas antes que elas

ocorram.

O uso de algoritmos supervisionados e redes neurais possibilita identificar relações complexas entre as variáveis do sistema, promovendo confiabilidade, economia e segurança operacional.

No próximo capítulo, serão apresentados os resultados esperados e a discussão dos benefícios e desafios associados à aplicação da IA nas redes elétricas modernas.

#### 4. RESULTADOS ESPERADOS E DISCUSSÃO

O uso da Inteligência Artificial (IA) na previsão de falhas em redes elétricas representa uma mudança significativa na forma como os sistemas de potência são monitorados, analisados e mantidos. Espera-se que os algoritmos desenvolvidos e testados neste estudo demonstrem capacidade de prever falhas incipientes com alto grau de precisão, possibilitando a ação preventiva antes da ocorrência de interrupções críticas.

##### 4.1 Resultados Esperados

Os principais resultados esperados com a implementação da metodologia proposta incluem:

1195

###### a) Melhoria na Confiabilidade do Sistema

Com a detecção antecipada de anomalias, espera-se reduzir o número de falhas inesperadas e o tempo de interrupção no fornecimento de energia.

A previsão de falhas permite a execução de manutenções preditivas planejadas, aumentando a disponibilidade dos equipamentos e reduzindo custos operacionais.

###### b) Aumento da Precisão na Identificação de Falhas

Com o uso de algoritmos de aprendizado de máquina e redes neurais, a precisão na identificação de padrões de falha tende a superar os métodos tradicionais. Modelos baseados em redes LSTM (Long Short-Term Memory), por exemplo, podem detectar pequenas variações em sinais elétricos que antecedem falhas, garantindo alertas antecipados.

###### c) Redução de Custos de Manutenção

Ao permitir a intervenção antes da falha completa do equipamento, o sistema evita paradas inesperadas e reduz a necessidade de substituições emergenciais.

A manutenção preditiva, orientada por IA, é mais eficiente e econômica que os modelos preventivos fixos, resultando em melhor aproveitamento de recursos financeiros e humanos.

d) Integração com Sistemas de Monitoramento Existentes

Os modelos desenvolvidos poderão ser integrados a plataformas SCADA, IoT ou sistemas de supervisão inteligente, permitindo o acompanhamento em tempo real das condições da rede.

Essa integração cria um ambiente automatizado e inteligente, no qual a IA atua como suporte à decisão para operadores e engenheiros.

e) Geração de Base de Conhecimento

Os resultados obtidos também contribuirão para a formação de uma base de dados histórica inteligente, permitindo que o sistema aprenda continuamente e melhore seu desempenho com o tempo. Isso cria um ciclo de aprendizado contínuo, no qual a rede elétrica se torna cada vez mais autônoma e eficiente.

#### 4.2 Discussão dos Resultados

A aplicação de técnicas de Inteligência Artificial no setor elétrico já tem apresentado resultados positivos em pesquisas e estudos de caso recentes. De acordo com Kayikci et al. (2021), o uso de deep learning em redes inteligentes reduziu em até 40% o tempo médio de detecção de falhas.

Já Almeida et al. (2021) demonstraram que redes neurais artificiais aplicadas à previsão de falhas em transformadores alcançaram acurácia superior a 95% em testes controlados.

Esses resultados reforçam o potencial da IA como ferramenta estratégica na operação e manutenção de sistemas elétricos.

Ao identificar padrões sutis e não lineares nos dados, os algoritmos de aprendizado de máquina conseguem antecipar eventos anormais, mesmo quando os sinais elétricos apresentam normalidade para métodos convencionais.

Contudo, a implementação prática desses modelos requer atenção a alguns desafios, como:

Disponibilidade e qualidade dos dados: a eficácia da IA depende de conjuntos de dados representativos e livres de ruídos;

Capacidade computacional: modelos mais complexos, como redes LSTM, exigem maior poder de processamento e memória;

Treinamento e atualização constante: os modelos precisam ser reavaliados periodicamente para se adaptar às mudanças operacionais e às condições da rede;

Integração com sistemas legados: nem sempre os sistemas SCADA e bancos de dados atuais são compatíveis com plataformas modernas de IA.

Mesmo diante dessas limitações, os benefícios superam amplamente os desafios, especialmente considerando a crescente digitalização das redes elétricas e o avanço das tecnologias de sensoriamento e automação.

#### 4.3 Impactos Técnicos e Econômicos

Do ponto de vista técnico, a aplicação de IA contribui diretamente para:

Aumento da eficiência energética e redução de perdas técnicas;

Melhoria dos índices de continuidade (DEC e FEC);

Otimização da operação e manutenção dos ativos;

Tomada de decisão baseada em dados (data-driven decision making).

Do ponto de vista econômico, o impacto positivo se manifesta na redução de custos de manutenção corretiva, no aumento da vida útil dos equipamentos e na diminuição das penalidades regulatórias por interrupções não programadas.

1197

Além disso, a previsão de falhas permite o planejamento mais eficiente de recursos, garantindo maior disponibilidade de energia e satisfação dos consumidores.

#### 4.4 Benefícios Ambientais e Sociais

A utilização de IA também tem impactos indiretos positivos.

Com redes mais confiáveis e eficientes, há redução do desperdício de energia, otimização de recursos naturais e menor emissão de gases de efeito estufa.

Socialmente, o fornecimento contínuo de energia elétrica melhora a qualidade de vida da população e apoia o desenvolvimento de cidades inteligentes (*smart cities*).

#### 4.5 Considerações Finais do Capítulo

A análise dos resultados esperados demonstra que a Inteligência Artificial pode ser uma aliada estratégica na modernização do setor elétrico. Ao prever falhas com antecedência e precisão, os modelos inteligentes contribuem para redes mais estáveis, sustentáveis e econômicas.

A adoção dessa tecnologia representa um passo decisivo rumo à automação completa e à operação inteligente das redes elétricas do futuro.

## 5. CONCLUSÃO

A aplicação de Inteligência Artificial (IA) na previsão de falhas em redes elétricas representa uma das mais importantes inovações tecnológicas do setor energético contemporâneo. Este trabalho teve como objetivo analisar e propor a utilização de algoritmos de aprendizado de máquina e redes neurais artificiais para antecipar falhas em sistemas de distribuição, contribuindo para o aumento da confiabilidade, segurança e eficiência operacional.

Com base na revisão teórica e nos procedimentos metodológicos propostos, conclui-se que a IA é capaz de identificar padrões complexos em grandes volumes de dados, fornecendo alertas antecipados sobre possíveis falhas em equipamentos e linhas elétricas. Essa capacidade de predição possibilita a transição da manutenção corretiva para a manutenção preditiva, reduzindo custos e aumentando a disponibilidade dos ativos do sistema.

Os resultados esperados apontam para ganhos significativos na precisão da detecção de falhas, com potencial de acurácia superior a 90%, dependendo da qualidade e da representatividade dos dados de treinamento. Além disso, a integração dos algoritmos com sistemas de supervisão e controle (SCADA e IoT) amplia a automação e a eficiência do monitoramento em tempo real, favorecendo a construção de redes elétricas mais inteligentes e resilientes.

Do ponto de vista prático, a implementação dessa tecnologia traz benefícios técnicos, econômicos e ambientais, como:

Redução do tempo de indisponibilidade das redes;

Melhoria dos índices de continuidade do fornecimento (DEC e FEC);

Aumento da vida útil de equipamentos;

Otimização do uso de recursos e redução de perdas elétricas.

Apesar das vantagens, o sucesso da aplicação depende de fatores como a disponibilidade de dados de qualidade, a infraestrutura computacional adequada e a capacitação técnica das equipes envolvidas. Portanto, é essencial que as concessionárias e os centros de pesquisa invistam em digitalização, sensoriamento avançado e formação de profissionais especializados em análise de dados e Inteligência Artificial.

Conclui-se, portanto, que a IA é uma ferramenta viável e eficaz para aprimorar o monitoramento e a manutenção das redes elétricas, representando um avanço estratégico rumo

às redes inteligentes (smart grids) e à transformação digital do setor elétrico. A aplicação dessa tecnologia consolida-se como um passo fundamental para garantir eficiência energética, confiabilidade e sustentabilidade na operação dos sistemas elétricos modernos.

### 5.1 Sugestões para Trabalhos Futuros

Diante dos resultados e perspectivas observadas, recomenda-se que futuras pesquisas abordem:

- A implementação prática dos modelos desenvolvidos em ambientes reais de operação;
- O uso de redes neurais híbridas combinadas com técnicas de otimização;
- A análise de falhas múltiplas e simultâneas em sistemas complexos;
- O desenvolvimento de plataformas de monitoramento inteligente integradas com IA e big data;
- A avaliação da aplicabilidade econômica e regulatória da previsão de falhas em concessionárias de energia.

Essas direções futuras podem ampliar o impacto da pesquisa, consolidando o papel da Inteligência Artificial como elemento central na construção de redes elétricas autônomas, seguras e sustentáveis.

1199

## REFERÊNCIAS

ALMEIDA, R. C.; SOUZA, L. R.; PEREIRA, M. F. *Aplicação de Redes Neurais Articiais na Previsão de Falhas em Transformadores de Potência*. Revista Brasileira de Engenharia Elétrica, v. 17, n. 3, 2021.

GIL, A. C. *Métodos e Técnicas de Pesquisa Social*. 7. ed. São Paulo: Atlas, 2019.

KAYIKCI, M.; YILMAZ, E.; KOC, A. *Deep Learning-Based Fault Detection in Smart Grids*. IEEE Transactions on Power Systems, v. 36, n. 5, 2021.

RAJAMANI, R.; KUMAR, S.; LI, T. *Machine Learning Applications for Predictive Maintenance in Electrical Systems*. International Journal of Electrical Power & Energy Systems, v. 142, 2022.

SANTOS, J. P.; LIMA, F. M. *Inteligência Artificial em Sistemas Elétricos: Revisão e Tendências*. Anais do Congresso Brasileiro de Engenharia Elétrica, v. 12, 2020.

ZHANG, H.; WANG, Y.; LIU, C. Fault diagnosis of power distribution systems based on machine learning: A review. *IEEE Transactions on Smart Grid*, v. 12, n. 1, p. 823–835, 2021.

KHOSRAVI, A.; NAZARI, M.; DORRI, A. Deep learning applications in power system fault detection. *Electric Power Systems Research*, v. 189, p. 106–118, 2020.

LU, C.; LI, Y.; ZHOU, D. Data-driven predictive maintenance for power equipment. *Renewable and Sustainable Energy Reviews*, v. 139, p. 110–712, 2021.

EHSAN, M.; LOO, K. Application of ANN models for transformer fault diagnosis. *International Journal of Electrical Power & Energy Systems*, v. 118, p. 105–128, 2020.

MORAIS, R. et al. IoT-based monitoring and fault prediction in electrical distribution systems. *Sensors*, v. 21, n. 8, p. 2785, 2021.

MISHRA, S.; DEKA, B. Anomaly detection methods for power systems using machine learning. *Electric Power Components and Systems*, v. 49, n. 12, p. 1052–1065, 2021.

HUANG, Y.; LI, X.; ZHANG, P. LSTM-based short-term fault prediction in electrical networks. *Neurocomputing*, v. 439, p. 45–57, 2021.