

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

**Inteligência Artificial aplicada no Monitoramento
Online de Transformadores de Potência para
Suporte à Manutenção Preditiva**

Frederico Tassi de Souza Silva

Monografia - MBA em Inteligência Artificial e Big Data

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Frederico Tassi de Souza Silva

Inteligência Artificial aplicada no Monitoramento Online de Transformadores de Potência para Suporte à Manutenção Preditiva

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Diego Furtado Silva

Versão original

São Carlos

2024

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

T213i Tassi de Souza Silva, Frederico
 Inteligência Artificial aplicada no
Monitoramento Online de Transformadores de Potência
para Suporte à Manutenção Preditiva / Frederico Tassi
de Souza Silva; orientador Diego Furtado Silva. --
São Carlos, 2024.
 62 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2024.

1. inteligência artificial. 2. machine learning.
3. manutenção preditiva. 4. gestão de ativos. 5.
monitoramento online. I. Furtado Silva, Diego,
orient. II. Título.

Frederico Tassi de Souza Silva

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Prof. Diego Furtado Silva

Original version

São Carlos

2024

Folha de aprovação em conformidade
com o padrão definido
pela Unidade.

No presente modelo consta como
folhadeaprovacao.pdf

AGRADECIMENTOS

Agradeço a todas as pessoas que tornaram possível a realização deste curso. Sem o apoio e a contribuição de cada um de vocês, este projeto não teria sido concluído com sucesso.

À equipe do CEPEL, agradeço pelo apoio que me concederam para conciliar as demandas acadêmicas com as responsabilidades profissionais.

Não posso deixar de expressar minha gratidão aos professores do curso, que compartilharam seu conhecimento, experiência e paixão pelo ensino. Suas orientações e feedbacks foram cruciais para o desenvolvimento deste trabalho e para minha formação em Inteligência Artificial.

Este trabalho final de curso é o resultado de um esforço coletivo e de muitas mãos amigas. Vocês todos fizeram parte desta conquista, e minha gratidão é imensa.

RESUMO

SILVA, F.T.S. **Inteligência Artificial aplicada no Monitoramento Online de Transformadores de Potência para Suporte à Manutenção Preditiva**. 2024. 62p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2024.

Este trabalho explora a aplicação de técnicas de Inteligência Artificial (IA) no monitoramento online de transformadores de potência, com o intuito de aprimorar a manutenção preditiva. Transformadores de potência são ativos essenciais no setor elétrico, garantindo a distribuição contínua e eficiente de energia, mas sua operação está sujeita a falhas que podem causar interrupções graves no fornecimento. Para mitigar esses riscos, é necessário adotar sistemas de monitoramento avançados que utilizam dados em tempo real para prever falhas e otimizar a manutenção. Neste estudo, foi desenvolvido um modelo preditivo utilizando algoritmos de aprendizado de máquina como Random Forest, XGBoost e Gradient Boosting, além da técnica de redução de dimensionalidade por Análise de Componentes Principais (PCA). Esses métodos foram aplicados a dados coletados por sensores instalados nos transformadores, monitorando variáveis como temperatura do óleo, umidade, corrente e tensão. Os resultados indicam que a IA pode prever dados de monitoramento e tendências que podem indicar previsões de falhas, resultando na redução de custos operacionais e no aumento da confiabilidade do sistema elétrico. A integração desses modelos a sistemas de monitoramento da condição de ativos, já utilizado por várias empresas do setor, possibilita uma gestão mais eficiente dos ativos, promovendo maior segurança e eficiência operacional. Este trabalho ressalta o potencial transformador da IA na gestão de manutenção no setor elétrico, trazendo avanços que podem prevenir falhas inesperadas e aumentar a vida útil dos transformadores.

Palavras-chave: Inteligência Artificial, Monitoramento Online, Transformadores de Potência, Manutenção Preditiva, Gestão de Ativos, Setor Elétrico

ABSTRACT

SILVA, F.T.S. **Artificial Intelligence Applied to Online Monitoring of Power Transformers for Predictive Maintenance Support**. 2024. 62p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2024.

This work explores the application of Artificial Intelligence (AI) techniques in the online monitoring of power transformers, with the aim of improving predictive maintenance. Power transformers are essential assets in the electrical sector, ensuring the continuous and efficient distribution of energy, but their operation is subject to failures that can cause severe interruptions in supply. To mitigate these risks, it is necessary to adopt advanced monitoring systems that use real-time data to predict failures and optimize maintenance. In this study, a predictive model was developed using machine learning algorithms such as Random Forest, XGBoost, and Gradient Boosting, as well as the Principal Component Analysis (PCA) technique for dimensionality reduction. These methods were applied to data collected by sensors installed on the transformers, monitoring variables such as oil temperature, humidity, current, and voltage. The results indicate that AI can predict monitoring data and trends that may signal potential failures, resulting in reduced operational costs and increased reliability of the electrical system. The integration of these models into condition monitoring systems, already used by various companies in the sector, enables more efficient asset management, promoting greater safety and operational efficiency. This work highlights the transformative potential of AI in maintenance management in the electrical sector, bringing advances that can prevent unexpected failures and extend the lifespan of transformers.

Keywords: Artificial Intelligence, Online Monitoring, Power Transformers, Predictive Maintenance, Asset Management, Electrical Sector

LISTA DE FIGURAS

Figura 1 – Modelo de negócio Canvas	33
Figura 2 – Matriz SWOT	36
Figura 3 – Componentes principais de um transformador de potência	40
Figura 4 – Distribuição de valores ausentes e zeros por variável	42
Figura 5 – Distribuição de valores ausentes e nulos por variável em 2024	42
Figura 6 – Histograma de distribuição das variáveis da base de dados	43
Figura 7 – Histograma com dados corrigidos	43
Figura 8 – Matriz de Correlação das variáveis	44
Figura 9 – Integração do modelo na solução para o cliente final	46
Figura 10 – Histograma e Boxplot da variável umidade	47
Figura 11 – Histograma e Boxplot da variável umidade	48
Figura 12 – Tempo de execução dos modelos (em segundos)	48
Figura 13 – Comparação entre valores reais e preditos - Método AdaBoost.	50
Figura 14 – Comparação entre valores reais e preditos - Método CatBoost	50
Figura 15 – Comparação entre valores reais e preditos - Método ExtraTrees	51
Figura 16 – Comparação entre valores reais e preditos - Método GradientBoosting	51
Figura 17 – Comparação entre valores reais e preditos - Método LightGBM	52
Figura 18 – Comparação entre valores reais e preditos - Método RandomForest	52
Figura 19 – Comparação entre valores reais e preditos - Método XGBoost	53
Figura 20 – Histograma dos dados tratados (Variável alvo: temperatura do enrolamento)	54
Figura 21 – Valor predito x real para temperatura do enrolamento como alvo	54
Figura 22 – Comparação valores preditos pelo modelo e reais, aplicando menos features como entrada no modelo XGBoost (resultados ruins)	56
Figura 23 – Comparação valores preditos pelo modelo e reais, aplicando modelo RandomForest em um determinado trecho	57
Figura 24 – Comparação valores preditos pelo modelo e reais, aplicando modelo ExtraTrees em outro trecho de predição	57

LISTA DE TABELAS

Tabela 1	– Variáveis Monitoradas e Funções em Transformadores de Potência . . .	39
Tabela 2	– Modelos Aplicados e métricas de desempenho	49
Tabela 3	– Modelos e desempenho (Entrada de dados: Transformador T1)	53
Tabela 4	– Modelos e desempenho (Variável alvo: temperatura do enrolamento) . .	55
Tabela 5	– Modelos e desempenho (sem monitor de umidade no treinamento) . . .	56

LISTA DE ABREVIATURAS E SIGLAS

IoT	Internet of Things (Internet das Coisas)
IA	Inteligência Artificial
SOMA	Sistema Orientado ao Monitoramento de Ativos (CEPEL)
CEPEL	Centro de Pesquisas de Energia Elétrica
PCA	Principal component analysis (Análise de Componentes Principais)
ARIMA	AutoRegressive Integrated Moving Average
RNN	Recurrent neural networks (Redes Neurais Recorrentes)
ROC	Receiver Operating Characteristic
MSE	Mean Squared Error (Erro quadrático médio)
MAE	Mean Absoluto Error (Erro absoluto médio)

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Contextualização	23
1.2	Inovação e Proposta de Solução	24
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Coleta de dados e análise exploratória	25
2.2	Pré-processamento de dados	25
2.3	Modelagem de dados e estado da arte	26
2.3.1	Preparação dos Dados e Redução de Dimensionalidade	26
2.3.2	Análise de Séries Temporais	27
2.3.3	Algoritmos Baseados em Árvores de Decisão	27
2.3.4	Técnicas de Boosting	27
2.3.5	Integração de Métodos de Machine Learning	27
2.3.6	Explicabilidade e Interpretação de Resultados	28
2.3.7	Considerações Finais	29
2.4	Análise de desempenho	29
2.5	Implantação e geração de valor	30
3	PANORAMA DE MERCADO E RESUTADOS ESPERADOS	31
3.1	Panorama de mercado	31
3.2	Investimento em Inteligência Artificial	31
3.3	Aplicações no Setor Elétrico	31
3.4	Resultados esperados	32
4	CANVAS, BENCHMARK TECNOLÓGICO E SWOT	33
4.1	Canvas	33
4.2	Benchmark Tecnológico	35
4.3	SWOT	36
5	MÉTODO DE PESQUISA E CONSTRUÇÃO DO MVP	39
5.1	Coleta de Dados	39
5.2	Análise Exploratória e Pré-processamento	41
5.3	Análise de Componentes Principais	45
5.4	Construção do MVP	45
5.4.1	Introdução	45
5.4.2	Validação pelo cliente	45
5.4.3	Integração no software	45

5.4.4	Conclusão	46
6	ANÁLISE DE RESULTADOS	47
6.1	Pré-processamento e escolha dos modelos	47
6.2	Avaliação de desempenho	49
6.3	Novas abordagens	53
7	CONCLUSÕES	59
	REFERÊNCIAS	61

1 INTRODUÇÃO

1.1 Contextualização

As empresas do setor elétrico enfrentam constantemente o desafio de garantir que seus sistemas mantenham alta qualidade e confiabilidade, assegurando a disponibilidade contínua de seus ativos. Esse cenário é intensificado pelas regulamentações rigorosas que regem o setor, as quais visam assegurar a estabilidade e segurança no fornecimento de energia elétrica. Com isso, a filosofia de manutenção das companhias tem evoluído, levando à implementação de sistemas de monitoramento online para avaliar a condição de ativos críticos, buscando otimizar a eficiência operacional (ANTONIADIS; KOUROUSSIS; KIRYTOPOULOS, 2020)

Embora as empresas possuam grandes volumes de dados que refletem o estado atual de seus ativos, muitas vezes enfrentam dificuldades em utilizá-los para tomar decisões estratégicas. Isso ocorre devido à descentralização dos dados, falta de padronização em processos e ferramentas, além da ausência de metodologias computacionais validadas que possibilitem o uso eficaz desse histórico de informações para previsões no contexto da gestão de ativos.

O avanço da tecnologia, junto ao barateamento de dispositivos relacionados à internet das coisas (IoT), facilitou a implementação de soluções de monitoramento, gerando uma base de dados robusta ao longo dos anos em diversas subestações e usinas do setor elétrico. Esse cenário abre espaço para o uso de ferramentas de inteligência artificial e aprendizado de máquina na análise e diagnóstico de ativos (PUGNA *et al.*, 2022) (COMPANY, 2021). No entanto, o que se observa em muitos casos é a aplicação dessas ferramentas de forma fragmentada, seja incorporada em equipamentos de monitoramento específicos, em softwares proprietários com protocolos de comunicação fechados, ou aplicada localmente a conjuntos limitados de dados, sem abranger todo o contexto corporativo da empresa.

No âmbito da excelência operacional, os sistemas de monitoramento desempenham um papel fundamental ao fornecer informações precisas e em tempo real sobre o desempenho dos ativos (BROWN; REHTANZ, 2018). Esses sistemas permitem que os operadores identifiquem rapidamente anomalias ou falhas, possibilitando ações corretivas antes que os problemas se agravem. Além disso, ao promover uma gestão mais eficiente dos recursos e uma manutenção preditiva, esses sistemas ajudam a reduzir custos operacionais, aumentando a confiabilidade e a segurança das instalações, o que contribui para um fornecimento de energia elétrica contínuo e estável para a população.

1.2 Inovação e Proposta de Solução

A falta de integração entre diferentes soluções de monitoramento de ativos no setor elétrico torna difícil obter uma visão abrangente do estado dos ativos, o que impede a detecção eficaz de padrões e tendências. Entretanto, o cenário de dados estruturados e consistentes oferece uma oportunidade promissora. A implementação de um sistema unificado que consolide e analise esses dados pode trazer avanços importantes. Ao combinar isso com técnicas de inteligência artificial para predição de diagnósticos, os sistemas de monitoramento e gestão de desempenho de ativos têm o potencial de transformar o setor, fornecendo informações valiosas para uma tomada de decisão mais precisa.

Para enfrentar esses desafios, o CEPEL desenvolveu o sistema SOMA, uma solução inovadora para análise de desempenho de ativos com base no monitoramento online das condições dos equipamentos (CEPEL, 2024). Essa ferramenta tecnológica oferece recursos de captura, integração e visualização de dados, análises avançadas, além de um sistema especialista de alarmes e notificações. O SOMA já está em uso em empresas como Chesf, Eletrosul, Eletronorte, Furnas, Petrobras, Eletronuclear, Itaipu Binacional, entre outras.

Neste trabalho, será proposto um modelo de predição de diagnósticos para transformadores de potência, utilizando técnicas de Inteligência Artificial. Diversas abordagens serão testadas e comparadas em termos de desempenho. Após validação, o modelo será integrado ao software, aproveitando todas as funcionalidades já existentes.

Assim, o desenvolvimento desses modelos dentro de um sistema de monitoramento de ativos como o SOMA, que já é utilizado em várias empresas e conta com bases de dados robustas e integradas, aliado à expertise do CEPEL, pode gerar ganhos expressivos no setor elétrico. Isso possibilitará a otimização da gestão de recursos, tornando a Engenharia de Manutenção mais eficiente e eficaz.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Coleta de dados e análise exploratória

A análise exploratória de dados é um passo essencial no desenvolvimento de modelos de aprendizado de máquina, pois permite compreender a natureza dos dados, identificar padrões, tendências e relações entre variáveis, além de detectar problemas de qualidade e preparar os dados para a modelagem (HAN; KAMBER; PEI, 2011).

O processo começa com a coleta de dados, que pode incluir tanto dados estruturados, como tabelas de bancos de dados, quanto dados não estruturados, como textos, áudios ou imagens. A escolha dos dados corretos é crucial e deve considerar fatores como a relevância para o problema em questão, sua disponibilidade e a qualidade dos dados.

Após a coleta, a análise exploratória é realizada para entender a estrutura e as principais características dos dados. Isso geralmente envolve a utilização de estatísticas descritivas para resumir métricas como média, mediana, desvio padrão e a distribuição das variáveis. Ferramentas visuais, como histogramas, gráficos de dispersão e boxplots, são muito úteis para explorar a distribuição dos dados e identificar padrões ou a presença de outliers.

Esse processo também ajuda a identificar correlações entre as variáveis independentes e a variável dependente (ou alvo), o que orienta a seleção de características relevantes e a escolha do algoritmo de modelagem mais adequado (WICKHAM; GROLEMUND, 2017). Além disso, insights iniciais sobre o problema, como tendências sazonais em séries temporais ou padrões de agrupamento em dados não estruturados, podem surgir durante essa etapa, ajudando a formular hipóteses que serão testadas na fase de modelagem.

Em resumo, a coleta e análise exploratória de dados são etapas fundamentais para o desenvolvimento de modelos de machine learning. Elas fornecem uma visão aprofundada dos dados, ajudam a identificar e corrigir problemas de qualidade, e direcionam o desenvolvimento do modelo, garantindo maior precisão e confiabilidade nos resultados.

2.2 Pré-processamento de dados

O pré-processamento de dados é uma etapa essencial no ciclo de vida dos projetos de ciência de dados, pois envolve a limpeza, transformação e preparação dos dados brutos para análise. Durante essa fase, são identificadas e corrigidas inconsistências, removidos outliers, tratados valores ausentes e transformados os dados em um formato adequado, garantindo que os analistas possam extrair informações relevantes e construir modelos mais precisos a partir dos dados brutos. A qualidade e relevância dos dados influenciam

diretamente a precisão e eficácia dos modelos de aprendizado de máquina e das análises estatísticas subsequentes.

Uma prática comum no pré-processamento é a imputação de dados, que substitui valores ausentes por estimativas baseadas nos dados disponíveis, evitando a perda de informações valiosas. Além disso, técnicas como a normalização e padronização dos dados são amplamente utilizadas para garantir que variáveis com diferentes escalas possam ser comparadas e interpretadas de forma adequada (GARCÍA; LUENGO; HERRERA, 2015). Isso é especialmente importante em algoritmos que são sensíveis às magnitudes das variáveis.

A seleção de características também desempenha um papel crucial, ajudando a identificar as variáveis mais relevantes para o problema em questão e, ao mesmo tempo, reduzindo a dimensionalidade dos dados. Essa redução não só melhora o desempenho dos modelos, mas também pode acelerar o tempo de processamento, tornando a análise mais eficiente.

Outra técnica indispensável no pré-processamento é a detecção de outliers, ou seja, a identificação de pontos de dados anômalos que podem distorcer os resultados das análises estatísticas. Remover ou tratar esses outliers é fundamental para garantir que os modelos sejam treinados com dados de alta qualidade (AGGARWAL, 2017).

Por fim, a engenharia de características é uma etapa importante que envolve a criação de novas variáveis com base nas já existentes, visando capturar melhor a complexidade dos dados e aumentar o desempenho dos modelos. Combinando essas técnicas de pré-processamento, os dados se tornam mais consistentes e significativos, o que contribui diretamente para a construção de modelos de machine learning mais robustos e precisos.

2.3 Modelagem de dados e estado da arte

A aplicação de algoritmos de machine learning e inteligência artificial (IA) tem transformado o gerenciamento de ativos no setor elétrico, permitindo a identificação de padrões, tendências e anomalias nos dados de monitoramento. Esses avanços possibilitam a previsão de falhas e contribuem para uma gestão mais eficiente dos ativos. No entanto, para alcançar resultados precisos, é fundamental entender as técnicas de modelagem, a preparação dos dados e a aplicação adequada dos modelos de IA.

2.3.1 Preparação dos Dados e Redução de Dimensionalidade

Os sistemas de monitoramento geram grandes volumes de dados, muitas vezes com inúmeras variáveis. Para lidar com essa complexidade, é necessário aplicar técnicas de redução de dimensionalidade, como a Análise de Componentes Principais (PCA). O PCA

reduz a quantidade de variáveis ao transformar dados correlacionados em componentes principais independentes, que ainda capturam a maior parte da variabilidade dos dados. Isso não apenas simplifica os conjuntos de dados, como também preserva informações cruciais para a modelagem, tornando o processo de aplicação de algoritmos de machine learning mais eficiente e menos sujeito a ruídos (JOLLIFFE, 2002).

2.3.2 Análise de Séries Temporais

Os ativos de geração e transmissão, como transformadores, produzem dados que variam ao longo do tempo, formando séries temporais. A análise desses dados permite entender a evolução de parâmetros críticos, como temperatura, corrente e tensão. Modelos como ARIMA (AutoRegressive Integrated Moving Average) e redes neurais recorrentes (RNN) são amplamente utilizados para prever comportamentos futuros e identificar padrões anômalos que podem indicar falhas iminentes (HYNDMAN; ATHANASOPOULOS, 2018). Essas técnicas são fundamentais para a manutenção preditiva, pois possibilitam que intervenções sejam realizadas antes que problemas maiores ocorram, reduzindo custos e melhorando a segurança operacional.

2.3.3 Algoritmos Baseados em Árvores de Decisão

Algoritmos baseados em árvores de decisão, como o Random Forest e o ExtraTrees, têm sido eficazes em aplicações de diagnóstico preditivo. O Random Forest, por exemplo, constrói múltiplas árvores de decisão a partir de subconjuntos aleatórios de dados, resultando em um modelo mais robusto e resistente a overfitting. Já o ExtraTrees aumenta a diversidade entre as árvores, gerando um modelo que pode ter ainda mais precisão em cenários específicos (BREIMAN, 2001). Ambos os algoritmos são adequados para lidar com dados complexos e ruidosos, comuns em sistemas de monitoramento de ativos.

2.3.4 Técnicas de Boosting

Técnicas de boosting, como XGBoost, Gradient Boosting, LightGBM, CatBoost e AdaBoost, têm ganhado popularidade devido à sua capacidade de oferecer alta performance em tarefas de classificação e regressão. O XGBoost, por exemplo, é conhecido por sua eficiência e capacidade de lidar com grandes volumes de dados. Já o LightGBM é elogiado por sua escalabilidade e rapidez, enquanto o CatBoost é especialmente eficaz em lidar com dados categóricos, tornando-o útil em cenários onde os dados não são puramente numéricos (CHEN; GUESTRIN, 2016). Essas técnicas oferecem soluções poderosas para o diagnóstico preditivo de falhas em sistemas complexos.

2.3.5 Integração de Métodos de Machine Learning

A combinação de diferentes algoritmos pode fortalecer os modelos preditivos, melhorando a acurácia e a robustez dos diagnósticos. Um exemplo comum é o uso combinado

de Gradient Boosting e AdaBoost. No Gradient Boosting, as árvores são construídas sequencialmente, corrigindo os erros das anteriores. Já o AdaBoost ajusta os pesos dos exemplos mal classificados, fazendo com que o modelo foque em áreas mais difíceis de prever. Esse processo iterativo resulta em um modelo mais eficaz para a previsão de falhas, minimizando os erros e maximizando a precisão.

2.3.6 Explicabilidade e Interpretação de Resultados

Apesar do sucesso das técnicas de machine learning, como redes neurais profundas e algoritmos avançados, um dos principais desafios ainda é entender como essas ferramentas chegam às suas conclusões. No caso das redes neurais, por exemplo, elas são frequentemente vistas como "caixas-pretas", onde as previsões são feitas, mas o processo que leva até elas não é claro. Isso pode ser problemático, principalmente em setores críticos como o elétrico, onde engenheiros e gestores precisam confiar e explicar as decisões que tomam com base nos dados gerados. Quando não é possível entender por que o modelo fez uma determinada previsão, a confiança na tecnologia pode ser abalada, dificultando sua adoção.

Para tentar tornar essas previsões mais transparentes, existem ferramentas que ajudam a interpretar os resultados dos modelos. Métodos como LIME (Local Interpretable Model-agnostic Explanations) e SHAP (SHapley Additive exPlanations) foram criados para dar uma visão de como um modelo de machine learning toma suas decisões, ajudando a traduzir o comportamento do modelo de uma maneira que possa ser compreendida por humanos. No entanto, essas ferramentas também têm suas limitações. Muitas vezes, as explicações que fornecem podem ser inconsistentes ou confusas, especialmente para aqueles que não são especialistas em machine learning. Além disso, as justificativas oferecidas por essas ferramentas nem sempre refletem com precisão o que realmente aconteceu dentro do modelo, o que pode gerar mais dúvidas do que respostas.

No setor elétrico, onde a precisão é fundamental para garantir a segurança e a confiabilidade dos sistemas, essa falta de clareza pode ser um grande obstáculo. As inovações como a análise de séries temporais, a redução de dimensionalidade com PCA e o uso de algoritmos como Random Forest e XGBoost trouxeram grandes avanços no monitoramento preditivo de ativos, permitindo que falhas sejam previstas antes de acontecerem. Mas sem uma forma clara e consistente de explicar como essas previsões são feitas, os engenheiros podem hesitar em confiar plenamente nos resultados. Isso ressalta a importância de não apenas adotar tecnologias avançadas, mas também garantir que suas interpretações sejam compreensíveis e confiáveis para que as inovações possam realmente transformar a forma como os ativos são gerenciados.

2.3.7 Considerações Finais

A aplicação de técnicas de machine learning e IA no diagnóstico preditivo de ativos do setor elétrico representa um avanço significativo. Métodos como a redução de dimensionalidade com PCA, a análise de séries temporais e o uso de algoritmos como Random Forest, XGBoost e Gradient Boosting demonstram grande potencial para aumentar a confiabilidade e a eficiência dos sistemas de monitoramento. A capacidade de prever falhas de forma precisa não só otimiza a manutenção, mas também garante uma operação mais segura e econômica, beneficiando tanto as empresas quanto os consumidores de energia.

2.4 Análise de desempenho

A análise de desempenho de algoritmos de aprendizado de máquina é fundamental para garantir a eficácia e confiabilidade dos modelos desenvolvidos. Essa etapa permite identificar os pontos fortes e fracos de cada modelo, ajustar parâmetros e, assim, selecionar a abordagem mais adequada para resolver um problema específico. Essa escolha cuidadosa é essencial para alcançar os resultados desejados.

Uma das formas mais comuns de avaliar o desempenho dos modelos é por meio de métricas estatísticas. Dependendo do tipo de problema e dos objetivos da análise, diferentes métricas podem ser utilizadas. Em problemas de classificação binária, por exemplo, são amplamente usadas métricas como precisão, recall, F1-score e a área sob a curva ROC (Receiver Operating Characteristic) (POWERS, 2020).

A precisão avalia a proporção de classificações corretas, enquanto o recall mede a capacidade de identificar corretamente as instâncias positivas. Já o F1-score é uma combinação entre precisão e recall, sendo uma única medida do desempenho do modelo. A área sob a curva ROC, por sua vez, avalia a habilidade do modelo em distinguir entre classes positivas e negativas em diferentes limiares de decisão.

Para problemas de regressão, utilizam-se métricas como o erro quadrático médio (MSE), o erro absoluto médio (MAE) e o coeficiente de determinação (R^2). O MSE e o MAE medem o quanto as previsões do modelo diferem dos valores reais, enquanto o R^2 indica quanto da variabilidade dos dados é explicada pelo modelo.

Essas métricas são essenciais, pois fornecem uma visão quantitativa do desempenho dos modelos, permitindo a comparação entre diferentes abordagens e ajustes de parâmetros. Além disso, ajudam a detectar problemas como overfitting (quando o modelo se ajusta demais aos dados de treinamento) ou underfitting (quando o modelo é incapaz de capturar padrões importantes), orientando a otimização do modelo.

Em resumo, a análise de desempenho com métricas estatísticas é uma ferramenta crucial para garantir a qualidade dos modelos de machine learning, assegurando que eles

possam ser aplicados de forma eficaz a novos dados e otimizados para fornecer os melhores resultados possíveis.

2.5 Implantação e geração de valor

A implementação de um modelo de inteligência artificial para prever diagnósticos de ativos no setor elétrico tem o potencial de gerar valor significativo, especialmente na otimização da manutenção, na redução de custos operacionais e na minimização de falhas inesperadas. Esse processo envolve diversas etapas, desde a coleta e preparação dos dados, passando pela construção e validação do modelo, até sua integração nas operações diárias.

O primeiro passo é a coleta e preparação de dados relevantes, que podem incluir informações sobre o histórico de manutenção, condições operacionais e dados de sensores dos ativos elétricos. No caso proposto, esse papel é desempenhado pelo sistema de monitoramento SOMA, que fornece uma base de dados robusta. A partir dessa base, algoritmos de aprendizado de máquina, como regressão, classificação ou modelos de séries temporais, podem ser aplicados para criar um modelo preditivo.

Após a construção do modelo, é essencial avaliá-lo em novos conjuntos de dados para garantir sua precisão e capacidade de generalização. Se necessário, ajustes nos parâmetros são realizados para melhorar o desempenho. Uma vez validado, o modelo pode ser implantado em ambiente de produção, integrado ao sistema SOMA, utilizando dados em tempo real ou em intervalos regulares para realizar previsões.

O verdadeiro valor desse processo é gerado quando as previsões do modelo são integradas ao processo de tomada de decisão operacional. Por exemplo, ao prever a probabilidade de falha de um ativo ou identificar uma tendência de aumento de temperatura, as equipes de manutenção podem priorizar inspeções e reparos em ativos de maior risco. Isso evita falhas catastróficas e minimiza o tempo de inatividade não planejado.

Além disso, a implementação bem-sucedida de um modelo preditivo pode melhorar a alocação de recursos, reduzindo a necessidade de manutenções desnecessárias e prolongando a vida útil dos ativos. Ao antecipar problemas, as empresas podem agir de forma proativa, mitigando riscos e aumentando a confiabilidade e eficiência de suas operações.

Em resumo, a implantação de modelos de diagnóstico preditivo no setor elétrico não apenas gera economia, mas também aumenta a segurança e a eficiência operacional, trazendo benefícios tangíveis tanto para as empresas quanto para seus clientes.

3 PANORAMA DE MERCADO E RESULTADOS ESPERADOS

3.1 Panorama de mercado

A Inteligência Artificial (IA) está se consolidando como uma das tecnologias mais impactantes da atualidade, revolucionando diversos setores econômicos e industriais. Seu crescimento global é impulsionado por avanços em áreas como machine learning, processamento de linguagem natural e visão computacional. Empresas de tecnologia de ponta, startups inovadoras e instituições acadêmicas estão investindo pesadamente em pesquisa e desenvolvimento, buscando novas aplicações que possam otimizar processos, reduzir custos e criar modelos de negócio mais eficientes.

Estudos de mercado indicam que o valor global do mercado de IA deverá ultrapassar os 190 bilhões de dólares até 2025, com uma taxa de crescimento anual composta de cerca de 36%. Regiões como América do Norte, Europa e Ásia-Pacífico lideram esse crescimento, sendo que China e Estados Unidos se destacam como os principais players no cenário competitivo (RESEARCH, 2020).

3.2 Investimento em Inteligência Artificial

Os investimentos em IA têm crescido exponencialmente, tanto por parte de grandes corporações quanto de governos. Empresas como Google, Microsoft, Amazon e IBM estão na vanguarda, destinando bilhões de dólares para a infraestrutura, aquisição de startups e desenvolvimento de tecnologias inovadoras baseadas em IA.

Além disso, fundos de capital de risco têm canalizado uma parte significativa de seus recursos para startups de IA, reconhecendo o potencial transformador dessa tecnologia. Em 2020, o financiamento para startups de IA atingiu um recorde de 40 bilhões de dólares, refletindo a confiança dos investidores no impacto inovador e lucrativo que a IA pode oferecer.

Governos também têm papel fundamental nesse desenvolvimento, com políticas públicas, subsídios e programas de pesquisa que incentivam o avanço da IA. Países como a China possuem planos ambiciosos para se tornarem líderes globais na área, enquanto a União Europeia, por exemplo, lançou o Programa de Inteligência Artificial Europeu, que visa reforçar a pesquisa e inovação no continente (PWC, 2019).

3.3 Aplicações no Setor Elétrico

No setor elétrico, a IA oferece um potencial transformador, trazendo inovações na gestão e operação dos sistemas de energia. Uma das principais aplicações é a previsão de

demanda (SILVA; OLIVEIRA, 2024), onde modelos avançados analisam grandes volumes de dados históricos e variáveis externas, como clima e eventos sazonais, para prever padrões de consumo de energia com alta precisão. Isso permite um planejamento mais eficiente, evitando desperdícios e garantindo que a oferta atenda à demanda de forma confiável e econômica.

A IA também pode otimizar o despacho de energia, processo que envolve a distribuição de eletricidade a partir de diferentes fontes de geração. Algoritmos de machine learning analisam dados em tempo real e tomam decisões rápidas e precisas sobre quais geradores devem ser acionados ou desligados, considerando fatores como custo, disponibilidade e condições operacionais. Essa abordagem não só reduz os custos operacionais, mas também melhora a eficiência e sustentabilidade do sistema elétrico (PEREIRA; COSTA, 2022).

Outra área promissora é a manutenção preditiva. Tradicionalmente, a manutenção de equipamentos era feita de maneira preventiva ou reativa, muitas vezes resultando em custos elevados e tempos de inatividade desnecessários (??). Com a IA, sensores instalados nos equipamentos monitoram continuamente seu desempenho, gerando dados que são analisados por algoritmos de aprendizado de máquina. Esses algoritmos conseguem identificar padrões que indicam falhas potenciais antes que elas ocorram, permitindo intervenções proativas e minimizando o tempo de inatividade.

A gestão de ativos também se beneficia da IA. Com a análise de dados históricos e em tempo real, modelos aplicados podem fornecer insights valiosos sobre o desempenho e a vida útil dos equipamentos, auxiliando na tomada de decisões sobre substituição ou renovação dos ativos. Isso garante uma gestão mais estratégica, prolonga a vida útil dos equipamentos e contribui para uma operação mais eficiente.

3.4 Resultados esperados

No contexto deste trabalho, a aplicação de modelos de IA para predição em sistemas de monitoramento no setor elétrico tem o potencial de gerar resultados significativos. Com a implementação desses modelos, é possível aumentar a confiabilidade do sistema através da manutenção preditiva, identificando falhas antes que elas ocorram. Isso minimiza interrupções e melhora a continuidade do serviço, além de auxiliar na tomada de decisões estratégicas na Engenharia de Manutenção, fornecendo informações valiosas sobre o estado dos equipamentos e permitindo uma gestão mais eficiente dos ativos.

Além de aumentar a eficiência e a confiabilidade, a adoção de IA no setor elétrico também estabelece uma base sólida para a inovação contínua e a transformação digital, abrindo caminho para futuras melhorias tecnológicas e operacionais.

4 CANVAS, BENCHMARK TECNOLÓGICO E SWOT

4.1 Canvas

O Canvas é uma ferramenta estratégica amplamente utilizada para visualizar e estruturar modelos de negócios de maneira simples e visual. O modelo mais conhecido é o Business Model Canvas, criado por Alexander Osterwalder, que organiza os principais componentes de um negócio em nove blocos: Proposta de Valor, Segmentos de Clientes, Canais, Relacionamento com Clientes, Fontes de Receita, Recursos-Chave, Atividades-Chave, Parcerias-Chave e Estrutura de Custos. O objetivo dessa ferramenta é ajudar empreendedores e gestores a entender, discutir e aprimorar seus modelos de negócios de maneira integrada. O Canvas aplicado ao modelo de negócio proposto neste trabalho é apresentado na Figura 1.

PARCERIAS-CHAVE	ATIVIDADES-CHAVE	PROPOSTA DE VALOR	RELAÇÃO COM CLIENTES	SEGMENTOS DE CLIENTES
- Empresas do setor elétrico - Centros de pesquisa e desenvolvimento - Fabricantes de sensores de monitoramento - Empresas de tecnologia	- Desenvolvimento web - Análise de dados - Suporte/Manutenção	- Solução integrada - Inteligência artificial - Otimização de recursos	- Suporte técnico e capacitação - Feedback e melhoria contínua	- Operadores de usinas e subestações - Setor de Engenharia de concessionárias - Diretores de gestão de ativos de geração e transmissão
	RECURSOS-CHAVE - Infraestrutura de tecnologia - Desenvolvedores de software	- Manutenção preditiva - Excelência operacional	CANAIS - Plataforma online - Implementação direta - Consultoria técnica	
ESTRUTURA DE CUSTOS		FONTES DE RECEITA		
- Desenvolvimento e atualização do sistema - Infraestrutura tecnológica, suporte e manutenção - Marketing e treinamento da solução		- Licenciamento de software (da solução onde está embarcada) - Serviços de manutenção, suporte e treinamentos - Entrega de valor (redução de custos técnicos e regulatórios)		

Figura 1 – Modelo de negócio Canvas

A proposta de valor deste sistema está na oferta de uma solução integrada para o monitoramento de ativos no setor elétrico. O sistema consolida e analisa dados de diversas fontes, proporcionando uma visão ampla e detalhada do estado dos ativos. Por meio de técnicas de inteligência artificial, ele permite a predição de diagnósticos, fornecendo insights precisos para apoiar a tomada de decisões. Além disso, a solução otimiza a gestão de recursos e possibilita a manutenção preditiva, o que resulta em redução de custos operacionais e maior confiabilidade e segurança das instalações.

Os segmentos de clientes contemplados incluem operadores de usinas e subestações, que precisam de monitoramento constante para garantir eficiência e segurança; empresas de manutenção e engenharia, que buscam melhorar a gestão de ativos e reduzir seus custos; e, de forma mais ampla, empresas do setor elétrico interessadas em aumentar a confiabilidade e estabilidade do fornecimento de energia.

Os canais de distribuição do sistema incluem o modelo de Software como Serviço (SaaS), permitindo o acesso à plataforma e suas funcionalidades online; a implementação direta, com a instalação e integração do sistema nas infraestruturas dos clientes; e a consultoria técnica, que oferece suporte especializado para auxiliar na implementação e utilização da solução.

O relacionamento com os clientes é mantido por meio de suporte técnico contínuo, que garante atendimento para resolver problemas e otimizar o uso do sistema; programas de treinamento e capacitação, assegurando que os usuários aproveitem todas as funcionalidades oferecidas; e a coleta de feedback, permitindo melhorias contínuas no sistema.

As fontes de receita incluem taxas de licenciamento para o uso do sistema, assinaturas recorrentes que cobrem serviços de manutenção, suporte e atualizações, além da receita obtida com serviços de consultoria e programas de capacitação oferecidos aos clientes.

Os recursos-chave necessários para a operação do sistema incluem uma infraestrutura tecnológica robusta para captura, integração e análise de dados; uma equipe altamente especializada em desenvolvimento de software e inteligência artificial; e bases de dados sólidas e integradas, derivadas dos ativos monitorados.

As atividades-chave deste modelo de negócios envolvem o desenvolvimento contínuo do software, com a implementação de novas funcionalidades e atualizações; a análise de dados e a criação de modelos preditivos, com base em inteligência artificial, para o diagnóstico dos ativos; e o suporte técnico e a manutenção do sistema, assegurando sua eficiência e disponibilidade.

As parcerias-chave são estabelecidas com empresas do setor elétrico, que utilizam o sistema para coletar e integrar dados, além de instituições de pesquisa e desenvolvimento, que colaboram no avanço de novas tecnologias e modelos de análise. Também são importantes as parcerias com fornecedores de tecnologia, que fornecem o hardware e o software necessários para o funcionamento do sistema.

Por fim, a estrutura de custos abrange os investimentos necessários para o desenvolvimento e a atualização contínua do software, além dos gastos com infraestrutura tecnológica, como servidores e armazenamento de dados, equipe de suporte e manutenção, e esforços em marketing e programas de capacitação para os usuários.

Esse modelo de negócios, ao oferecer uma solução inovadora e integrada, tem o potencial de transformar a gestão de ativos no setor elétrico. Com isso, é possível alcançar

ganhos significativos em termos de eficiência, segurança e redução de custos, posicionando a solução como uma ferramenta estratégica no mercado.

4.2 Benchmark Tecnológico

O benchmarking tecnológico é uma prática indispensável para empresas que buscam se destacar pela inovação e competitividade, especialmente em setores onde a tecnologia tem um papel central. Esse processo envolve a análise comparativa de processos, tecnologias e ferramentas, com o objetivo de alinhar as operações às melhores práticas do mercado. Ao observar o que empresas líderes estão utilizando, uma organização pode adotar novas estratégias, otimizar seu desempenho e alcançar um nível superior de eficiência e excelência operacional.

Na área de engenharia de manutenção, o benchmarking tecnológico tem sido um recurso vital para o avanço de sistemas de predição. Com o uso de tecnologias avançadas, como inteligência artificial e aprendizado de máquina, as empresas podem monitorar continuamente o estado dos equipamentos, prevendo falhas antes mesmo de que aconteçam. Ao comparar suas práticas com as soluções adotadas por outras organizações, é possível implementar melhorias que tornam o planejamento da manutenção mais eficiente, resultando em menores custos com reparos emergenciais e na ampliação da vida útil dos ativos (LEWIS; DESOUZA, 2019)

No setor elétrico, o benchmarking se destaca como uma ferramenta valiosa para o desenvolvimento de sistemas de monitoramento de ativos. Com a digitalização crescente das redes e a incorporação de dispositivos de Internet das Coisas (IoT), o volume de dados gerado por equipamentos críticos, como transformadores e linhas de transmissão, tem aumentado significativamente (GUPTA; JAIN, 2020). Ao comparar essas inovações com as de concorrentes, as empresas conseguem identificar oportunidades de aprimorar o monitoramento e aplicar algoritmos preditivos para aumentar a confiabilidade e a segurança das operações, reduzindo falhas inesperadas e interrupções no fornecimento de energia.

Além disso, o benchmarking tecnológico aplicado aos sistemas de predição e monitoramento traz ganhos expressivos em termos de eficiência operacional. Ao seguir as melhores práticas tecnológicas, as empresas do setor elétrico podem alocar recursos de forma mais estratégica (GOMEZ-EXPOSITO; CONEJO; CANIZARES, 2019), otimizar o cronograma de manutenções e diminuir o tempo de inatividade dos equipamentos. Isso, por sua vez, contribui não só para a redução dos custos, mas também para um fornecimento de energia mais confiável, o que aumenta a satisfação dos clientes.

Por fim, o benchmarking é uma fonte constante de inovação. Ao se manter atualizado com as tendências tecnológicas e as inovações implementadas por empresas de ponta, uma organização consegue se adaptar rapidamente às mudanças do mercado e das

regulamentações, preservando sua competitividade. No setor elétrico, isso significa estar preparado para atender à crescente demanda por energia limpa e eficiente, além de se adequar às novas exigências de sustentabilidade e segurança, garantindo um futuro sólido e inovador para a empresa.

4.3 SWOT

A Análise SWOT é uma ferramenta essencial de planejamento estratégico, usada para identificar os pontos fortes (Strengths), pontos fracos (Weaknesses), oportunidades (Opportunities) e ameaças (Threats) de uma organização, projeto ou iniciativa. Ela ajuda a empresa a entender melhor o ambiente interno e externo em que está inserida, possibilitando o desenvolvimento de estratégias que aproveitem as forças e oportunidades, ao mesmo tempo que minimizam os pontos fracos e enfrentam as ameaças. Apesar de simples, essa abordagem é poderosa e contribui para a criação de estratégias eficazes e para a tomada de decisões bem fundamentadas.

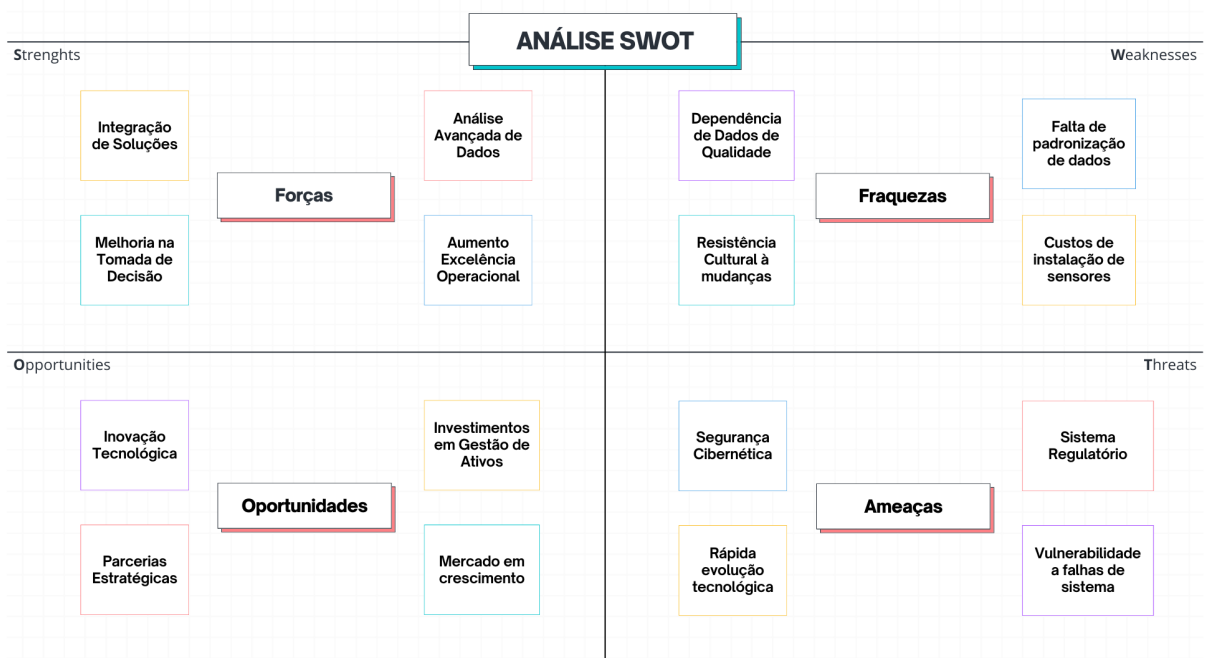


Figura 2 – Matriz SWOT

Ao aplicar a análise SWOT ao modelo de negócio voltado para o desenvolvimento de soluções preditivas para o diagnóstico de ativos no setor elétrico, identificamos uma série de oportunidades e desafios. Entre os pontos fortes, destacam-se a capacidade de integrar soluções de monitoramento de ativos em um sistema unificado, utilizando algoritmos avançados de inteligência artificial para realizar análises preditivas. Isso não só facilita a tomada de decisões mais eficazes na gestão de ativos, como também reduz custos

operacionais ao implementar estratégias de manutenção preditiva. A Matriz para este trabalho é mostrada na Figura 2.

Por outro lado, alguns desafios importantes incluem a complexidade de integrar sistemas legados já em uso, a necessidade de dados de alta qualidade para garantir análises precisas e a resistência organizacional às mudanças, além dos custos elevados envolvidos na implementação de novas tecnologias.

As oportunidades surgem do aumento da demanda por soluções tecnológicas avançadas no setor elétrico, oferecendo espaço para liderar o mercado por meio de inovação contínua. Além disso, um ambiente regulatório favorável e parcerias estratégicas podem reforçar ainda mais a posição competitiva da empresa. No entanto, há ameaças significativas, como a intensa concorrência de outras empresas que estão desenvolvendo soluções semelhantes, os riscos cada vez maiores de segurança cibernética devido ao gerenciamento de grandes volumes de dados e a necessidade de adaptação rápida às evoluções tecnológicas. Mudanças imprevistas nas regulamentações também podem impactar as operações, exigindo ajustes rápidos e significativos no sistema.

Essa análise SWOT destaca tanto as áreas de vantagem quanto os desafios a serem superados, ajudando a traçar um caminho estratégico sólido para a empresa no setor elétrico.

5 MÉTODO DE PESQUISA E CONSTRUÇÃO DO MVP

5.1 Coleta de Dados

Os dados utilizados para o desenvolvimento do modelo foram coletados a partir de sensores instalados em dois transformadores de potência (chamados aqui de T1 e T2) de uma subestação de uma concessionária localizada na região sul do Brasil. Um transformador é um equipamento que desempenha um papel crucial na subestação, sendo responsável pela transformação de níveis de tensão elétrica para atender as demandas de transmissão e distribuição de energia elétrica. Seu funcionamento eficiente é vital para a operação contínua e confiável da subestação e, conseqüentemente, para a estabilidade do Sistema Interligado Nacional (SIN).

Tabela 1 – Variáveis Monitoradas e Funções em Transformadores de Potência

Tipo de Monitoramento	Variáveis Monitoradas	Unidade
Dados de Operação	Corrente	A
	Frequência	Hz
	Posição do Tap	-
	Potência Aparente	MVA
	Potência Ativa	MW
	Potência Reativa	Mvar
	Tensão de Linha	kV
Monitor de Buchas	Capacitância	pF
	Tangente Delta	%
	Corrente de Fuga	A
Térmico	Temperatura do óleo	°C
	Temp. Enrolamento	°C
	Carregamento	%
Monitor de Umidade	Saturação Relativa	%
	Tendência de Evolução	ppm/dia
	Umidade do óleo	ppm

Fonte: Elaborada pelo autor.

As variáveis monitoradas encontram-se descritas na Tabela 1. Os dados foram coletados ao longo do ano de 2023 e nos primeiros meses de 2024. A coleta de dados reais detalhada neste capítulo forneceu a base necessária para o desenvolvimento de um modelo de IA proposto. Os dados são aquisitados a cada 4 segundos no sistema, porém no banco de dados o valor instantâneo é salvo a cada 5 minutos. Ao combinar dados operacionais e de monitoramento específicos, conseguimos uma visão abrangente do desempenho e das condições do transformador de potência, essencial para a predição eficiente e eficaz de possíveis falhas e para a otimização da manutenção preventiva.

Os transformadores de potência (Figura 3) desempenham um papel fundamental na distribuição de energia elétrica, e um monitoramento eficaz de várias variáveis é essencial para garantir sua operação segura e eficiente. A corrente que passa pelos enrolamentos do transformador é rigorosamente monitorada, uma vez que correntes excessivas podem ser indicativas de sobrecargas ou falhas internas, resultando em superaquecimento e danos consideráveis ao equipamento. Além disso, a frequência da corrente alternada deve ser mantida estável, tipicamente em 50 Hz ou 60 Hz, para assegurar o funcionamento adequado de todos os dispositivos conectados ao sistema, já que qualquer flutuação pode afetar a segurança e a funcionalidade do sistema.




Figura 3 – Componentes principais de um transformador de potência

Ajustar a posição do tap no comutador é crucial para regular a tensão de saída do transformador, mantendo-a dentro de parâmetros seguros, especialmente sob variadas condições de carga. O monitoramento das potências aparente, ativa e reativa ajuda a avaliar a eficiência energética do transformador. Enquanto a potência ativa reflete a energia realmente usada para realizar trabalho, a potência reativa sustenta os campos magnéticos necessários em motores e outros dispositivos. A vigilância da tensão entre fases também é vital, pois tensões inapropriadas podem danificar tanto o transformador quanto os equipamentos a ele conectados.

Quanto ao monitoramento das buchas, a medição da capacitância desses componentes é fundamental para avaliar a condição do isolamento. Mudanças nessa medida podem sinalizar uma degradação do isolamento ou a presença de umidade, comprometendo

a segurança do transformador. Monitorar a corrente de fuga das buchas é igualmente importante, pois altos valores podem indicar falhas de isolamento com potencial para causar problemas graves. A tangente delta das buchas, que mede a energia perdida como calor no isolamento, serve como um indicador crítico da saúde das buchas, com altos valores apontando para a deterioração ou contaminação.

A temperatura é outro parâmetro crítico. A carga atual do transformador é constantemente comparada à sua capacidade nominal para evitar sobrecargas, o que ajuda a prolongar a vida útil do equipamento. As temperaturas dos enrolamentos e do óleo são monitoradas de perto, pois elevações podem indicar problemas de resfriamento ou sobrecarga, levando à degradação do isolamento e diminuindo a vida útil do transformador.

Finalmente, o monitoramento da umidade é crucial. Controlar a saturação relativa do óleo ajuda a prevenir níveis excessivos de umidade, que são prejudiciais ao isolamento e à operação segura do transformador. A tendência de evolução da umidade no óleo e a umidade específica no óleo do comutador também são meticulosamente verificadas, pois altos níveis de umidade podem comprometer o isolamento e reduzir a eficácia do comutador, afetando negativamente a operação do transformador.

Portanto, cada variável monitorada tem um papel distinto e vital na manutenção da integridade, eficiência e segurança dos transformadores de potência, evidenciando a necessidade de um sistema de monitoramento robusto e confiável.

5.2 Análise Exploratória e Pré-processamento

Durante o processo de análise dos dados coletados, observou-se que as variáveis de capacitância e tangente delta apresentaram variações mínimas ao longo do período analisado. Devido à sua estabilidade e baixa variação, essas variáveis foram desconsideradas no pré-processamento de dados, uma vez que não contribuíram significativamente para a modelagem.

Foi realizada uma avaliação dos elementos ausentes na base de dados utilizada (Figura 4) e durante o processo de inspeção dos dados, foi identificado que a base de dados contém várias lacunas. O transformador T2 apresentou a maioria das grandezas com 20% de dados ausentes em comparação com os dados de T1 porque a aquisição dos dados para o T2 iniciou-se posteriormente, resultando em uma quantidade menor de dados disponíveis para o período analisado. Os dados zerados são poucos em relação ao total. Além disso, algumas variáveis como umidade no T1 e temperatura do óleo no T2 apresentaram um grande número de dados faltantes, que foram causados possivelmente por problemas de rede, configuração e comunicação no monitoramento.

O gráfico com a mesma análise (Figura 5), agora apenas para os dados de 2024, em que se tinha informação de que ambos os dados de monitoramento de T1 e T2 estavam




Figura 4 – Distribuição de valores ausentes e zeros por variável

em funcionamento, mostra que o problema de dados faltantes com o T2 cessou, e ocorreu apenas para uma variável isolada como a temperatura do óleo, e ainda algumas variáveis no T1. A quantidade igual de elementos zero em algumas variáveis indica claramente perda de comunicação ou problemas na aquisição de dados na fonte de monitoramento.




Figura 5 – Distribuição de valores ausentes e nulos por variável em 2024

O histograma da base de dados utilizada é mostrado na Figura 6, e a análise da imagem mostra que existem outliers que precisam ser eliminados principalmente em relação

às grandezas de temperatura do óleo e enrolamento, que apresentam indicações de valores impraticáveis.




Figura 6 – Histograma de distribuição das variáveis da base de dados

Os outliers foram identificados com base no método do Intervalo Interquartil (IQR) e foram substituídos pelos valores médios das variáveis, exceto os valores ausentes e nulos, que normalmente indicam perda de comunicação dos dados na prática. O histograma resultante da base de dados tratada é mostrado na Figura 7.




Figura 7 – Histograma com dados corrigidos

Para lidar com os valores ausentes na base de dados, foi realizada uma interpolação linear pelo natureza dos dados ligada a uma série histórica temporal. A substituição dos valores ausentes pela média ajuda a manter a coerência dos dados sem introduzir viés significativo, dado o baixo percentual de valores ausentes da grande maioria das variáveis monitoradas.

A matriz de correlação (Figura 8) desta base de dados tratada mostra algumas características como alta correlação positiva entre variáveis análogas de operação dos transformadores, tais como, frequência (0,99), corrente (0,95), potência aparente (0,95), potência ativa (0,95), posição do tap (0,98), potência reativa (0,90) e tensão (0,99). Essa característica era esperada devido à natureza interconectada e funcional dos sistemas elétricos de potência.

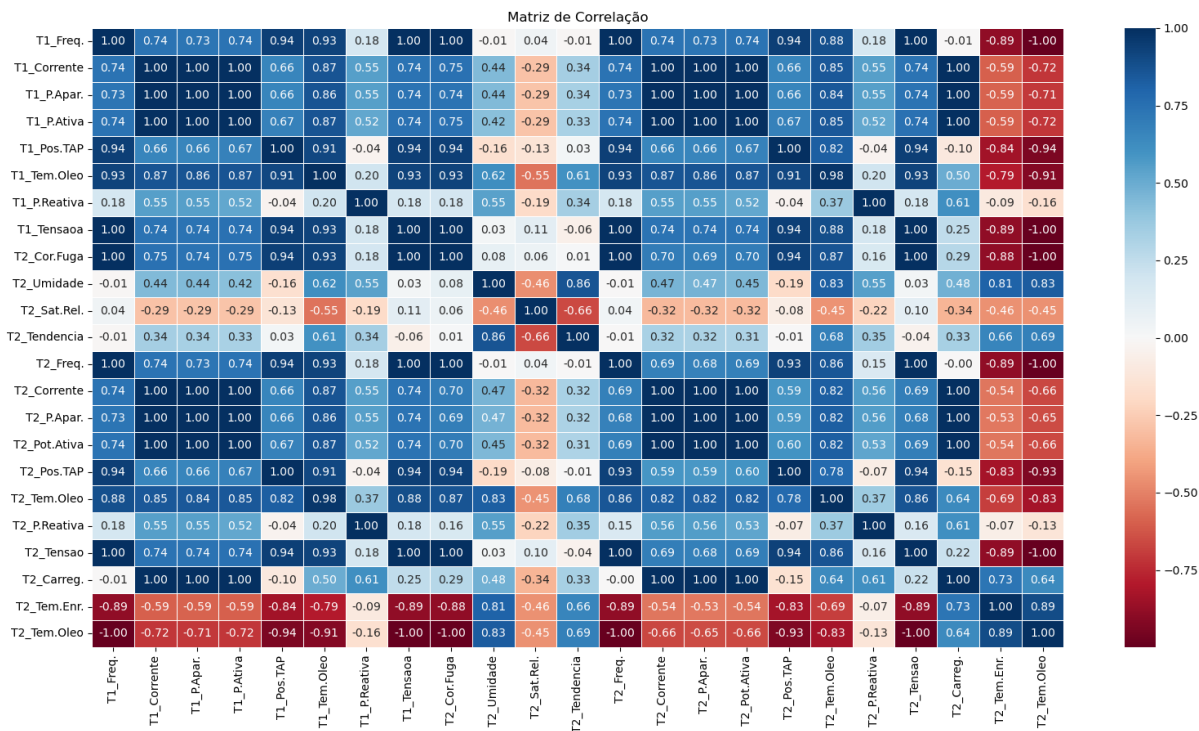


Figura 8 – Matriz de Correlação das variáveis

A alta correlação entre a temperatura do óleo e a temperatura do enrolamento (0,99) é esperada devido à função do óleo em transferir calor dos enrolamentos. Esse comportamento ajuda a monitorar o estado térmico do transformador e garantir seu funcionamento seguro e eficiente. Possuem também altas correlações com o carregamento do transformador (0,62 e 0,71).

A umidade do óleo do comutador também tem correlação positiva significativa com a temperatura do óleo (0,46) e do enrolamento (0,44). As altas correlações entre grandezas de operação como tensão e frequência (1,00) e entre potências já era esperada fruto do natureza e definições destas grandezas no funcionamento do sistema de potência.

5.3 Análise de Componentes Principais

Com a base de dados já preparada, foram selecionadas as variáveis alvo. Foram escolhidos os valores dos sistemas de monitoramento de temperatura, buchas e umidade, porque as variáveis de operação estão sempre disponíveis e obrigatórias nos centros de operação do sistema elétrico.

O PCA foi aplicado aos dados de entrada aos dados de entrada (grandezas de monitoramento) para reduzir sua dimensionalidade. Isso significa transformar os dados originais em um novo espaço onde cada nova característica (ou componente principal) é uma combinação linear das características originais. A quantidade de componentes principais escolhidas depende da quantidade de variância que se quer explicar com essas componentes

5.4 Construção do MVP

5.4.1 Introdução

O Produto Mínimo Viável (MVP) representa a primeira iteração do modelo preditivo que estamos desenvolvendo, projetado especificamente para testar sua eficácia no mundo real antes de prosseguir com uma implementação mais abrangente. Este MVP visa fornecer uma solução prática para o monitoramento e gestão de ativos em tempo real, ajudando a avaliar rapidamente a validade e a eficiência da proposta.

5.4.2 Validação pelo cliente

Antes de finalizarmos e lançarmos o modelo oficialmente, é essencial passá-lo por um rigoroso processo de validação com o cliente. Esta fase crítica assegura que o modelo não só atenda às necessidades específicas do cliente mas também funcione adequadamente em condições reais. Durante esta etapa, o modelo é testado usando tanto dados reais quanto simulados para verificar sua precisão e confiabilidade. Além disso, especialistas do setor de energia, que fazem parte da nossa equipe de desenvolvimento, avaliam meticulosamente os módulos para garantir que estejam à altura dos padrões exigidos.

5.4.3 Integração no software

Uma vez validado, o modelo será integrado ao módulo Sapiens do sistema SOMA, que é desenvolvido em Python (Figura 9). Este módulo processa os dados brutos de monitoramento e utiliza o modelo preditivo para gerar previsões detalhadas sobre a condição dos ativos. Os resultados são então apresentados na interface do usuário do SOMA, que suporta a visualização através de gráficos históricos, análises gráficas detalhadas e dashboards interativos. Esta funcionalidade não apenas enriquece a experiência do usuário, mas também facilita a interpretação dos dados, permitindo aos gestores configurar alarmes

e notificações baseadas em condições específicas identificadas pelo modelo. Isso contribui para uma gestão e monitoramento contínuos dos ativos, otimizando processos e prevenindo falhas.




Figura 9 – Integração do modelo na solução para o cliente final

5.4.4 Conclusão

Uma vez validado e integrado ao módulo Sapiens, o MVP oferecerá uma solução robusta e abrangente para o monitoramento e gestão de ativos no setor elétrico. A combinação com o sistema SOMA abre caminho para análises avançadas e monitoramento em tempo real, melhorando significativamente a tomada de decisões e a manutenção proativa de equipamentos essenciais como transformadores. Este processo não só aumenta a eficiência operacional, mas também amplia a vida útil dos ativos e promove uma gestão mais eficaz do desempenho, dos relatórios e das operações de manutenção.

6 ANÁLISE DE RESULTADOS

6.1 Pré-processamento e escolha dos modelos

Considerando a variável umidade do transformador T1 como alvo, após a limpeza de dados seu histograma e boxplot estão mostrados na Figura 10.




Figura 10 – Histograma e Boxplot da variável umidade

A análise de componentes principais (PCA) revelou que 95% da variância total dos dados pode ser explicada por 7 componentes principais. Isso significa que esses 7 componentes capturam quase toda a informação presente nas variáveis originais, permitindo uma redução significativa da dimensionalidade, sem perder muito da variabilidade e estrutura essencial dos dados (Figura 11).

Embora o tempo computacional aplicado aos modelos sem o uso de PCA não tenha impactado significativamente neste caso, optamos por utilizar os dados sem redução de dimensionalidade. No entanto, para conjuntos de dados muito grandes, contendo informações de monitoramento de milhares de ativos, o uso do PCA pode ser uma técnica valiosa. Ao aplicar o PCA, é necessário escolher uma variância explicada que garanta que o modelo capture bem as características dos dados e reduza o esforço computacional, sem perder informações relevantes.

Após o pré-processamento, dividimos os dados em dois subconjuntos: um conjunto de treinamento e um conjunto de teste, seguindo a proporção clássica de 80% para




Figura 11 – Histograma e Boxplot da variável umidade

treinamento e 20% para teste. Essa divisão permite que o modelo seja treinado em uma quantidade significativa de dados e, posteriormente, avaliado em um conjunto separado, garantindo que o desempenho do modelo seja medido de forma justa e representativa da sua capacidade de generalização para novos dados.




Figura 12 – Tempo de execução dos modelos (em segundos)

Os modelos escolhidos para o trabalho foram XGBoost, RandomForest, Gradient-Boosting, LightGBM, CatBoost, ExtraTrees, e AdaBoost, devido ao seu bom desempenho

no tratamento de séries temporais de dados provenientes de sistemas de monitoramento. Esses algoritmos baseados em árvores são robustos e eficazes ao lidar com grandes volumes de dados e conseguem capturar de forma eficiente padrões complexos, variações temporais e dependências entre as observações. Além disso, são modelos que oferecem flexibilidade em ajustes de hiperparâmetros.

O gráfico da Figura 12 compara o tempo de execução dos modelos selecionados, representando o tempo em segundos para cada um. É possível perceber que para esta base de dados o tempo foi muito baixo e não impediu a criação de modelo em nenhum dos casos, mas observando os números vemos que modelos como XGBoost, LightGBM e CatBoost apresentam tempos relativamente menores que RandomForest.

6.2 Avaliação de desempenho

Os dados preditos pelo modelo, comparados com os valores reais do conjunto teste, são mostrados na Figura 13 (AdaBoost), Figura 14 (CatBoost), Figura 15 (ExtraTrees), Figura 16 (GradientBoosting), Figura 17 (LightGBM), Figura 18 (RandomForest) e Figura 19 (XGBoost).

Para avaliar a precisão e a capacidade preditiva do modelo, foram utilizadas diversas métricas de desempenho, como o Erro Quadrático Médio (MSE) e o Coeficiente de Determinação (R^2). O MSE quantifica a diferença entre os valores preditos e os valores observados, enquanto o R^2 indica a proporção da variabilidade dos dados que é explicada pelo modelo.

A Tabela 2 mostra a diferença entre valores MSE e R^2 para aplicação dos modelos mencionados, além do tempo computacional de execução. O modelo ExtraTrees, apresentou melhor resultado, pois teve o menor MSE e o R^2 próximos aos demais. Embora o tempo de execução não tenha sido baixo como do XGBoost, para essa aplicação ele não interfere na aplicabilidade da solução. A solução AdaBoost apresentou um maior erro, o que é perceptível ao olhar graficamente, em que se percebe que o modelo não conseguiu acompanhar alguns valores mais fora da média.

Tabela 2 – Modelos Aplicados e métricas de desempenho

Método	MSE	R2 score	Tempo de Execução
XGBoost	0.39	0.97	0.76 s
RandomForest	0.12	0.99	101.15 s
GradientBoosting	0.86	0.94	24.14 s
LightGBM	0.42	0.97	0.74 s
CatBoost	0.66	0.95	1.26 s
ExtraTrees	0.08	0.99	32.10 s
AdaBoost	2.83	0.80	23.54 s

Fonte: Elaborada pelo autor.

O modelo Adaboost não consegue captar os valores mais extremos de umidade, como é perceptível. Já o Catboost consegue chegar próximo visivelmente destes valores.




Figura 13 – Comparação entre valores reais e preditos - Método AdaBoost.




Figura 14 – Comparação entre valores reais e preditos - Método CatBoost

O Modelo ExtraTrees foi o que melhor percebeu as variações dos valores e o gráfico de grandezas reais e preditas quase se confunde. O GradienteBoosting teve o mesmo problema dos demais, quando os valores se afastavam da média.




Figura 15 – Comparação entre valores reais e preditos - Método ExtraTrees




Figura 16 – Comparação entre valores reais e preditos - Método GradientBoosting

Os modelo LightGBM apresentou o mesmo comportamentos que os demais, com dificuldade em acompanhar valores mais extremos. O Modelo RandomForest apresentou um ótimo resultado, o seu problema é que o modelo salvo no computador é muito pesado (para este caso, cerca de 300 Mb, em comparação a valores como 200 KB ao salvar no formato joblib no computador).




Figura 17 – Comparação entre valores reais e preditos - Método LightGBM




Figura 18 – Comparação entre valores reais e preditos - Método RandomForest

O modelo XGBoost apresenta bom resultado, embora tenho os mesmos problemas que o demais de alcance em valores extremos. Sua vantagem é um tempo de execução muito baixo, e pode ser utilizado facilmente com outras features.




Figura 19 – Comparação entre valores reais e preditos - Método XGBoost

6.3 Novas abordagens

Novas abordagens foram adotadas pensando na escalabilidade da solução. A primeira delas foi a criação e treinamento de novos modelos, tomando como dados de entrada apenas as informações de monitoramento do transformador T1. Isso é importante porque muitos equipamentos são monitorados de forma isolada, em outras subestações, e modelos equivalentes a esses podem ser construídos, e aplicados a novos equipamentos com características semelhantes de funcionamento e que não possuam tal monitoramento.

Os tempos de execução e métricas de avaliação dos modelos para o caso em que apenas os dados do Transformador T1 são utilizados para o treinamento do modelo são mostrados na Tabela 3. Os modelos se comportaram de forma análoga, tanto para os erros, tempo de execução como para comparação gráfica entre valores reais e preditos.

Tabela 3 – Modelos e desempenho (Entrada de dados: Transformador T1)

Método	MSE	R2 score	Tempo de Execução
XGBoost	0.73	0.95	0.48 s
RandomForest	0.20	0.99	50.61 s
GradientBoosting	1.45	0.90	12.99 s
LightGBM	0.68	0.77	0.94 s
CatBoost	1.18	1.18	0.92 s
ExtraTrees	0.11	0.99	23.45 s
AdaBoost	3.00	0.79	13.57 s

Fonte: Elaborada pelo autor.

Outra abordagem envolve a troca da variável alvo para Temperatura do Enrolamento. Esta temperatura é chamada de hot spot e é a de maior valor medido. Os dados escolhidos foram apenas os do transformador T1. O histograma e gráfico boxplots desta variável, já recebidos os devidos tratamentos, são mostrados na Figura 20. A previsão dos valores comparada aos valores reais foi semelhante a análise da umidade e pode ser vista no exemplo do modelo ExtraTrees na Figura 21.




Figura 20 – Histograma dos dados tratados (Variável alvo: temperatura do enrolamento)




Figura 21 – Valor predito x real para temperatura do enrolamento como alvo

Em relação ao tempo execução e análise de desempenho via MSE e R2 (Tabela 4), o modelo obteve desempenhos similares à análise da umidade, porém com um aumento do erro quadrático.

Tabela 4 – Modelos e desempenho (Variável alvo: temperatura do enrolamento)

Método	MSE	R2 score	Tempo de Execução
XGBoost	0.11	1.00	0.41 s
RandomForest	0.05	1.00	34.90 s
GradientBoosting	0.08	1.00	11.22 s
LightGBM	0.06	1.00	0.48 s
CatBoost	0.07	1.00	1.03 s
ExtraTrees	0.04	1.00	12.01 s
AdaBoost	1.01	0.96	9.75 s

Fonte: Elaborada pelo autor.

A temperatura do enrolamento está diretamente relacionada com a carga do transformador, as condições de operação e a dissipação de calor no óleo. Essa variável tem um comportamento mais previsível e está fortemente acoplada ao desempenho elétrico do transformador, respondendo diretamente a variações na corrente e na carga aplicada. Por isso, os modelos preditivos conseguem capturar com mais precisão essas mudanças, resultando em erros menores nas previsões.

A temperatura do enrolamento é uma variável crucial no monitoramento de transformadores, pois permite identificar sobrecargas, diagnosticar falhas no sistema de resfriamento, acionar alarmes em sistemas de monitoramento, suportar a manutenção preditiva e reduzir riscos de falhas catastróficas, prolongando a vida útil do equipamento e protegendo o investimento.

Ao se utilizar o modelo treinado XGBoost (Figura 22) ou LightGBM com a entrada de dados original, considerando grandezas dos transformadores T1 e T2, porém agora considerando como features apenas dados de operação do transformador T2 (que são informações sempre disponíveis), e prevendo a variável umidade, os valores não apresentaram bons resultados. Isso acontece pela natureza de funcionamento do sistema elétrico, com vários equipamentos conectados, sistemas complexos que variam constantemente com a carga (consumo), condições atmosféricas, condições meteorológicas etc., desta forma, quanto mais informações de monitoramento possíveis, mais características os modelos conseguem absorver, e mais precisos ficam as previsões.

Por fim, um aspecto interessante é a não utilização das grandezas de saturação relativa e tendência na criação do modelo. Isso implica em como se o monitor de umidade não estivesse instalado. Este fato acontece muito nos ativos por conta dos altos custos de aquisição e manutenção destes sistemas. Treinando os modelos nesta condição chega-se aos desempenhos mostrados na Tabela 5.




Figura 22 – Comparação valores preditos pelo modelo e reais, aplicando menos features como entrada no modelo XGBoost (resultados ruins)

Tabela 5 – Modelos e desempenho (sem monitor de umidade no treinamento)

Método	MSE	R2 score	Tempo de Execução
XGBoost	2.23	0.84	0.44 s
RandomForest	0.83	0.94	43.92 s
GradientBoosting	3.23	0.77	11.73 s
LightGBM	2.27	0.84	0.45 s
CatBoost	2.96	0.79	1.07 s
ExtraTrees	0.59	0.96	18.99 s
AdaBoost	4.21	0.70	12.27 s

Fonte: Elaborada pelo autor.

Os modelos ExtraTrees e RandomForest apresentaram os menores erros MSE, abaixo dos outros modelos e podem ser utilizados para este tipo de predição de dados em sistemas de monitoramento. Esta informação, dentro de um sistema de avaliação de desempenho de ativos, pode disparar um alarme, ou notificação, alertando aos engenheiros essa tendência de crescimento.

A Figura 23 mostra um trecho do tempo de comparação entre valores preditos e reais para o modelo RandomForest aplicado sem utilização das características do monitor de umidade (que calcula umidade do óleo, saturação relativa e tendência de evolução). É possível perceber o quão próximo o modelo chega dos valores reais. O mesmo ocorre para o modelo ExtraTrees (Figura 24).




Figura 23 – Comparação valores preditos pelo modelo e reais, aplicando modelo RandomForest em um determinado trecho




Figura 24 – Comparação valores preditos pelo modelo e reais, aplicando modelo ExtraTrees em outro trecho de predição

7 CONCLUSÕES

A aplicação de técnicas de Inteligência Artificial (IA) no monitoramento online de transformadores de potência apresentou um grande potencial para transformar a maneira como a manutenção desses ativos críticos é realizada no setor elétrico. A abordagem tradicional, baseada em manutenção preventiva e corretiva, não é insuficiente para lidar com as demandas modernas de confiabilidade e eficiência. Com o uso de algoritmos como Random Forest, XGBoost e ExtraTrees, aliada à redução de dimensionalidade por PCA, é possível prever características da condição dos ativos que darão subsídios à manutenção preditiva. Esse avanço não apenas otimiza a manutenção, mas também contribui para a redução de custos e o aumento da confiabilidade dos sistemas elétricos.

Os resultados deste estudo indicam que a implementação de modelos em sistema de desempenho de ativos elétricos, utilizado por diversas empresas do setor, pode melhorar a gestão destes ativos. A capacidade de monitorar em tempo real ou prever a partir de modelos variáveis críticas como temperatura do óleo, umidade e corrente dos transformadores permite identificar padrões de degradação e antecipar falhas que, de outra forma, passariam despercebidas até o momento de uma falha. Essa abordagem possibilita que as equipes de manutenção atuem de forma proativa, substituindo ou reparando componentes antes que falhem de forma catastrófica, evitando interrupções inesperadas no fornecimento de energia.

Além disso, a integração de técnicas de IA com sistemas de monitoramento já existentes, demonstra a viabilidade de incorporar soluções tecnológicas avançadas sem a necessidade de reestruturar completamente a infraestrutura de monitoramento das empresas. O uso de dados históricos e em tempo real aumenta a precisão dos modelos, e a implementação dessas soluções pode ser escalada para diferentes ativos, além dos transformadores de potência, sempre pensando na avaliação do risco técnico financeiro do ativo para a empresa.

REFERÊNCIAS

- AGGARWAL, C. C. **Outlier analysis**. 2nd. ed. New York, NY: Springer, 2017.
- ANTONIADIS, I.; KOUROUSSIS, G.; KIRYTOPOULOS, K. Online condition monitoring in electrical power systems: Trends and challenges. **Journal of Electrical Engineering & Technology**, v. 15, n. 1, p. 1–11, 2020.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, n. 1, p. 5–32, 2001.
- BROWN, A.; REHTANZ, C. Condition monitoring for real-time asset management in power systems. **IEEE Transactions on Smart Grid**, v. 9, n. 6, p. 6860–6868, 2018.
- CEPEL. **SOMA 2 - Sistema de Otimização da Manutenção de Ativos**. 2024. Acesso em: 22 set. 2024. Available at: <https://www.cepel.br/produtos/soma-2/>.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. *In: Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 785–794.
- COMPANY, M. . How analytics can improve asset management in electric-power networks. **McKinsey Insights**, 2021. Available at: <https://www.mckinsey.com/industries/electric-power-and-natural-gas/our-insights/how-analytics-can-improve-asset-management-in-electric-power-networks>.
- GARCÍA, S.; LUENGO, J.; HERRERA, F. **Data preprocessing in data mining**. [S.l.: s.n.]: Springer International Publishing, 2015.
- GOMEZ-EXPOSITO, A.; CONEJO, A. J.; CANIZARES, C. A. Benchmarking in power system asset management: Concepts, challenges, and opportunities. **IEEE Power and Energy Magazine**, IEEE, v. 17, n. 1, p. 80–89, 2019.
- GUPTA, A.; JAIN, R. Iot-based smart grid system for monitoring and control of electrical energy. **Materials Today: Proceedings**, Elsevier, v. 46, p. 4833–4838, 2020.
- HAN, J.; KAMBER, M.; PEI, J. **Data mining: Concepts and techniques**. 3rd. ed. Burlington, MA: Morgan Kaufmann, 2011.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2nd edition. ed. [S.l.: s.n.]: OTexts, 2018. Available at <https://otexts.com/fpp2/>.
- JOLLIFFE, I. T. Principal component analysis. **Springer series in statistics**, Springer, 2002.
- LEWIS, M. A.; DESOUZA, K. C. Benchmarking in maintenance engineering: a state-of-the-art review. **Journal of Quality in Maintenance Engineering**, Emerald Publishing Limited, v. 25, n. 3, p. 352–375, 2019.
- PEREIRA, C.; COSTA, A. Optimizing energy dispatch with artificial intelligence: Real-time machine learning applications for grid efficiency and sustainability. **Energy Systems and AI Review**, Elsevier, v. 18, p. 230–245, 2022.

POWERS, D. M. Evaluation: From precision, recall and f-measure to roc, informedness, markedness and correlation. **Journal of Machine Learning Technologies**, v. 2, n. 1, p. 37–63, 2020.

PUGNA, I. B. *et al.* Management perspectives towards the data-driven organization in the energy sector. **Energies**, v. 15, n. 16, p. 5775, 2022.

PWC. **Sizing the prize: What’s the real value of AI for your business and how can you capitalise?** 2019. Accessed: 2023-09-23. Available at: <https://www.pwc.com/gx/en/issues/analytics/assets/pwc-ai-analysis-sizing-the-prize-report.pdf>.

RESEARCH, G. V. **Artificial Intelligence Market Size, Share & Trends Analysis Report By Solution, By Technology, By End-use, By Region And Segment Forecasts, 2020 - 2027**. 2020. Accessed: 2023-09-23. Available at: <https://www.grandviewresearch.com/industry-analysis/artificial-intelligence-ai-market>.

SILVA, J.; OLIVEIRA, M. The transformative potential of artificial intelligence in energy systems management: A focus on demand forecasting. **Journal of Energy and Artificial Intelligence**, Springer, v. 35, p. 102–118, 2024.

WICKHAM, H.; GROLEMUND, G. **R for data science: Import, tidy, transform, visualize, and model data**. Sebastopol, CA: O’Reilly Media, 2017.