



UNIVERSIDADE FEDERAL DO MARANHÃO  
Curso de Engenharia da Computação

João Pedro de Alcântara Lima

**Reconhecimento de padrões interruptivos em  
redes elétricas de distribuição utilizando  
*Machine Learning***

São Luís  
2025

João Pedro de Alcântara Lima

**Reconhecimento de padrões interruptivos em redes elétricas de distribuição utilizando *Machine Learning***

Monografia apresentada ao curso de Engenharia da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia da Computação.

Orientador: Prof. Dr. Haroldo Gomes Barroso Filho

São Luís

2025

João Pedro de Alcântara Lima

## **Reconhecimento de padrões interruptivos em redes elétricas de distribuição utilizando *Machine Learning***

Monografia apresentada ao curso de Engenharia da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia da Computação.

Trabalho em São Luís, 28 de fevereiro de 2025:

---

**Prof. Dr. Haroldo Gomes Barroso  
Filho**  
Orientador

---

**Prof. Dr. Sofiane Ben El Hedi Labidi**  
Examinador

---

**Profa. Dra. Pedro Baptista Fernandes**  
Examinador

São Luís  
2025

# Agradecimentos

A conclusão deste trabalho não seria possível sem o apoio, carinho e incentivo de pessoas especiais em minha vida.

Primeiramente, agradeço a Deus pela força, saúde e sabedoria concedidas ao longo desta jornada.

À minha querida avó, Merice Franca Alcantara, cuja experiência e sabedoria sempre me inspiraram a seguir em frente, mesmo nos momentos mais desafiadores. Sua fé e amor incondicional são um exemplo de vida que carrego comigo todos os dias.

À minha mãe, Adriana Franca Alcantara, que sempre acreditou em mim e me deu o suporte necessário para alcançar meus sonhos. Sua dedicação, sacrifícios e conselhos me guiaram ao longo de toda a minha trajetória acadêmica. Não há palavras suficientes para expressar minha gratidão por todo o amor e apoio que você me proporcionou.

Ao meu pai, George Hamilton Martins Lima, que sempre custeou meus estudos e me proporcionou as condições necessárias para trilhar esse caminho. Seu esforço e dedicação foram fundamentais para que eu pudesse chegar até aqui.

Agradeço também à minha namorada, Isadora Serra Martins, por seu carinho, compreensão e incentivo ao longo dessa caminhada. Seu apoio inestimável e presença constante fizeram toda a diferença nos momentos desafiadores. Obrigado por acreditar em mim e por compartilhar comigo essa jornada.

Agradeço à minha tia, Mary Jane França Alcântara, que me dava aulas particulares no fundo de quintal de casa. Sua dedicação e paciência foram essenciais para minha formação e aprendizado.

Agradeço também aos meus professores e colegas, que contribuíram de maneira significativa para o desenvolvimento deste trabalho, oferecendo conhecimentos, sugestões e críticas construtivas.

Por fim, a todos que, direta ou indiretamente, participaram desta caminhada, deixo aqui meu mais sincero agradecimento.

*"As melhores ideias são as perigosas. Se acomode ou se incomode. A fé não vale de nada pra mente preguiçosa."*

Filipe Ret, *"Neurótico de Guerra."*

# Resumo

O trabalho "Reconhecimento de padrões interruptivos em redes elétricas de distribuição utilizando *Machine Learning*" aborda a aplicação de técnicas de *Machine Learning* para identificar e analisar padrões de interrupção em redes de distribuição de energia elétrica. O objetivo principal é aprimorar a gestão e a eficiência operacional das redes elétricas ao entender melhor os eventos de interrupção e suas causas.

Inicialmente, o estudo utiliza dados históricos sobre interrupções de energia elétrica, coletados a partir de uma fonte pública disponibilizados em formatos acessíveis, como CSV (Agência Nacional de Energia Elétrica - ANEEL, 2024). Esses dados incluem informações críticas sobre indicadores do segmento de distribuição de energia, contendo descrições de Duração Equivalente de Interrupção por Unidade Consumidora (DEC), Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), além de registros de interrupções, Tempo Médio de Atendimento a Emergências (TMAE), Tempo Médio de Preparação (TMP), Tempo Médio de Deslocamento (TMD) e Tempo Médio de Execução (TME).

O processo de análise de dados começa com a importação e união das bases de dados no Python, essencial para garantir a avaliação dos dados históricos. Em seguida, foi aplicado técnicas como *Clustering* para detectar anomalias, identificando padrões incomuns que podem indicar despadronização nos dados. A visualização dos dados é realizada através da biblioteca *matplotlib*, permitindo entender a distribuição dos dados e identificar os indicadores.

Os resultados obtidos permitem uma melhor compreensão dos eventos de interrupção, facilitando a identificação de áreas que requerem manutenção preventiva ou corretivas. A análise também oferece *insights* sobre a eficiência das operações de distribuição de energia, possibilitando decisões mais informadas e estratégias mais eficazes para a gestão das redes elétricas.

O trabalho conclui que o uso de *Machine Learning* para o reconhecimento de padrões interruptivos pode significativamente melhorar a capacidade das empresas de energia em gerenciar e otimizar suas operações, reduzindo o impacto das interrupções e aumentando a confiabilidade do fornecimento de energia.

**Palavras-chave:** *Machine Learning*, Duração Equivalente de Interrupção por Unidade Consumidora (DEC), Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), Tempo Médio de Atendimento a Emergências (TMAE), Tempo Médio de Preparação (TMP), Tempo Médio de Deslocamento (TMD) e Tempo Médio de Execução (TME).

# Abstract

The work "Pattern Recognition of Disruptive Events in Energy Distribution Networks using *Machine Learning*" addresses the application of *Machine Learning* techniques to identify and analyze patterns of interruptions in electrical energy distribution networks. The main objective is to enhance the management and operational efficiency of electrical networks by better understanding interruption events and their causes.

Initially, the study uses historical data on electrical power interruptions, collected from a publicly available source provided in accessible formats such as CSV ([Agência Nacional de Energia Elétrica - ANEEL, 2024](#)). This data includes critical information about indicators in the energy distribution segment, containing descriptions of Equivalent Duration of Interruption per Consumer Unit (DEC), Equivalent Frequency of Interruption per Consumer Unit (FEC), as well as records of interruptions, Average Emergency Response Time (TMAE), Average Preparation Time (TMP), Average Travel Time (TMD), and Average Execution Time (TME).

The data analysis process begins with the import and merging of databases in *Python*, which is essential to ensure the evaluation of historical data. Subsequently, techniques such as *Clustering* were applied to detect anomalies, identifying unusual patterns that may indicate inconsistencies in the data. Data visualization is performed using the *pyplot* library, allowing for an understanding of data distribution and the identification of key indicators.

The results obtained allow for a better understanding of interruption events, facilitating the identification of areas that require preventive or corrective maintenance. The analysis also provides *insights* into the efficiency of energy distribution operations, enabling more informed decisions and more effective strategies for managing electrical networks.

The work concludes that the use of *Machine Learning* for recognizing disruptive patterns can significantly improve the ability of energy companies to manage and optimize their operations, reducing the impact of interruptions and increasing the reliability of power supply.

**Keywords:** *Machine Learning*, Equivalent Duration of Interruption per Consumer Unit (DEC), Equivalent Frequency of Interruption per Consumer Unit (FEC), Average Emergency Response Time (TMAE), Average Preparation Time (TMP), Average Travel Time (TMD), and Average Execution Time (TME).

# Lista de ilustrações

Figura 1 – Fonte: Autor . . . . .	18
Figura 2 – <i>Cluster</i> de distribuidoras com base no TMAE e Número de ocorrências	21
Figura 3 – Detecção de <i>outliers</i> do número de interrupções . . . . .	23
Figura 4 – Detecção de <i>outliers</i> do número de interrupções . . . . .	24
Figura 5 – Previsão do fechamento de DEC e Limite de 2024 a partir da regressão dos dados históricos de 2014 a 2023 com <i>ARIMA</i> . . . . .	25
Figura 6 – Top 10 distribuidoras com maior quantidade de ocorrências de 2020 a 2024 . . . . .	27
Figura 7 – Top 10 distribuidoras com maior DEC de 2020 a 2024 . . . . .	28
Figura 8 – Comparação das distribuidoras com maior DEC de 2020 a 2023 . . . . .	29
Figura 9 – Top 10 distribuidoras com maior FEC de 2020 a 2024 . . . . .	30
Figura 10 – Comparação das distribuidoras com maior FEC de 2020 a 2023 . . . . .	31
Figura 11 – Distribuidoras ofensoras de TMAE, TME, TMP e TMD no cenário de 2020 a 2024 . . . . .	32
Figura 12 – Distribuidora-Ano-Mês ofensores de TMAE, TME, TMP e TMD . . . . .	33

# Lista de tabelas

# Lista de abreviaturas e siglas

EC *Engenharia da Computação*

UFMA *Universidade Federal do Maranhão*

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
<b>1.1</b>	<b>Objetivos</b>	<b>11</b>
1.1.1	Objetivos Específicos	12
<b>1.2</b>	<b>Estrutura do Trabalho</b>	<b>12</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>13</b>
<b>2.1</b>	<b>Indicadores de Continuidade e Interrupções</b>	<b>14</b>
<b>2.2</b>	<b>Base de Dados e Reconhecimento de Padrões</b>	<b>15</b>
<b>2.3</b>	<b>Importância da Análise de Indicadores</b>	<b>15</b>
<b>2.4</b>	<b>Contribuições da Análise de Padrões Interruptivos</b>	<b>16</b>
<b>2.5</b>	<b>Trabalhos Relacionados</b>	<b>16</b>
<b>3</b>	<b>METODOLOGIA</b>	<b>18</b>
<b>3.1</b>	<b>Fluxograma de trabalho</b>	<b>18</b>
<b>3.2</b>	<b>Importação e Pré-processamento dos Dados</b>	<b>19</b>
3.2.1	Utilização de Bibliotecas <i>Python</i>	19
3.2.2	Normalização e Transformação dos Dados	19
3.2.3	Organização dos Dados para Análise e Modelagem	20
<b>3.3</b>	<b>Técnicas Aplicadas e projeção de Indicadores com base histórica</b>	<b>20</b>
3.3.1	Clusterização com <i>K-Means</i>	20
3.3.2	Detecção de <i>Outliers</i> com <i>Isolation Forest</i>	22
3.3.3	Projeção do Indicador DEC com Modelos <i>ARIMA</i>	25
<b>4</b>	<b>RESULTADOS</b>	<b>27</b>
<b>5</b>	<b>CONCLUSÃO</b>	<b>34</b>
	<b>REFERÊNCIAS</b>	<b>35</b>

# 1 Introdução

O reconhecimento de padrões interruptivos em redes de distribuição de energia elétrica é um desafio fundamental para garantir a confiabilidade e a eficiência no fornecimento de energia. Interrupções inesperadas podem causar impactos significativos, desde a desconexão temporária de clientes até problemas mais complexos que afetam a operação da rede elétrica como um todo. Identificar e avaliar esses padrões é essencial para a melhoria contínua da infraestrutura elétrica e para a minimização dos impactos adversos. Estudos recentes têm explorado diversas abordagens para lidar com essas interrupções, incluindo o uso de aprendizado de máquina e redes elétricas inteligentes (ZANCHETTA, 2014).

Com o avanço das técnicas de pré-processamento de dados e aprendizado de máquina, tornou-se possível lidar com o desafio de maneira mais eficaz. Ferramentas e métodos modernos permitem a análise detalhada dos dados históricos, oferecendo *insights* valiosos sobre as causas e a frequência das interrupções. Neste trabalho, utilizou-se o *K-Means* da biblioteca *sklearn.cluster* para realizar o agrupamento e a detecção de padrões, o *Isolation Forest* da biblioteca *sklearn.ensemble* para a identificação de *outliers*, e o *ARIMA* da *statsmodels* para realizar previsões ao qual está bem fundamentado no artigo de (IBM, 2024), especialmente no que diz respeito ao comportamento das interrupções ao longo do tempo.

A análise e o pré-processamento dos dados foram realizados utilizando *Python*, que, juntamente com as bibliotecas mencionadas, forneceu uma base robusta para a execução dos modelos de aprendizado de máquina e a análise de séries temporais. Além disso, o *StandardScaler* da biblioteca *sklearn.preprocessing* foi utilizado para normalizar os dados, garantindo que todos os parâmetros fossem tratados de maneira eficiente.

O objetivo deste trabalho é demonstrar como a combinação de técnicas de aprendizado de máquina, como o *K-Means*, *Isolation Forest* e *ARIMA*, pode aprimorar a capacidade das empresas de energia em prever, identificar e gerenciar interrupções de maneira mais precisa e eficiente. Ao integrar esses métodos com ferramentas de análise e visualização de dados, busca-se fornecer *insights* valiosos para a melhoria da operação das redes elétricas, contribuindo para um fornecimento de energia mais confiável e contínuo.

## 1.1 Objetivos

O objetivo geral deste trabalho é aprimorar a análise e a gestão das interrupções em redes de distribuição de energia elétrica por meio da aplicação de técnicas de análise

de dados e *Machine Learning*. Utilizando ferramentas de análise de dados e métodos como *K-Means*, *Isolation Forest* e *ARIMA*, busca-se identificar e entender padrões de interrupção, com o intuito de melhorar a eficiência operacional das redes elétricas e garantir um fornecimento de energia mais confiável e contínuo.

### 1.1.1 Objetivos Específicos

Destaca-se como objetivos específicos deste trabalho:

- Avaliar as principais distribuidoras com maior quantidade de interrupções, utilizando técnicas de *Machine Learning* para segmentação e clusterização dos dados.
- Prever o comportamento da Duração Equivalente de Interrupção por Unidade Consumidora (DEC) utilizando o modelo *ARIMA* baseado em séries temporais.
- Avaliar os indicadores de desempenho operacional, como TMAE, TME, TMD e TMP, por distribuidora ao longo dos meses e anos, utilizando análise de dados avançada.
- Detectar anomalias em eventos de interrupção aplicando o método *Isolation Forest*.
- Identificar padrões de interrupções por meio de segmentação e clusterização utilizando o algoritmo *K-Means*.

## 1.2 Estrutura do Trabalho

O presente trabalho está organizado em cinco capítulos, além desta introdução. No **Capítulo 2.1**, intitulado **Fundamentação Teórica**, são abordados os indicadores de continuidade e interrupções, apresentando os conceitos teóricos essenciais para a compreensão do tema. Esse capítulo também discute a importância da análise de indicadores e as contribuições proporcionadas pela análise de padrões interruptivos, além de revisar trabalhos relacionados.

No **Capítulo 3**, é detalhada a metodologia adotada, incluindo a utilização de bibliotecas *Python* para a análise de dados, o processo de importação e pré-processamento dos dados, bem como as técnicas aplicadas, como a clusterização com *K-Means*, a detecção de *outliers* com *Isolation Forest* e a projeção do indicador DEC com modelos *ARIMA*.

O **Capítulo 4** apresenta os resultados obtidos a partir da aplicação das técnicas descritas no capítulo anterior, destacando as principais descobertas e análises realizadas.

Por fim, o **Capítulo 5** traz as conclusões do trabalho, sintetizando as contribuições e discutindo possíveis direções para pesquisas futuras.

## 2 Fundamentação Teórica

O reconhecimento de padrões interruptivos em redes de distribuição de energia elétrica é um campo de estudo essencial para garantir a eficiência e a confiabilidade do fornecimento de energia. A análise de dados históricos e a aplicação de técnicas como *Machine Learning* que possibilitam identificar padrões de interrupções, prever comportamentos futuros e propor melhorias na operação das redes elétricas.

A ([Agência Nacional de Energia Elétrica - ANEEL, 2024](#)) disponibiliza um conjunto de dados abrangente sobre todas as interrupções ocorridas nas redes de distribuição do país, exceto aquelas sob gestão de permissionárias de serviço público. Esses dados incluem informações detalhadas, como a identificação das concessionárias, o valor limite de DEC e FEC regulatório que cada distribuidora possui, a instalação elétrica afetada, o tipo e causa das interrupções, além das datas de início e fim de cada evento. Essa riqueza de informações é essencial para análises aprofundadas e para o desenvolvimento de modelos preditivos.

A aplicação de *Machine Learning* nesse contexto permite que sistemas aprendam a partir dos dados coletados, identificando padrões complexos que podem não ser evidentes por meio de análises tradicionais. Por exemplo, algoritmos de aprendizado supervisionado podem ser treinados para classificar tipos de falhas com base em características específicas das interrupções registradas. Além disso, técnicas de aprendizado não supervisionado podem auxiliar na detecção de anomalias ou na segmentação de diferentes comportamentos dentro dos dados.

([MAGALHÃES, 2018](#)) Em sua dissertação intitulada "Modelagem e simulação de indicadores de continuidade: ferramenta auxiliar para a manutenção em redes de distribuição de energia elétrica", aborda a importância da confiabilidade nos sistemas de distribuição de energia elétrica. O autor destaca que falhas frequentes nesses sistemas afetam diretamente os indicadores de continuidade, como o DEC (Duração Equivalente de Interrupção por Unidade Consumidora) e o FEC (Frequência Equivalente de Interrupção por Unidade Consumidora), estabelecidos pela Agência Nacional de Energia Elétrica (ANEEL). O não cumprimento desses indicadores pode resultar em penalidades para as concessionárias.

Para auxiliar no planejamento de manutenção e melhorar a eficiência operacional, Magalhães desenvolveu modelos preditivos utilizando técnicas de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNAs). Esses modelos foram aplicados a um conjunto de consumidores de uma concessionária na região Nordeste do Brasil, analisando modos

de falha nos circuitos de alimentação, causas e frequências de interrupção, e o impacto dessas falhas nos valores do DEC e FEC.

A aplicação dos modelos permitiu avaliar a influência de determinados modos de falha sobre os indicadores de continuidade, priorizando tarefas de manutenção nos equipamentos que mais contribuem para o aumento desses indicadores. O estudo conclui que o conhecimento detalhado da influência dos modos de falha sobre o DEC e FEC possibilita uma tomada de decisão mais assertiva na execução de ações de manutenção, contribuindo para a estabilidade e confiabilidade operacional de todo o sistema elétrico.

Este trabalho evidencia a relevância da modelagem e simulação de indicadores de continuidade como ferramentas essenciais para a manutenção eficiente em redes de distribuição de energia elétrica, auxiliando as concessionárias a atenderem aos padrões regulatórios e a melhorarem a qualidade do serviço prestado aos consumidores.

## 2.1 Indicadores de Continuidade e Interrupções

A qualidade e a continuidade do fornecimento de energia elétrica no Brasil são monitoradas por diversos indicadores regulados pela Agência Nacional de Energia Elétrica (ANEEL). Entre os principais estão a Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), além de outros indicadores que avaliam métricas temporais de atendimentos emergenciais, todos estão descritos abaixo.

O DEC indica o tempo médio, em horas, que cada unidade consumidora ficou sem energia elétrica em um determinado período. Para calculá-lo, soma-se a duração de todas as interrupções ocorridas e divide-se pelo número total de consumidores atendidos pela distribuidora. Esse indicador é fundamental para avaliar a duração total das interrupções no fornecimento de energia, permitindo que as distribuidoras identifiquem áreas que necessitam de melhorias para garantir a continuidade do serviço.

Por sua vez, o FEC reflete o número médio de vezes que cada unidade consumidora experimentou interrupções no fornecimento de energia durante um período específico. Seu cálculo é realizado dividindo-se o total de interrupções registradas pelo número de unidades consumidoras atendidas. Esse indicador auxilia na avaliação da frequência das interrupções, permitindo que as distribuidoras identifiquem padrões e implementem ações preventivas para reduzir a recorrência de falhas.

Além desses, outros indicadores são utilizados para avaliar o desempenho operacional das distribuidoras no atendimento a ocorrências emergenciais. O Tempo Médio de Preparação (TMP) mede o tempo médio gasto desde a identificação de uma ocorrência até a mobilização da equipe de atendimento, avaliando a eficiência das distribuidoras na

prontidão e resposta inicial às emergências. O Tempo Médio de Deslocamento (TMD) indica o tempo médio que as equipes levam para se deslocar até o local da ocorrência após serem acionadas, avaliando a eficiência logística e a capacidade de resposta das equipes de campo. O Tempo Médio de Execução (TME) reflete o tempo médio necessário para resolver uma ocorrência desde a chegada da equipe ao local até a restauração do serviço, avaliando a eficácia das equipes na resolução de problemas e na restauração do fornecimento de energia. Por fim, o Tempo Médio de Atendimento a Emergências (TMAE) representa o tempo médio total desde a identificação de uma ocorrência até a completa restauração do serviço, fornecendo uma visão geral da eficiência das distribuidoras no gerenciamento e resolução de emergências.

Todos estes indicadores estão contidos no módulo de ([Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST, 2022](#)) que são fundamentais para que a ANEEL e as distribuidoras monitorem e aprimorem continuamente a qualidade do fornecimento de energia elétrica, garantindo um serviço mais confiável e eficiente para os consumidores.

## 2.2 Base de Dados e Reconhecimento de Padrões

Os dados utilizados neste estudo foram extraídos do conjunto público disponibilizado pela ([Agência Nacional de Energia Elétrica - ANEEL, 2024](#)) no seu portal de relatórios, que contém informações históricas sobre interrupções, indicadores de continuidade e outros indicadores relevantes para avaliação de desempenho das distribuidoras. Para esta análise, foi utilizada uma base histórica abrangendo o período de 2014 a 2023, totalizando 10 anos de dados. Essa base permitiu uma análise detalhada das interrupções e a previsão do comportamento do indicador DEC utilizando modelos de séries temporais, como o *ARIMA* (AutoRegressive Integrated Moving Average).

O reconhecimento de padrões interruptivos concentra-se na identificação de comportamentos recorrentes ou anômalos nas redes de distribuição. Esses padrões podem estar relacionados a falhas em equipamentos, condições climáticas ou sobrecargas na rede. Técnicas como clusterização e detecção de anomalias são frequentemente empregadas para agrupar interrupções com características similares e identificar eventos fora do padrão.

## 2.3 Importância da Análise de Indicadores

A análise integrada dos indicadores DEC, FEC, TMAE, TME, TMD e TMP, ao longo do tempo e por distribuidora, permite uma visão ampla da qualidade do serviço de distribuição. Essa abordagem possibilita identificar distribuidoras com desempenhos críticos e atuar preventivamente na mitigação de interrupções. Ao empregar técnicas de

*Machine Learning* e análise de séries temporais, torna-se possível prever tendências e estabelecer estratégias operacionais para melhoria contínua da infraestrutura.

## 2.4 Contribuições da Análise de Padrões Interruptivos

O estudo do reconhecimento de padrões interruptivos fornece *insights* detalhados sobre os comportamentos das redes de distribuição, permitindo intervenções mais direcionadas. A análise de dados históricos e a aplicação de técnicas de *Machine Learning* proporcionam uma visão técnica essencial para a manutenção e modernização da infraestrutura elétrica. Assim, enquanto os indicadores DEC e FEC oferecem uma visão geral da continuidade do serviço, a avaliação de padrões específicos e reincidências em equipamentos fornece subsídios para ações operacionais mais eficazes.

## 2.5 Trabalhos Relacionados

O artigo "A Deep Learning-based Fault Detection and Classification in Smart Electrical Power Transmission System" ([AL-DULAIMI; MOSTAFA; GUNASEKARAN, 2023](#)) apresenta uma abordagem inovadora para a detecção e classificação de falhas em sistemas inteligentes de transmissão de energia elétrica, utilizando técnicas de aprendizado profundo. Os autores desenvolveram um modelo baseado em redes neurais profundas que analisa parâmetros críticos, como tensão, corrente e ângulo de fase, para identificar e localizar falhas nas linhas de transmissão. A aplicação desse modelo visa aprimorar a estabilidade e a confiabilidade do sistema de transmissão de energia, permitindo uma resposta mais rápida e precisa a eventos de falha.

Na dissertação "Modelagem e simulação de indicadores de continuidade: ferramenta auxiliar para a manutenção em redes de distribuição de energia elétrica" ([MAGALHÃES, 2018](#)), o autor propõe uma ferramenta de modelagem e simulação para auxiliar na manutenção de redes de distribuição de energia elétrica. A pesquisa foca na análise de indicadores de continuidade, visando otimizar as estratégias de manutenção e melhorar a qualidade do fornecimento de energia. Através da simulação desses indicadores, é possível prever comportamentos da rede e planejar intervenções de forma mais eficiente, contribuindo para a redução de interrupções no serviço.

O relatório técnico "Machine Learning Algorithms - A Review" ([MAHESH, 2020](#)) oferece uma revisão abrangente dos algoritmos de aprendizado de máquina, discutindo suas aplicações em diversas áreas, como mineração de dados, processamento de imagens e análises preditivas. O autor explora os principais tipos de aprendizado, incluindo supervisionado, não supervisionado e por reforço, destacando as características e casos de uso de cada abordagem. Além disso, o relatório aborda as vantagens do aprendizado de máquina na

automação de tarefas complexas e na capacidade dos algoritmos de aprenderem a partir de dados, sem a necessidade de programação explícita para cada tarefa.

No trabalho "Proposta de procedimentos e metodologia para estabelecimento de metas de qualidade (DEC e FEC) para concessionárias de distribuição de energia elétrica através da análise comparativa" (TANURE; TAHAN, 2004), os autores propõem uma metodologia para definir metas de qualidade para concessionárias de distribuição de energia elétrica, focando nos indicadores de Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e Frequência Equivalente de Interrupção por Unidade Consumidora (FEC). A metodologia baseia-se em análises comparativas entre diferentes concessionárias, visando estabelecer parâmetros de desempenho que incentivem a melhoria contínua na qualidade do serviço prestado aos consumidores.

A Resolução Normativa ANEEL nº 956/2021, publicada pela Agência Nacional de Energia Elétrica (ANEEL) em 2021, estabelece os Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST). Esta resolução visa padronizar e regulamentar as atividades técnicas relacionadas ao funcionamento e desempenho dos sistemas de distribuição de energia elétrica no Brasil. O PRODIST é composto por diversos módulos que abordam temas como planejamento da expansão do sistema, conexão ao sistema de distribuição, procedimentos operativos, sistemas de medição, entre outros, com o objetivo de garantir a qualidade e a confiabilidade do fornecimento de energia elétrica aos consumidores. (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST, 2022)

## 3 Metodologia

A metodologia deste trabalho consiste em um conjunto de etapas estruturadas para analisar padrões interruptivos em redes de distribuição de energia elétrica e avaliar o desempenho das distribuidoras em relação a indicadores regulatórios. As principais etapas realizadas são descritas a seguir.

### 3.1 Fluxograma de trabalho

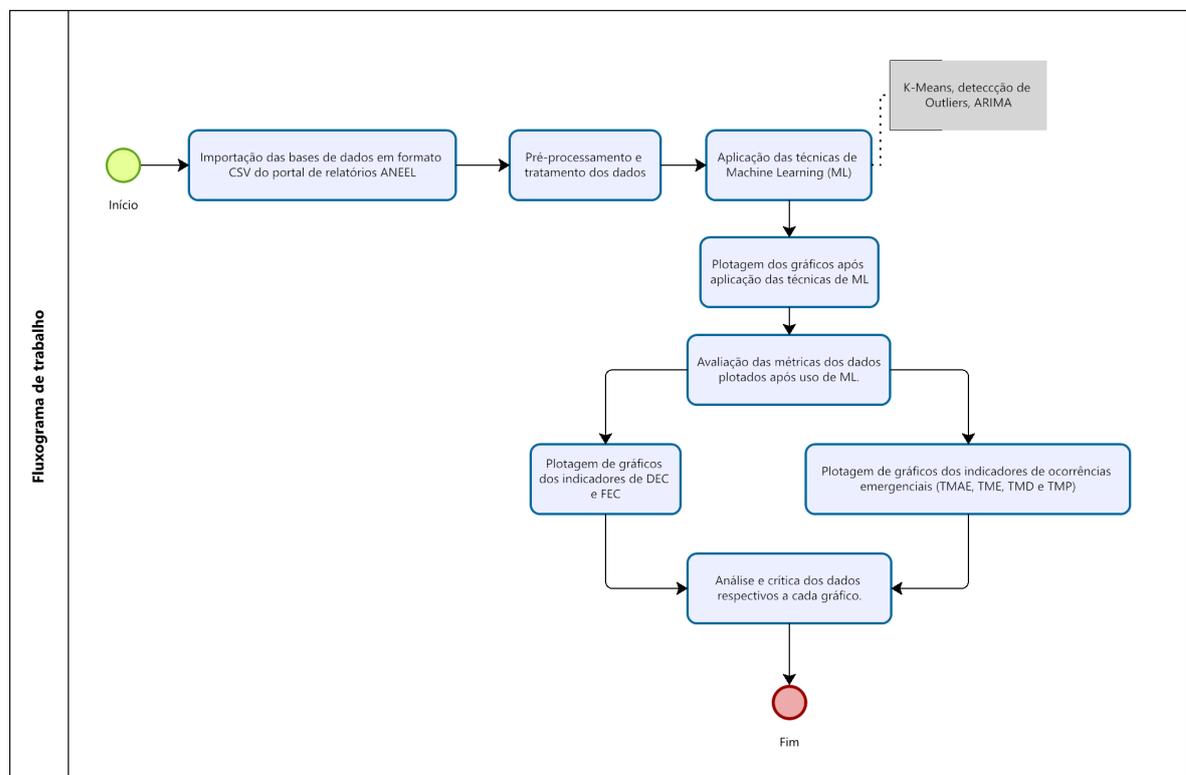


Figura 1 – Fonte: Autor

O fluxo de trabalho apresentado no diagrama descreve o processo de análise de dados utilizado, abrangendo desde a importação e pré-processamento dos dados até a aplicação de técnicas de Machine Learning e a avaliação dos resultados obtidos. Após a aplicação dessas técnicas, são geradas visualizações gráficas para facilitar a interpretação dos dados, permitindo a análise de métricas e indicadores relevantes. O processo inclui a avaliação de diferentes aspectos dos dados, como indicadores de desempenho e ocorrências emergenciais, culminando em uma análise crítica dos resultados obtidos, garantindo uma interpretação fundamentada das informações extraídas.

## 3.2 Importação e Pré-processamento dos Dados

A importação e pré-processamento dos dados é uma etapa crucial em qualquer estudo que envolva análise de dados ou aplicação de técnicas de *Machine Learning*. Abaixo, detalhamos cada um dos pontos mencionados, explicando como foram aplicados no trabalho:

Os dados foram importados de arquivos no formato **CSV**, um formato comum para armazenamento de dados tabulares. Esses arquivos continham informações sobre os indicadores de ocorrências emergenciais: TMAE, TME, TMD e TMP. Além disso, foi utilizado outro dataset do portal de relatórios da ([Agência Nacional de Energia Elétrica - ANEEL, 2024](#)) contendo dados anuais estratificados de DEC e FEC por distribuidora de energia, abrangendo o período de 2014 a 2023. Esse dataset foi essencial para análises comparativas e aplicação de modelos de *Machine Learning*.

A importação foi realizada utilizando a biblioteca **pandas**, que oferece funções como `pd.read_csv()` para carregar dados de arquivos CSV diretamente em um *DataFrame*, uma estrutura de dados tabular que facilita a manipulação e análise.

### 3.2.1 Utilização de Bibliotecas *Python*

As bibliotecas *Python* desempenharam um papel fundamental no pré-processamento dos dados:

- **Pandas**: Para manipulação de dados, incluindo leitura, limpeza, transformação e agregação.
- **Datetime**: Para manipulação de datas e cálculos temporais.
- **NumPy**: Para operações matemáticas e manipulação de arrays.
- **Scikit-learn**: Para técnicas de normalização e codificação de dados.

### 3.2.2 Normalização e Transformação dos Dados

Para garantir que os dados estivessem em formatos adequados para análise e modelagem, foram aplicadas as seguintes etapas:

- **Normalização**: Alguns algoritmos de *Machine Learning* exigem que os dados estejam em uma escala específica. Portanto, técnicas como **Min-Max Scaling** foram aplicadas para normalizar os valores dos indicadores.
- **Transformação de formatos**: Dados em formatos inadequados (por exemplo, datas como strings) foram convertidos para tipos apropriados. A biblioteca **datetime** foi utilizada para converter strings de datas em objetos do tipo `datetime`, facilitando cálculos temporais.

### 3.2.3 Organização dos Dados para Análise e Modelagem

Após o pré-processamento, os dados foram organizados em estruturas adequadas para análise e aplicação de modelos de *Machine Learning*:

- **Divisão em conjuntos de treino e teste:** Utilizou-se a função `train_test_split()` da biblioteca *Scikit-learn* para dividir os dados em conjuntos de treinamento e teste, garantindo que os modelos fossem avaliados de forma robusta.
- **Estruturação em *features* e *targets*:** Os dados foram separados em variáveis independentes (*features*) e dependentes (*targets*), conforme necessário para a modelagem.

## 3.3 Técnicas Aplicadas e projeção de Indicadores com base histórica

No estudo em questão, foram aplicadas técnicas de análise de dados e aprendizado de máquina para identificar padrões de interrupções e projetar indicadores de continuidade no fornecimento de energia elétrica. A seguir, detalhamos as metodologias empregadas:

### 3.3.1 Clusterização com *K-Means*

A clusterização é uma técnica de aprendizado não supervisionado que agrupa dados com características similares, facilitando a identificação de padrões ocultos. Neste estudo, utilizou-se o algoritmo *K-Means* para agrupar as interrupções registradas de acordo com atributos como duração, frequência, localização geográfica, causas e horários de ocorrência. Ao determinar o número ideal de *Clusters* ( $k$ ), foi possível segmentar as interrupções em grupos homogêneos, permitindo análises mais direcionadas. Por exemplo, interrupções causadas por falhas em equipamentos podem formar um *Cluster* distinto das interrupções causadas por eventos climáticos adversos. Essa segmentação auxilia na identificação de áreas ou condições operacionais que requerem atenção especial, possibilitando a implementação de medidas preventivas específicas para cada tipo de interrupção. Abaixo, segue a descrição do algoritmo *K-Means* para agrupamento de dados.

A função *K-Means* é dada por:

$$f = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2$$

onde:

- $f$  é a função objetivo que representa a soma dos quadrados das distâncias entre os pontos e os centróides de seus respectivos clusters.
- $k$  é o número de clusters.

- $n$  é o número total de pontos no conjunto de dados.
- $x_i^{(j)}$  é o  $i$ -ésimo ponto que pertence ao  $j$ -ésimo cluster.
- $c_j$  é o centróide do  $j$ -ésimo cluster.
- $\|x_i^{(j)} - c_j\|^2$  é a distância ao quadrado entre o ponto  $x_i^{(j)}$  e o centróide  $c_j$ .

O método de clusterização *K-Means* foi aplicado no dataset de TMAE para identificar grupos de interrupções com características similares. Essa etapa possibilitou:

- Agrupamento de interrupções de acordo com a quantidade de interrupções.
- Agrupamento de interrupções de acordo com o valor de TMAE.

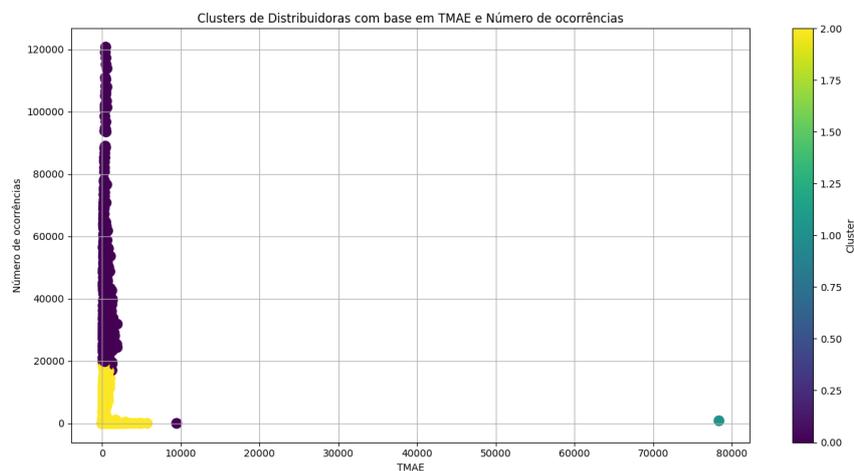


Figura 2 – *Cluster* de distribuidoras com base no TMAE e Número de ocorrências

**Distribuição dos Dados:** O eixo X representa o TMAE, que varia amplamente, com a maioria das distribuidoras concentradas em valores próximos de zero. O eixo Y representa o Número de Ocorrências, que vai até 120.000, indicando grande variação no volume de registros por distribuidora. A maior densidade de pontos está na região inferior à esquerda (baixo TMAE e menor número de ocorrências), o que reflete a maioria das distribuidoras com operações mais eficientes ou menos eventos registrados.

**Identificação de *Clusters*:** Os pontos estão classificados em *Clusters*, indicados por cores na barra lateral (código de cores do *Cluster*). Observa-se:

- Um ***Cluster* principal** (cor roxa) concentra a maioria das distribuidoras, com valores baixos de TMAE e variação significativa no número de ocorrências.
- Um ***Cluster* menor** (cor amarela) envolve distribuidoras com baixo TMAE e um número muito pequeno de ocorrências.

- Um **outlier claro** (cor ciano) no canto superior direito, com valores extremamente altos de TMAE e relativamente baixos no número de ocorrências, indicando um comportamento singular.

#### **Tendências e Anomalias:**

- A concentração no *Cluster* roxo sugere que a maior parte das distribuidoras tem desempenho operacional semelhante, lidando com volumes variados de ocorrências sem grandes discrepâncias no tempo médio de atendimento.
- O *Cluster* amarelo pode representar distribuidoras que atuam em regiões de menor demanda, com poucos eventos a serem atendidos.
- O outlier no canto superior direito pode indicar uma anomalia operacional ou uma distribuidora que enfrenta desafios únicos, como baixa eficiência no atendimento (alto TMAE) ou registros inconsistentes.

### 3.3.2 Detecção de *Outliers* com *Isolation Forest*

A detecção de anomalias visa identificar eventos que se desviam significativamente do comportamento padrão dos dados. O algoritmo *Isolation Forest* foi empregado para detectar interrupções atípicas que poderiam indicar falhas críticas ou situações excepcionais na rede de distribuição. Este método isola observações anômalas ao particionar repetidamente os dados, sendo eficiente para grandes volumes de informações. Ao aplicar o *Isolation Forest*, foram identificadas interrupções com características incomuns, como durações excessivamente longas ou frequências anômalas em determinadas regiões, permitindo uma investigação aprofundada dessas ocorrências e a implementação de ações corretivas específicas.

A detecção de *outliers* foi realizada para identificar valores anômalos que poderiam comprometer a análise. Este processo envolveu: - Detecção de *outliers* no número de ocorrências de interrupções, aplicando o algoritmo *Isolation Forest*.

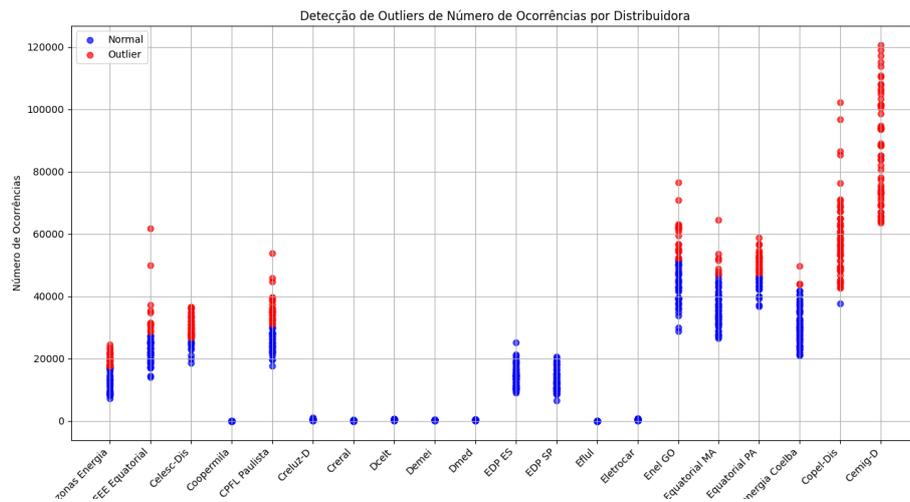


Figura 3 – Detecção de *outliers* do número de interrupções

**Distribuição dos Dados:** O gráfico usa cores para distinguir entre valores considerados "Normais" (azul) e "*outliers*" (vermelho). Observa-se uma concentração de pontos azuis para a maioria das distribuidoras, indicando valores consistentes dentro de um intervalo esperado.

**Identificação de *outliers*:** Algumas distribuidoras possuem vários valores destacados como *outliers* (vermelhos). Isso indica que essas distribuidoras registraram números de ocorrências significativamente maiores ou menores que a maioria. A distribuidora Cemig D, localizada à direita, apresenta o maior número de *outliers*, indicando alta variabilidade ou eventos atípicos no número de ocorrências.

**Tendências por Distribuidora:** Algumas distribuidoras, como CPFL Paulista, COPEL-Dis e Cemig D, apresentam tanto valores normais quanto muitos *outliers*, sugerindo grande disparidade nos dados dessas empresas. Já outras distribuidoras como Demel e Eletrocar mostram um padrão estável com poucos ou nenhum outlier visível, sugerindo consistência nas ocorrências.

**Amplitude de Ocorrências:** A escala do eixo Y (número de ocorrências) varia amplamente, chegando a valores acima de 120.000 para algumas distribuidoras. Isso indica que algumas distribuidoras possuem um volume de ocorrências muito maior do que outras, possivelmente devido ao tamanho ou à densidade populacional das áreas atendidas.

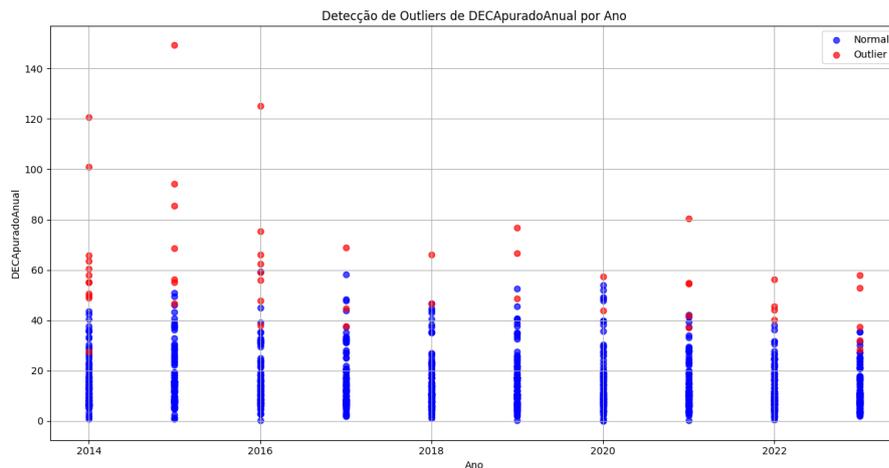


Figura 4 – Detecção de *outliers* do número de interrupções

O gráfico acima realiza a detecção de *outliers* para o indicador DEC Apurado Anual (Duração Equivalente de Interrupção por Unidade Consumidora) ao longo dos anos, sendo assim segue a análise do mesmo:

**Distribuição dos Dados:** A maior parte dos pontos está concentrada na faixa entre 0 e 40 horas no eixo Y, indicando que a maioria das distribuidoras tem valores de DEC anuais relativamente baixos. Existem distribuidoras com valores mais elevados, situando-se acima de 60 horas, que aparecem como possíveis *outliers*.

**Identificação de *outliers*:** Pontos vermelhos representam *outliers* detectados, que estão significativamente acima dos valores típicos (azuis). Os *outliers* são mais frequentes em anos como 2014, 2015 e 2016, com DEC superior a 60 horas ou até 140 horas. Esses valores podem indicar problemas graves ou eventos excepcionais, como falhas em larga escala ou desastres naturais que afetaram as operações.

**Tendências ao Longo dos Anos:** A partir de 2017, observa-se uma leve redução na quantidade de *outliers* ao longo do tempo. Isso pode sugerir melhorias nos sistemas de distribuição ou maior controle sobre interrupções. Apesar disso, os anos mais recentes ainda apresentam alguns *outliers* altos, especialmente em 2022 e 2023, indicando que algumas distribuidoras continuam enfrentando desafios com interrupções prolongadas. - Identificação de *outliers* nos indicadores DEC e FEC, que representam interrupções com características fora do padrão esperado.

Esses *outliers* foram avaliados para verificar se indicavam falhas críticas ou eventos operacionais excepcionais.

### 3.3.3 Projeção do Indicador DEC com Modelos *ARIMA*

Para prever o comportamento futuro do Indicador de Duração Equivalente de Interrupção por Unidade Consumidora (DEC), foram utilizados modelos de séries temporais, especificamente o *ARIMA* (*AutoRegressive Integrated Moving Average*). O modelo *ARIMA* é composto por três componentes:

- **Autoregressivo (AR):** Reflete a relação entre uma observação e um número definido de observações anteriores.
- **Integrado (I):** Indica o número de diferenciações necessárias para tornar a série temporal estacionária.
- **Média Móvel (MA):** Modela a dependência entre uma observação e os resíduos de erros de modelos de médias móveis aplicados a observações anteriores.

Ao aplicar o modelo *ARIMA* aos dados históricos de DEC de 2014 a 2023, foi possível capturar tendências, sazonalidades e padrões cíclicos presentes na série temporal. A partir disso, foram realizadas projeções para os anos subsequentes, fornecendo insights valiosos para o planejamento estratégico das distribuidoras. Essas previsões auxiliam na identificação de possíveis aumentos na duração das interrupções, permitindo que as empresas adotem medidas proativas para mitigar impactos negativos e garantir a conformidade com as exigências regulatórias estabelecidas pela ANEEL.

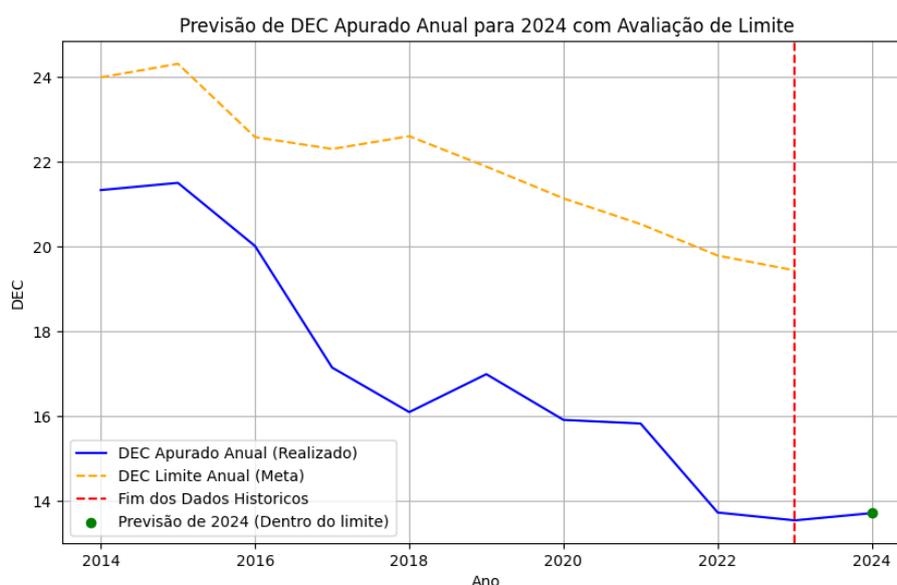


Figura 5 – Previsão do fechamento de DEC e Limite de 2024 a partir da regressão dos dados históricos de 2014 a 2023 com *ARIMA*

O gráfico apresenta a evolução do DEC (Duração Equivalente de Interrupção por Unidade Consumidora) apurado anualmente de 2014 a 2023, comparando os valores

realizados com as metas estabelecidas. Observa-se uma tendência geral de redução do DEC ao longo dos anos, especialmente entre 2015 e 2018, quando os valores apurados se distanciaram substancialmente da meta.

Entre 2021 e 2024, nota-se uma estabilização nos valores apurados, com a previsão de 2024 mostrando uma leve elevação em relação a 2023, mas ainda dentro do limite estipulado. Isso reflete uma manutenção satisfatória no controle das interrupções, embora seja importante monitorar essa pequena alta para evitar desvios futuros.

O gráfico também destaca o fim dos dados históricos com uma linha vermelha em 2023 e projeta um ponto de previsão para 2024, indicado em verde. Essa projeção sugere que o desempenho permanecerá abaixo do limite regulatório estipulado para as distribuidoras, evidenciando esforços consistentes de melhoria no desempenho operacional e na qualidade do serviço prestado.

## 4 Resultados

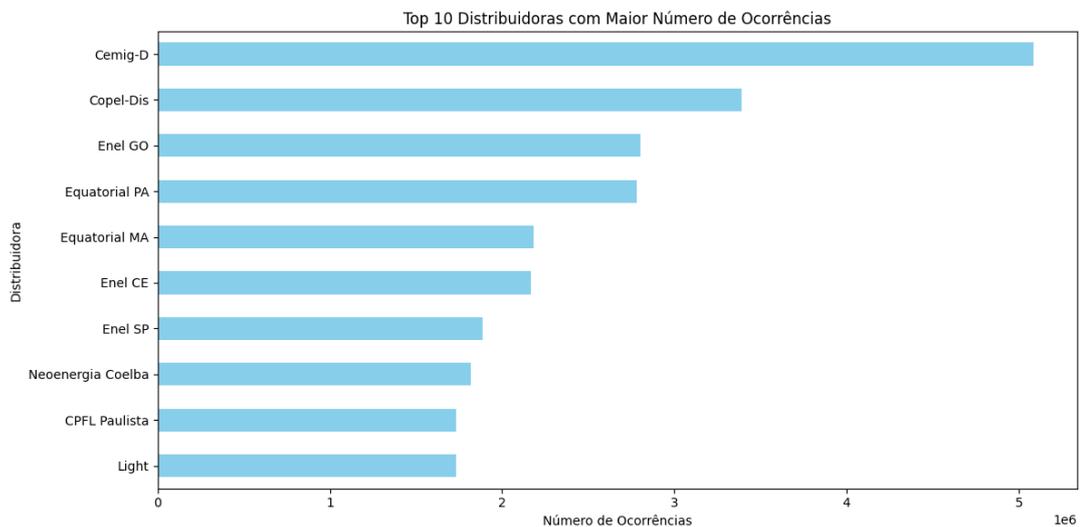


Figura 6 – Top 10 distribuidoras com maior quantidade de ocorrências de 2020 a 2024

- **Distribuidoras com maior quantidade de ocorrências:** A **Cemig-D** lidera o ranking com o maior número de interrupções, possivelmente devido à abrangência da área atendida e desafios climáticos em Minas Gerais.
- **Distribuidoras intermediárias:** A **Copel-Dis**, **Enel GO**, **Equatorial PA** e **Equatorial MA** destacam-se em posições intermediárias. Estas distribuidoras enfrentam interrupções associadas a condições climáticas regionais, como geadas no Sul e chuvas intensas no Norte e Nordeste.
- **Distribuidoras com menor quantidade de ocorrências:** A **CPFL Paulista** e a **Light** têm os menores números de interrupções, indicando infraestrutura mais moderna ou menor vulnerabilidade climática.

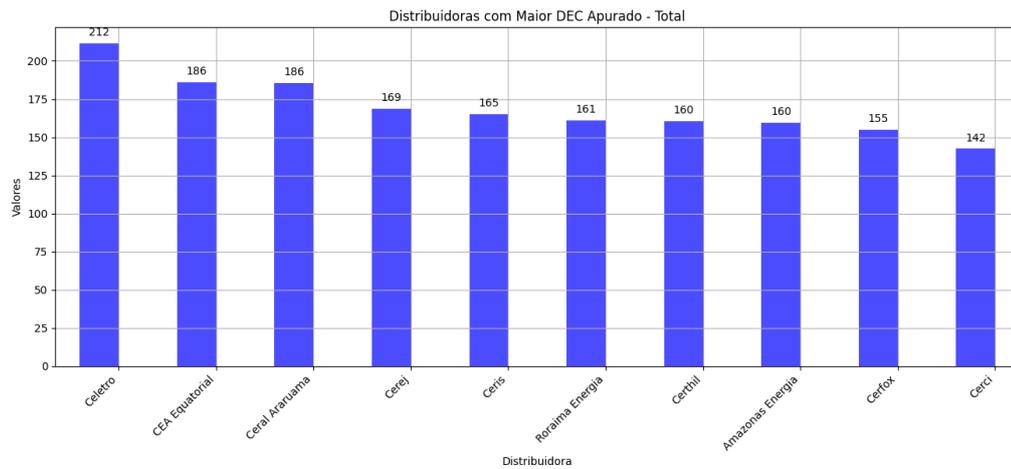
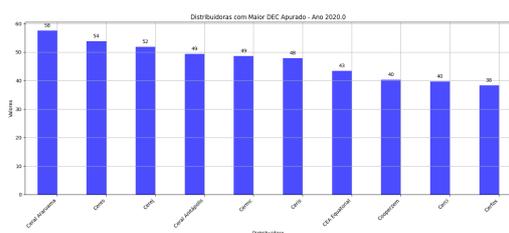
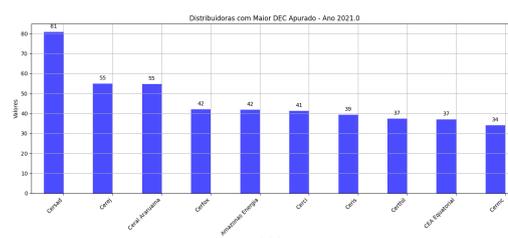


Figura 7 – Top 10 distribuidoras com maior DEC de 2020 a 2024

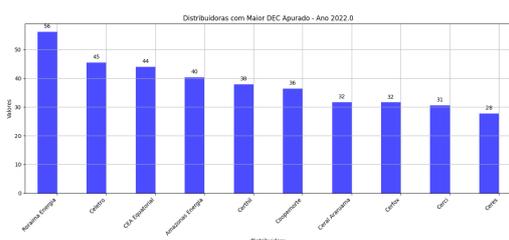
- **Distribuidoras com maior quantidade de DEC apurado:** A **Celetro** lidera o ranking com um DEC apurado de 212 horas, destacando-se significativamente acima das demais. Esse número elevado pode estar associado a limitações de infraestrutura e desafios operacionais em sua área de atuação.
- **Distribuidoras intermediárias:** As distribuidoras **CEA Equatorial** e **Ceral Araruama** compartilham valores de DEC intermediários (186), seguidas por **Cerej** (169) e **Ceris** (165). Estes valores sugerem que, apesar de não liderarem, enfrentam desafios relacionados à confiabilidade do fornecimento de energia.
- **Distribuidoras com menor quantidade de DEC apurado:** As distribuidoras **Cerci** (142) e **Cerfox** (155) apresentam os menores valores de DEC no gráfico, indicando um desempenho relativamente melhor em comparação com as demais, possivelmente devido a redes mais modernas ou menor exposição a fatores adversos.



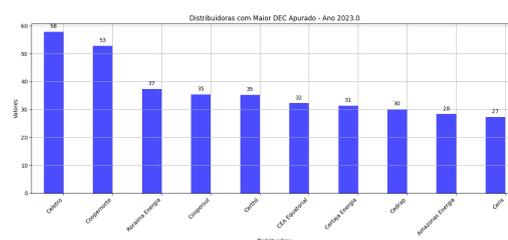
(a) Top 10 distribuidoras com maior DEC em 2020



(b) Top 10 distribuidoras com maior DEC em 2021



(c) Top 10 distribuidoras com maior DEC em 2022



(d) Top 10 distribuidoras com maior DEC em 2023

Figura 8 – Comparação das distribuidoras com maior DEC de 2020 a 2023

**Distribuidoras com pior desempenho (maiores valores de DEC):**

Em 2020 as distribuidoras com maior DEC foram Ceral Araruama (58), Ceres (54) e Ceral Antópolis (52). Já em 2023, as distribuidoras com maior DEC foram Celetro (58), Coopernorte (53) e Roraima Energia (37). Nota-se que Celetro em 2023 alcançou o mesmo valor que Ceral Araruama em 2020 (58). Porém, houve uma significativa queda no DEC das outras distribuidoras mais críticas, como Ceres, que passou de 54 (2020) para valores não apresentados no topo de 2023.

Em 2020, os valores mais baixos entre os piores desempenhos estavam em torno de 38 (Ceflo). Já em 2023, a faixa mais baixa das piores distribuidoras ficou em 27 (Ceres), indicando uma melhora no desempenho global.

Distribuidoras recorrentes: Algumas distribuidoras aparecem em ambas as listas com variações significativas:

Ceres: Apesar de estar em ambas as listas, reduziu seu DEC de 49 em 2020 para 27 em 2023. CEA Equatorial: Passou de 40 em 2020 para 32 em 2023, apresentando também melhora.

Distribuidoras novas nos piores desempenhos de 2023:

Roraima Energia, Coopernorte, Celetro e outras aparecem no ranking de 2023, mas não estavam entre as piores de 2020, indicando possível deterioração nos serviços.

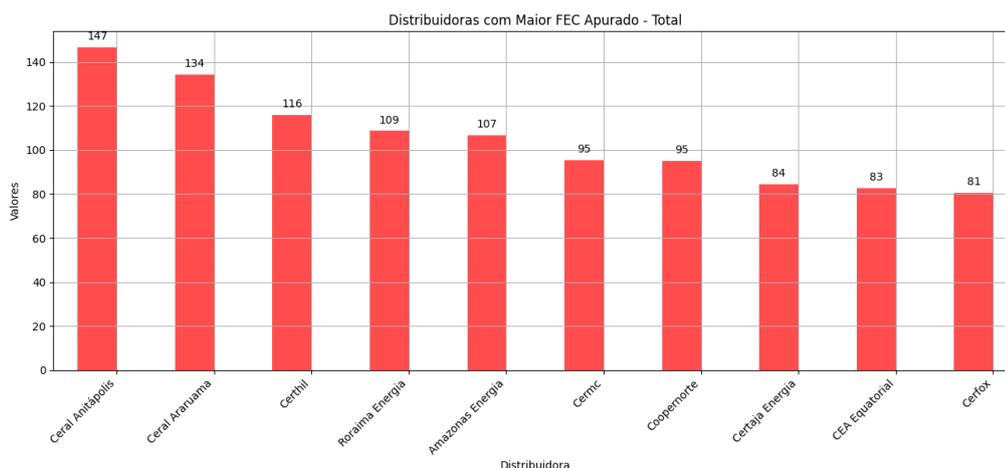


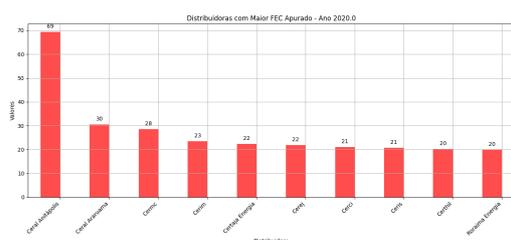
Figura 9 – Top 10 distribuidoras com maior FEC de 2020 a 2024

- **Distribuidoras com maior quantidade de FEC apurado:** A **Ceral Anitápolis** lidera o ranking com um FEC apurado de 147 horas acumuladas ao longo destes 5 anos, destacando-se como a distribuidora com maior quantidade de interrupções acumuladas. Este alto valor pode refletir desafios operacionais significativos, como infraestrutura insuficiente ou limitações técnicas.

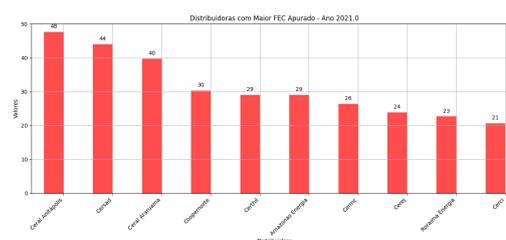
A **Ceral Araruama** ocupa a segunda posição, com um FEC apurado de 134 horas, também indicando uma alta frequência de interrupções.

- **Distribuidoras intermediárias:** As distribuidoras **Certhil (116)**, **Roraima Energia (109)** e **Amazonas Energia (107)** exibem valores intermediários de FEC. Estas distribuidoras podem estar enfrentando desafios moderados, com frequências de interrupções menores em comparação às líderes, mas ainda consideráveis.
- **Distribuidoras com menor quantidade de FEC apurado:** As distribuidoras **Cermc (95)** e **Coopermorte (95)** apresentam números iguais, representando um desempenho levemente melhor dentro do grupo analisado.

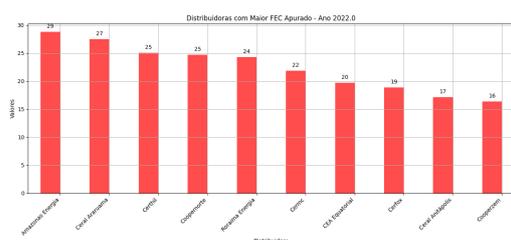
Já as distribuidoras **Certaja Energia (84)**, **CEA Equatorial (83)** e **Cerfox (81)** registram os menores valores de FEC, indicando um desempenho superior em termos de frequência de interrupções. Esses resultados podem estar associados a investimentos em infraestrutura e à gestão mais eficiente de suas redes.



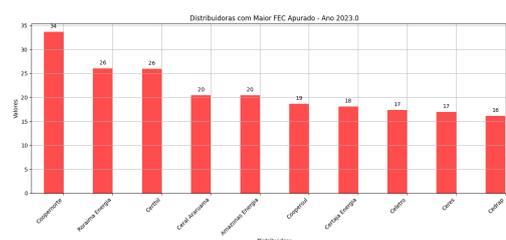
(a) Top 10 distribuidoras com maior FEC em 2020



(b) Top 10 distribuidoras com maior FEC em 2021



(c) Top 10 distribuidoras com maior FEC em 2022



(d) Top 10 distribuidoras com maior FEC em 2023

Figura 10 – Comparação das distribuidoras com maior FEC de 2020 a 2023

Entre 2020 e 2023, os valores de FEC das distribuidoras apresentaram uma redução significativa. Em 2020, as distribuidoras com maior FEC foram Ceral Antópolis (69), Ceral Araruama (30) e Cemc (28). Já em 2023, os maiores índices foram registrados por Coopermorte (34), Roraima Energia (26) e Certhil (26). O maior índice em 2023 foi quase metade do maior valor de 2020, evidenciando uma melhora na frequência das interrupções entre as distribuidoras mais críticas. Além disso, o intervalo dos índices entre os piores desempenhos diminuiu, indo de 20-69 em 2020 para 16-34 em 2023.

Apesar da melhoria geral, algumas distribuidoras apresentaram pioras ou continuaram com índices elevados. Roraima Energia, que registrou FEC de 20 em 2020, subiu para 26 em 2023, enquanto Certhil passou de 21 para 26 no mesmo período. Distribuidoras como Coopermorte, Cedrap e Coopersul apareceram no ranking de 2023, mas não figuravam entre as piores de 2020, indicando deterioração em seus serviços. Por outro lado, Ceral Antópolis, que liderava com o maior FEC em 2020, não aparece mais entre as piores em 2023, mostrando progresso.

De forma geral, o desempenho das distribuidoras em relação ao FEC melhorou consideravelmente no período analisado. O maior índice em 2023 foi quase metade do registrado em 2020, e o menor entre os piores desempenhos também reduziu de 20 para 16. Contudo, a entrada de novas distribuidoras no grupo com altos índices e a piora de algumas recorrentes indicam desafios regionais que ainda precisam ser enfrentados para uma melhora uniforme no setor.

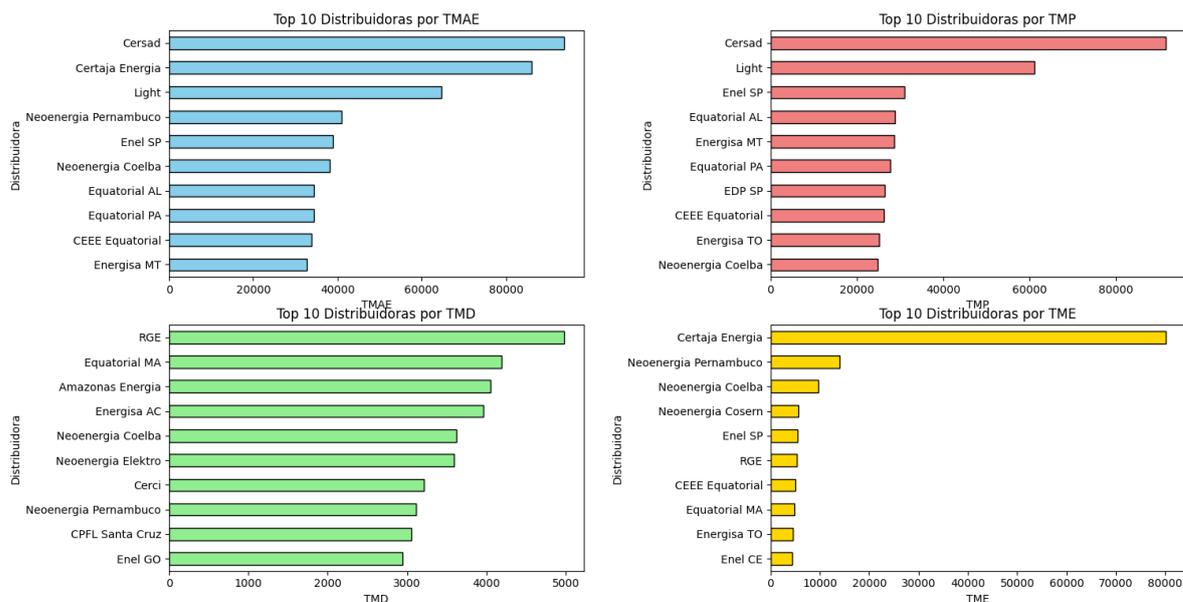


Figura 11 – Distribuidoras ofensoras de TMAE, TME, TMP e TMD no cenário de 2020 a 2024

Os gráficos apresentam os desempenhos das principais distribuidoras de energia em quatro métricas operacionais: Tempo Médio de Atendimento a Emergências (TMAE), Tempo Médio de Preparação (TMP), Tempo Médio de Deslocamento (TMD) e Tempo Médio de Execução (TME). No gráfico superior esquerdo (TMAE), Cersad destaca-se como a distribuidora com o maior tempo médio, seguida por Certaja Energia e Light, o que indica maior lentidão no atendimento a emergências nessas empresas, enquanto as demais distribuidoras listadas também apresentam desafios similares.

No gráfico superior direito (TMP), que mede o tempo necessário para preparação dos serviços, novamente Cersad lidera, mostrando um desempenho menos eficiente. Empresas como Light e Enel SP também apresentam tempos elevados, o que pode refletir processos internos que requerem melhorias para maior agilidade na prestação de serviços.

Nos gráficos inferiores, o TMD e o TME ilustram diferentes aspectos da operação. No gráfico inferior esquerdo (TMD), que avalia o tempo de deslocamento, RGE se destaca com o menor tempo médio, sugerindo maior eficiência logística. Por outro lado, no gráfico inferior direito (TME), que mede o tempo médio de execução de serviços, Certaja Energia apresenta o maior tempo, seguida de Neoenergia Pernambuco e Neoenergia Coelba, apontando que essas empresas possuem etapas de execução mais demoradas, impactando o atendimento global. Esses dados destacam os pontos fortes e as deficiências operacionais entre as distribuidoras analisadas.

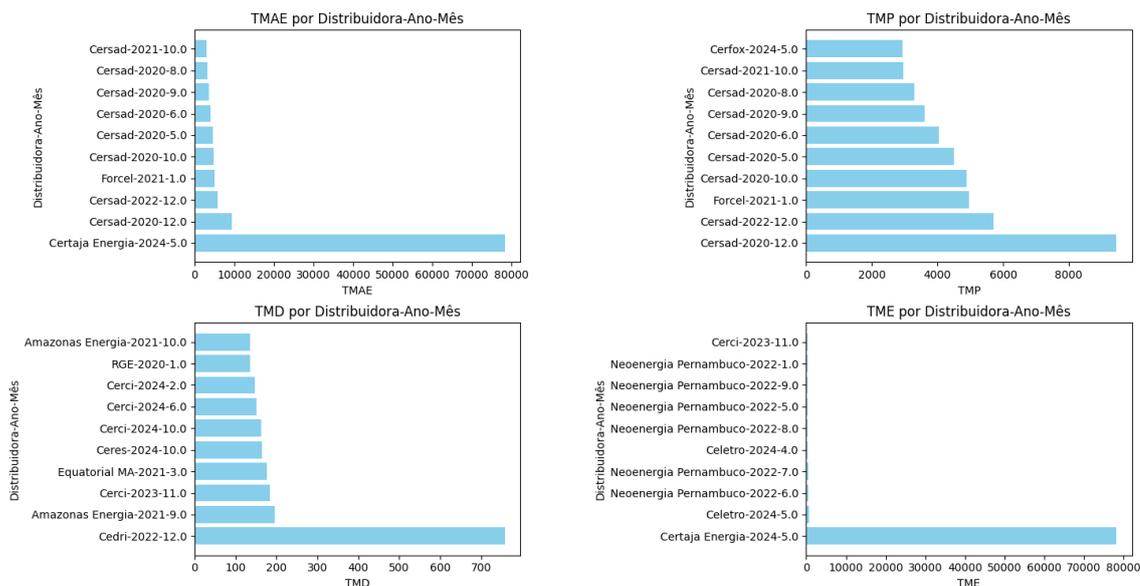


Figura 12 – Distribuidora-Ano-Mês ofensores de TMAE, TME, TMP e TMD

Os gráficos fornecem uma análise detalhada das métricas TMAE, TMP, TMD e TME ao longo do tempo, considerando distribuidoras específicas em períodos determinados. No gráfico superior esquerdo, relacionado ao Tempo Médio de Atendimento a Emergências (TMAE), observa-se que a distribuidora Cersad apresenta valores significativamente altos em diversos períodos, destacando-se especialmente em dezembro de 2020 com o maior TMAE. Isso indica um problema persistente no tempo de resposta a emergências.

No gráfico superior direito, que avalia o Tempo Médio de Preparação (TMP), Cersad novamente apresenta os maiores valores, com destaque para dezembro de 2022, sugerindo atrasos consideráveis nos processos de preparação para atendimento. Este padrão reforça a necessidade de melhorias nos processos internos da distribuidora. Outras distribuidoras, como Certaja Energia, também apresentam desempenhos elevados, mas de forma menos crítica.

Nos gráficos inferiores, o Tempo Médio de Deslocamento (TMD) mostra um desempenho mais homogêneo, com valores relativamente baixos em comparação com as outras métricas, sendo Amazonas Energia e RGE as distribuidoras mais eficientes. Já no Tempo Médio de Execução (TME), Certaja Energia se destaca com um valor excepcionalmente alto, sugerindo grandes ineficiências na execução das atividades. No geral, os dados ressaltam a necessidade de intervenções específicas em cada etapa operacional para melhorar a eficiência dessas empresas.

## 5 Conclusão

A análise dos dados sobre interrupções em redes de distribuição de energia elétrica, utilizando uma combinação de técnicas de *Machine Learning*, provou ser uma abordagem altamente eficaz para aprimorar a gestão e a eficiência operacional das redes elétricas. A aplicação dessas técnicas permitiu não apenas a identificação de padrões significativos, mas também uma análise aprofundada do desempenho das distribuidoras e dos fatores subjacentes que contribuem para as interrupções.

A utilização de algoritmos de clusterização e detecção de anomalias possibilitou a identificação precisa das principais distribuidoras e regiões predominantes das ocorrências, oferecendo uma visão detalhada sobre as falhas recorrentes e os problemas crônicos na infraestrutura. A análise da volumetria das interrupções, associada ao estudo da duração dessas interrupções com a avaliação do TMAE e TME, forneceu *insights* sobre a atuação das distribuidoras perante cenários de contingência de falta de energia devido a fatores climáticos.

Os resultados obtidos enfatizam a importância de uma abordagem baseada em dados e o valor das técnicas de *Machine Learning* para a previsão de padrões de falhas e a otimização das operações das redes de distribuição. As recomendações desenvolvidas com base nesta análise visam não apenas reduzir o impacto das interrupções, mas também promover melhorias contínuas na confiabilidade e eficiência do fornecimento de energia.

Em suma, a integração de *Machine Learning* com as bases de dados históricas dos indicadores de continuidade e de distribuição representam um avanço significativo para a inovação e a gestão aprimorada nas redes elétricas, oferecendo um caminho promissor para enfrentar os desafios futuros e garantir um fornecimento de energia cada vez mais confiável e eficiente.

## Referências

- Agência Nacional de Energia Elétrica - ANEEL. *Indicadores de Distribuição - ANEEL*. 2024. Acessado em: 9 de dezembro de 2024. Disponível em: <<https://portalrelatorios.aneel.gov.br/indicadoresDistribuicao>>. Citado 5 vezes nas páginas 5, 6, 13, 15 e 19.
- AL-DULAIMI, S. H. K.; MOSTAFA, S.; GUNASEKARAN, S. S. A deep learning-based fault detection and classification in smart electrical power transmission system. *ResearchGate*, 2023. Disponível em: <[https://www.researchgate.net/publication/381166853\\_A\\_Deep\\_Learning-based\\_Fault\\_Detection\\_and\\_Classification\\_in\\_Smart\\_Electrical\\_Power\\_Transmission\\_System](https://www.researchgate.net/publication/381166853_A_Deep_Learning-based_Fault_Detection_and_Classification_in_Smart_Electrical_Power_Transmission_System)>. Citado na página 16.
- IBM. *Apresentando os modelos ARIMA*. 2024. Accessed: 2024-12-11. Disponível em: <<https://www.ibm.com/br-pt/topics/arima-model>>. Citado na página 11.
- MAGALHÃES, E. F. A. Modelagem e simulação de indicadores de continuidade: ferramenta auxiliar para a manutenção em redes de distribuição de energia elétrica. 2018. Disponível em: <<https://repositorio.ufba.br/handle/ri/24296>>. Citado 2 vezes nas páginas 13 e 16.
- MAHESH, B. Machine learning algorithms - a review. *ResearchGate*, 2020. Disponível em: <[https://www.researchgate.net/profile/Batta-Mahesh/publication/344717762\\_Machine\\_Learning\\_Algorithms\\_-\\_A\\_Review/links/5f8b2365299bf1b53e2d243a/Machine-Learning-Algorithms-A-Review.pdf](https://www.researchgate.net/profile/Batta-Mahesh/publication/344717762_Machine_Learning_Algorithms_-_A_Review/links/5f8b2365299bf1b53e2d243a/Machine-Learning-Algorithms-A-Review.pdf)>. Citado na página 16.
- Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST*. 2022. Acesso em: 22 ago. 2024. Disponível em: <<https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>>. Citado 2 vezes nas páginas 15 e 17.
- TANURE, J. E. P. S.; TAHAN, C. M. V. Proposta de procedimentos e metodologia para estabelecimento de metas de qualidade (dec e fec) para concessionárias de distribuição de energia elétrica através da análise comparativa. 2004. Disponível em: <<https://repositorio.usp.br/item/001415412>>. Citado na página 17.
- ZANCHETTA, L. P. Trabalho de Conclusão de Curso, *Reconfiguração de Redes de Distribuição de Energia com Geração Distribuída Empregando Conceitos de Redes Elétricas Inteligentes*. Santa Catarina: [s.n.], 2014. Disponível em: <<https://repositorio.ufsc.br/bitstream/handle/123456789/128061/TCC%20-%20VF%20-%20Lucas%20P.%20Z%20-%20FINAL%20AJUSTADO.pdf?sequence=1>>. Citado na página 11.