



**UNIVERSIDADE FEDERAL DE ITAJUBÁ**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E**  
**TECNOLOGIA DA COMPUTAÇÃO - *CAMPUS* ITAJUBÁ**

**Identificação de anomalias em bobinas de  
circuitos auxiliares de disjuntores a SF6 por  
meio de lógica fuzzy**

**Pedro Henrique Fonseca Siqueira**

Itajubá - MG

29 de agosto de 2025



**UNIVERSIDADE FEDERAL DE ITAJUBÁ**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E**  
**TECNOLOGIA DA COMPUTAÇÃO - *CAMPUS* ITAJUBÁ**

**Pedro Henrique Fonseca Siqueira**

## **Identificação de anomalias em bobinas de circuitos auxiliares de disjuntores a SF6 por meio de lógica fuzzy**

Dissertação submetida ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação como parte dos requisitos para obtenção do Título de Mestre em Ciência e Tecnologia da Computação.

Orientador: Prof. Dr. Giovani Bernardes Vitor  
Coorientador: Prof. Dr. Ivan Paulo de Faria

Itajubá - MG  
29 de agosto de 2025

**Pedro Henrique Fonseca Siqueira**

# **Identificação de anomalias em bobinas de circuitos auxiliares de disjuntores a SF6 por meio de lógica fuzzy**

Dissertação submetida ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação como parte dos requisitos para obtenção do Título de Mestre em Ciência e Tecnologia da Computação.

---

**Prof. Dr. Giovani Bernardes Vitor**  
Orientador

---

**Prof. Dr. Ivan Paulo de Faria**  
Coorientador

---

**Prof. Dr. Sandro Carvalho Izidoro**

---

**Prof. Dr. Érick Oliveira Rodrigues**

Itajubá - MG  
17 de junho de 2025

# Resumo

Disjuntores de alta tensão são componentes cruciais na operação e proteção de sistemas elétricos, sendo responsáveis pelo desempenho seguro da rede. A integridade de seus circuitos auxiliares, especialmente das bobinas de abertura e fechamento, é vital para garantir o funcionamento confiável do equipamento. Problemas nesses componentes — como desgaste de materiais, falhas no gatilho, curto-circuitos internos ou variações no tempo de energização — podem comprometer a atuação do disjuntor, resultando em falha na interrupção da corrente, abertura indevida ou indisponibilidade do sistema. Este trabalho propõe um método de diagnóstico baseado em Sistemas de Inferência Fuzzy em série para avaliar a integridade desses componentes por meio do Grau de Risco, obtido a partir da análise dos sinais de corrente das bobinas de um disjuntor a SF6, sem a necessidade de interromper sua operação. Os resultados indicaram comportamento de classificação coerente com o esperado, com variações no Grau de Risco associadas ao acúmulo ou redução do Fator de Recorrência. Diferenças na quantidade e diversidade das amostras impactaram a estabilidade das classificações: disjuntores do modelo HD4 apresentaram maior exploração na variação de classificação dos intervalos, enquanto os do modelo AP3 mostraram maior magnitude e menor diversidade de valores. A análise de sinais de falha não se mostrou ideal para calibração preventiva, reforçando a importância de dados obtidos antes da ocorrência. Recomenda-se, em trabalhos futuros, ampliar o número de amostras em ambientes controlados e em campo, bem como integrar outras variáveis operacionais, visando maior robustez e aplicabilidade do modelo em sistemas elétricos mais complexos. Mesmo com essas limitações, o método contribui para a modernização do diagnóstico em sistemas de potência, promovendo maior disponibilidade e redução de custos operacionais.

**Palavras-chaves:** *Diagnóstico, Classificação, Bobina, Corrente, Disjuntor, Alta Tensão, Lógica fuzzy, Aprendizado de Máquina, Inteligência Artificial.*

# Abstract

High-voltage circuit breakers are critical components in the operation and protection of electrical power systems, ensuring the safe performance of the grid. The integrity of their auxiliary circuits, particularly the opening and closing coils, is essential for reliable equipment operation. Failures in these components — such as material wear, triggering faults, internal short circuits, or variations in energization time — can compromise breaker performance, resulting in unsuccessful current interruption, unintended tripping, or system unavailability. This work proposes a diagnostic method based on serial Fuzzy Inference Systems to evaluate the integrity of these components by calculating a Risk Degree from the analysis of coil current signals in an SF6 circuit breaker, without the need to interrupt equipment operation. The results demonstrated classification behavior consistent with expectations, with variations in the Risk Degree associated with the accumulation or reduction of the Recurrence Factor. Differences in the quantity and diversity of samples affected the stability of the classifications: HD4-model breakers showed greater exploration in the variation of classification intervals, while AP3-model breakers revealed higher magnitude and lower diversity of values. The analysis of fault signals was not suitable for preventive calibration, reinforcing the importance of pre-fault data. Future work should focus on expanding the number of samples in both controlled and field environments, as well as integrating other operational variables to increase the robustness and applicability of the model to more complex electrical systems. Despite these limitations, the proposed method contributes to the modernization of diagnostics in power systems, promoting greater availability and reducing operational costs.

**Keywords:** *Diagnostics, Classification, Coil, Current, Circuit Breaker, High Voltage, Fuzzy Logic, Machine Learning,*

# Lista de abreviaturas e siglas

|      |                                     |
|------|-------------------------------------|
| ACC  | <i>Acurácia</i>                     |
| EQM  | <i>Erro Quadrático Médio</i>        |
| MSE  | <i>Mean Squared Error</i>           |
| PREC | <i>Precisão</i>                     |
| VP   | <i>Verdadeiro Positivo</i>          |
| TP   | <i>True Positive</i>                |
| VN   | <i>Verdadeiro Negativo</i>          |
| TN   | <i>True Negative</i>                |
| FP   | <i>Falso Positivo</i>               |
| FN   | <i>Falso Negativo</i>               |
| BA   | <i>Bobina de Abertura</i>           |
| TC   | <i>Trip Coil</i>                    |
| BF   | <i>Bobina de Fechamento</i>         |
| CC   | <i>Closing Coil</i>                 |
| CA   | <i>Corrente Alternada</i>           |
| AC   | <i>Alternating Current</i>          |
| IA   | <i>Inteligência Artificial</i>      |
| RNA  | <i>Redes Neurais Artificiais</i>    |
| ANN  | <i>Artificial Neural Networks</i>   |
| FIS  | <i>Sistema de Inferência Fuzzy</i>  |
| SIF  | <i>Fuzzy Inference System</i>       |
| CNN  | <i>Convolutional Neural Network</i> |
| DT   | <i>Decision Tree</i>                |
| KNN  | <i>K-Nearest Neighbors</i>          |
| ML   | <i>Machine Learning</i>             |
| RF   | <i>Random Forest</i>                |
| SVM  | <i>Support Vector Machine</i>       |
| RNC  | <i>Rede Neural Convolutacional</i>  |
| AD   | <i>Árvore de Decisão</i>            |

|     |                                          |
|-----|------------------------------------------|
| AM  | <i>Aprendizado de Máquina</i>            |
| ACP | <i>Análise de Componentes Principais</i> |
| FA  | <i>Floresta Aleatória</i>                |
| MVS | <i>Máquina de Vetores de Suporte</i>     |
| TWC | <i>Transformada Wavelet Contínua</i>     |
| CWT | <i>Continuous Wavelet Transform</i>      |
| TWD | <i>Transformada Wavelet Discreta</i>     |
| DWT | <i>Discrete Wavelet Transform</i>        |
| TW  | <i>Transformada Wavelet</i>              |
| WT  | <i>Wavelet Transform</i>                 |
| TF  | <i>Transformada de Fourier</i>           |
| FT  | <i>Fourier Transform</i>                 |
| WP  | <i>Wavelet Packet</i>                    |
| PW  | <i>Pacote Wavelet</i>                    |
| FOM | <i>First of Maxima</i>                   |
| MOM | <i>Middle of Maxima</i>                  |
| CoM | <i>Center of Mass</i>                    |
| PdM | <i>Primeiro dos Máximos</i>              |
| MdM | <i>Meio dos Máximos</i>                  |
| CdM | <i>Centro de Massa</i>                   |
| SGF | <i>Savitzky-Golay Filter</i>             |
| FSG | <i>Filtro de Savitzky-Golay</i>          |
| OLM | <i>Online Monitoring</i>                 |

# Sumário

|          |                                          |           |
|----------|------------------------------------------|-----------|
|          | <b>Sumário</b>                           | <b>7</b>  |
| <b>1</b> | <b>INTRODUÇÃO</b>                        | <b>8</b>  |
| 1.1      | Contextualização                         | 8         |
| 1.2      | Problemática                             | 9         |
| 1.3      | Objetivos da dissertação                 | 10        |
| 1.4      | Justificativa e Contribuição             | 12        |
| 1.5      | Organização do Texto                     | 13        |
| <b>2</b> | <b>REFERENCIAL TEÓRICO</b>               | <b>14</b> |
| 2.1      | Embasamento Teórico                      | 14        |
| 2.1.1    | Disjuntores de alta tensão               | 14        |
| 2.1.2    | Filtros                                  | 19        |
| 2.1.2.1  | Filtro de Médias Móveis Exponenciais     | 19        |
| 2.1.2.2  | Filtro de Savitzky–Golay                 | 20        |
| 2.1.3    | Classificação e Classificadores          | 22        |
| 2.1.4    | Sistema Fuzzy                            | 23        |
| 2.1.4.1  | Fuzzificação                             | 24        |
| 2.1.4.2  | Inferência <i>Fuzzy</i> e base de regras | 24        |
| 2.1.4.3  | <i>defuzzificação</i>                    | 25        |
| 2.2      | Trabalhos Relacionados                   | 25        |
| <b>3</b> | <b>METODOLOGIA</b>                       | <b>29</b> |
| 3.0.1    | Sensoriamento e Tratamento de Dados      | 30        |
| 3.0.2    | Composição do Conjunto de Dados          | 32        |
| 3.0.3    | Treinamento do Modelo Classificador      | 33        |
| 3.0.4    | Testes e Validações                      | 40        |
| <b>4</b> | <b>RESULTADOS</b>                        | <b>41</b> |
| <b>5</b> | <b>CONCLUSÃO</b>                         | <b>48</b> |
|          | <b>REFERÊNCIAS</b>                       | <b>50</b> |



# 1 Introdução

A confiabilidade dos sistemas de proteção em redes elétricas depende de uma série de componentes que, embora discretos, exercem funções cruciais. Entre eles, as bobinas de comando dos disjuntores a SF6 merecem atenção especial, dado seu papel na execução das manobras elétricas. Este trabalho parte da necessidade de aprimorar os métodos de identificação de anomalias nesses dispositivos, propondo uma abordagem baseada em inteligência computacional e sistemas especialistas que busca maior precisão diante da variabilidade dos sinais reais.

## 1.1 Contextualização

O crescimento da demanda por energia e a incorporação de novas tecnologias tornam os sistemas elétricos de potência cada vez mais complexos. O aumento do número de equipamentos implica no número de conexões e na quantidade de manobras, exigindo maior sofisticação na operação, controle e proteção. Nesse contexto, o chaveamento de diversos dispositivos gera transitórios de tensão e corrente, podendo comprometer a integridade do sistema. Para mitigar esses impactos, é fundamental contar com equipamentos de proteção adequados, como disjuntores de alta tensão, que garantem a operação segura e confiável do sistema. (CHEN et al., 2015; BENMOUYAL NORMANN FISCHER; CHOWDHURY, 2018).

A crescente complexidade dos sistemas elétricos de potência acompanha o avanço tecnológico e a integração de novas fontes de energia. A quantidade de elementos adicionados e suas consequências expõem a rede a riscos de instabilidade, demandando soluções eficientes para seu gerenciamento e manutenção de indicadores satisfatórios (BENMOUYAL NORMANN FISCHER; CHOWDHURY, 2018; KAUSHAL; BASAK, 2020).

Os estudos de Shafiullah, Ahmed e Al-Sulaiman (2022) e Jacobson et al. (2015) apontam que o avanço das fontes de energia renováveis no sistema, como fotovoltaica, eólica e hídrica, traz consigo particularidades que podem comprometer a estabilidade da rede elétrica. A natural intermitência da geração e a variação na relação oferta e demanda exigem mecanismos de proteção para mitigar impactos na rede. Equipamentos como disjuntores atuam como barreiras de segurança que previnem falhas sistêmicas ao isolar irregularidades e evitarem sobrecargas. Em um sistema interligado, qualquer instabilidade gerada pela inserção de cargas ou fontes pode se propagar e afetar todo o funcionamento da rede elétrica.

Distúrbios elétricos impactam o sistema como um todo, inclusive os próprios equipamentos

de proteção. Portanto, além da inserção de dispositivos de segurança, como disjuntores de alta tensão, é essencial assegurar sua manutenção e funcionamento adequados para preservar a confiabilidade da rede (BENMOUYAL NORMANN FISCHER; CHOWDHURY, 2018; KAUSHAL; BASAK, 2020).

De acordo com Razi-Kazemi e Niayesh (2021) as principais estratégias de manutenção são três tipos: manutenção baseada no tempo, manutenção baseada na condição e a manutenção centrada na confiabilidade. A primeira, também conhecida por manutenção preventiva, são atividades realizadas a cada intervalo de tempo predefinido para evitar ou reduzir falhas nos componentes. A segunda, chamada de manutenção preditiva, determina o tempo de inspeção e as atividades necessárias com base na condição dos disjuntores por meio do número de operações, corrente da bobina ou outros sinais. O terceiro, por sua vez, é a implementação da preditiva em relação à criticidade de cada parte do sistema de energia. Ademais, também existe um quarto tipo, a manutenção corretiva, que se trata da tomada de ação após a ocorrência e detecção de falha, possuindo suas divisões como a não planejada (emergencial), planejada, paliativa ou curativa.

## 1.2 Problemática

Garantir a integridade dos mecanismos de proteção, como as bobinas de abertura (bobinas de abertura) e bobinas de fechamento (bobinas de fechamento) de disjuntores, é fundamental para o bom funcionamento dos sistemas elétricos de potência. Entretanto, existem limitações dos sistemas tradicionais de análise de falhas e manutenção, além da dificuldade na implementação de metodologias preditivas eficientes.

Disjuntores a SF6 possuem vários componentes internos que precisam ser avaliados, mas a maioria das intervenções requer que o disjuntor esteja desconectado da rede. Essa avaliação consome tempo e pode impactar a segurança e prontidão do sistema, exigindo melhorias nas estratégias de manutenção preditiva, preventiva e corretiva. (RUDSARI; RAZI-KAZEMI; SHOOREHDELI, 2019; VIANNA et al., 2017)

A escassez de informações de campo é um desafio presente, ainda mais difícil quando se trata de informações completas de dispositivos específicos, uma vez que o monitoramento de grandezas dos disjuntores por meio de periféricos pode ser insuficiente, principalmente de suas bobinas, dificultando a tomada de decisões. Muitas empresas não possuem registros adequados de falhas e defeitos nos equipamentos das subestações. (RUDSARI; RAZI-KAZEMI; SHOOREHDELI, 2019; VIANNA et al., 2017)

Como Razi-Kazemi e Niayesh (2021) apresentam, sistemas de monitoramento online (OLM) buscam monitorar sinais de diagnóstico de maneira contínua e precisa, e isso não é algo trivial, especialmente devido à complexidade das medições e análises ou por exigir investimentos consideráveis.

Ademais, reunir dados relevantes e modelá-los corretamente para prever falhas exige infraestrutura robusta e metodologias avançadas, o que dificulta a identificação precisa de tendências e o desenvolvimento de modelos probabilísticos confiáveis. Definir índices precisos para estimar a qualidade dos disjuntores e sua vida útil por meio de suas bobinas de acionamento é uma tarefa complexa. O nível de informação de campo e a qualificação técnica de profissionais são grandezas que devem caminhar juntas. O desequilíbrio entre elas proporciona um cenário de ineficiência na condução de tomada de decisões, podendo resultar no aumento da ocorrência e do impacto das falhas nas bobinas de abertura e de fechamento. Quando há alta complexidade das informações sem o conhecimento técnico, cria-se um cenário de demanda de contratação de especialistas. (RUDSARI; RAZI-KAZEMI; SHOOREHDELI, 2019; VIANNA et al., 2017; RAZI-KAZEMI; NIAYESH, 2021)

### 1.3 Objetivos da dissertação

Esta dissertação tem objetivos que podem ser divididos em duas categorias: uma de natureza geral, voltada para a estratégia do método proposto; e outra de caráter específico, que detalha os passos metodológicos, os critérios de avaliação e os contextos experimentais utilizados ao longo do estudo.

#### Objetivo Geral

O objetivo principal dessa dissertação é desenvolver e validar uma metodologia capaz de avaliar o estado das bobinas de disjuntores a SF6, por meio da análise dos sinais de corrente das bobinas de abertura e de fechamento. A estratégia aplicada utiliza um Sistema de Inferência *Fuzzy* (SIF) que permite interpretar sinais mesmo sob condições de ruído e variações operacionais, gerando diagnósticos mais precisos. Com essa abordagem, busca-se oferecer uma solução prática e simples para melhorar e facilitar a manutenção preditiva e aumentar a confiabilidade dos sistemas elétricos de potência.

#### Objetivos Específicos

Para avaliar a completude do método proposto e desenvolvido, o sistema foi estruturado a partir de um conjunto de objetivos específicos, organizados em categorias a saber:

- Implementar um sistema robusto de aquisição e pré-processamento dos sinais de corrente das bobinas, exemplificado na Figura 1;
- Realizar a extração de características representativas dos sinais coletados, preservando informações relevantes à análise de desempenho e detecção de anomalias, representado na Figura 2;

- Projetar e implementar regras baseadas em Lógica *Fuzzy*, fundamentadas no conhecimento de especialistas, para classificação dos padrões de energização das bobinas, conforme simbolizado na Figura 3;
- Validar experimentalmente o modelo proposto utilizando dados reais, obtidos em diferentes condições operacionais e níveis de ruído como mostrado na Figura 4.




Figura 1 – Aquisição e pré-processamento de sinais de corrente das bobinas de disjuntores de alta tensão, considerando diferentes modelos de equipamentos e variações de operação.




Figura 2 – Extração de características relevantes dos sinais de corrente, com o objetivo de identificar pontos críticos relacionados a desgaste ou falha em componentes internos do mecanismo de acionamento, como bobina, armadura ou gatilho da mola.




Figura 3 – Definição e aplicação de regras *Fuzzy* para classificar o comportamento de energização das bobinas, possibilitando a previsão de desgastes e falhas operacionais.




Figura 4 – Validação do modelo com dados experimentais reais provenientes de ensaios laboratoriais e de campo, avaliando sua eficácia sob diferentes condições de ruído e interferência.

## 1.4 Justificativa e Contribuição

A adoção da inteligência artificial (IA) para a automação de processos demorados e caros tem sido impulsionada pelo avanço tecnológico, especialmente em sistemas especialistas que utilizam inferência baseada em um banco de conhecimento para fornecer diagnósticos. Dentre essas abordagens, destacam-se os sistemas difusos, ou *Fuzzy*, que operam com variáveis linguísticas semelhantes à interpretação humana, tornando a tomada de decisões mais intuitiva e adaptável.

Essa abordagem permite identificar anomalias operacionais sem necessidade de interrupções no sistema elétrico de potência, oferecendo uma solução preditiva eficiente para manutenção. A técnica *Fuzzy* utilizada se destaca por sua flexibilidade na modelagem de sistemas complexos e por sua eficácia na manutenção preditiva, trazendo avanços na confiabilidade de disjuntores de alta tensão. A metodologia também aprimora a confiabilidade do diagnóstico ao mitigar interferências externas por meio de técnicas de filtragem e pré-processamento dos dados.

Comparado a métodos convencionais de diagnóstico, este modelo proporciona vantagens significativas, como a capacidade de operar em tempo real, eliminando dependências de inspeção manual e reduzindo custos operacionais. Além disso, ao analisar os sinais de energização das bobinas, o sistema pode detectar falhas iminentes com maior precisão, possibilitando uma intervenção preditiva antes da degradação completa do equipamento. Representando o conhecimento dos especialistas, o modelo não apenas processa dados, mas sim incorpora expertise técnica.

Portanto, é proposta a utilização de um método de classificação baseado em sistemas *Fuzzy*, através da análise de sinais provenientes da extração de características de interesse dos sinais de corrente das bobinas em subestações de grande porte, sujeitas a ruídos e interferências. Utiliza dados reais e desenvolve uma modelagem de inteligência artificial baseada em sistemas *Fuzzy*, representando o conhecimento dos especialistas na área. Essa abordagem permite uma avaliação contínua e precisa dos disjuntores de alta tensão, contribuindo significativamente para a manutenção preventiva e corretiva desses equipamentos.

## 1.5 Organização do Texto

Este trabalho de dissertação é composto por cinco capítulos que articulam, de forma integrada, a fundamentação teórica e a aplicação prática dos métodos investigados.

No Capítulo 1, a pesquisa é situada no contexto da análise das bobinas de acionamento de disjuntores de alta tensão, destacando sua importância para a confiabilidade de sistemas elétricos modernos. Este capítulo apresenta esse desafio e enfatiza a necessidade de integração entre técnicas de processamento de sinais com inteligência artificial para aprimorar a manutenção e a segurança operacional.

O Capítulo 2 dedica-se a uma revisão especializada da literatura. Aqui, são analisados estudos que abordam o processamento de sinais ruidosos e os diagnósticos em campo, com destaque para pesquisas que utilizam abordagens *Fuzzy* na monitorização de disjuntores a SF6. Essa análise evidencia as lacunas existentes nos métodos convencionais e justifica a adoção da metodologia proposta para superar tais desafios.

No Capítulo 3, detalham-se as etapas de implementação do projeto. São descritos os procedimentos de aquisição e pré-processamento dos sinais captados das bobinas, a implementação dos algoritmos *Fuzzy* para identificação de anomalias e as estratégias utilizadas para simular falhas. Este capítulo enfatiza os métodos experimentais adotados, garantindo a replicabilidade e a robustez dos processos aplicados.

No Capítulo 4, os principais achados são apresentados e analisados. Por meio de experimentos e simulações, são expostos os indicadores de desempenho do sistema, evidenciando a eficácia da abordagem *Fuzzy* na detecção precoce de falhas quando comparada aos métodos tradicionais de diagnóstico.

Por fim, o Capítulo 5 sintetiza as contribuições do estudo, discute as implicações práticas dos resultados e aponta as limitações encontradas. São sugeridas novas direções para pesquisas futuras, ressaltando o potencial de aprimoramento da metodologia *Fuzzy* na manutenção preventiva e corretiva de sistemas elétricos de potência.

## 2 Referencial Teórico

Este capítulo apresenta o embasamento teórico que sustenta a metodologia proposta, permitindo compreender sua fundamentação e justificar sua aplicação. A análise da literatura permite não apenas situar o trabalho no estado da arte, mas também evidenciar as lacunas e oportunidades de pesquisa que justificam sua realização.

Neste capítulo, são apresentados os conceitos técnicos que contextualizam o método proposto e são discutidos os principais estudos, técnicas e ferramentas relacionadas ao diagnóstico de equipamentos elétricos de alta tensão, com ênfase em bobinas de disjuntores a SF<sub>6</sub>, e destaque para abordagens que integram processamento de sinais e sistemas de inferência fuzzy. O conteúdo é organizado com intuito de transitar progressivamente entre a contextualização de trabalhos correlatos, a explanação detalhada dos conceitos que sustentam a análise e as tecnologias adotadas.

### 2.1 Embasamento Teórico

A avaliação preditiva da integridade de disjuntores a SF<sub>6</sub> requer um entendimento detalhado sobre sua estrutura, funcionamento e sinais característicos. Portanto, este capítulo apresenta os conceitos fundamentais para essa análise, incluindo o funcionamento dos disjuntores de alta tensão, técnicas de filtragem de sinais e o sistema Fuzzy, que serão empregados na classificação da condição das bobinas.

#### 2.1.1 Disjuntores de alta tensão

Os disjuntores de alta tensão são dispositivos eletromecânicos fundamentais para a proteção e a operação dos sistemas elétricos de potência. Eles atuam interrompendo automaticamente a corrente elétrica em situações anormais, como sobrecargas e curtos-circuitos, isolando a parte afetada do sistema para evitar que os danos se propaguem e garantindo a continuidade do fornecimento de energia. Por sua capacidade de suportar e interromper correntes na ordem de milhares de amperes e tensões de centenas de kilovolts, esses dispositivos são essenciais tanto em subestações de transmissão quanto em redes de distribuição, assegurando a integridade dos equipamentos e a segurança operacional.

Disjuntores consistem em três seções principais: seção de controle, mecanismo de operação e câmara de interrupção. Eles são convencionalmente categorizados com base no meio da técnica de extinção do arco elétrico; como ar, óleo, vácuo e SF<sub>6</sub> [Razi-Kazemi e Niayesh \(2021\)](#). Embora disjuntores a vácuo sejam mais comuns em sistemas de média tensão, alguns também são utilizados em determinadas aplicações de alta tensão, principalmente

quando a agilidade de operação e baixo custo de manutenção são fatores decisivos. Disjuntores a SF6 utilizam o gás hexafluoreto de enxofre (SF6) pela excelente propriedade dielétrica e de supressão de arcos, possuem ampla aplicação em sistemas de alta tensão devido à sua alta capacidade de interrupção e confiabilidade operacional.

Em disjuntores de alta tensão a SF6, o funcionamento seguro e eficiente depende de um conjunto integrado de componentes, cada um com funções específicas:

- **Contatos elétricos fixos e móveis:** São os elementos condutores que, ao contato, estabelecem a continuidade do circuito, ou promovem a interrupção da corrente ao se afastarem.
- **Compartimento de SF6:** Trata-se de uma câmara hermeticamente selada, onde o gás SF6 é armazenado sob pressão. Esse gás possui propriedades dielétricas altas e age na extinção rápida do arco elétrico formado entre os contatos, contribuindo tanto para o isolamento quanto para a supressão do arco.
- **Câmara de extinção de arco:** Localizada entre os contatos, é projetada para extinguir o arco elétrico quando os contatos se separam. Neste momento, o gás SF6 em alta pressão atua contra o movimento, desestabilizando o arco e impedindo sua sustentação.
- **Mecanismo de acionamento:** Responsável pelo movimento dos contatos, esse mecanismo pode ser composto por motores elétricos, atuadores hidráulicos ou sistemas eletromagnéticos. Sua função é garantir que os contatos se abram ou se fechem de maneira rápida e precisa, minimizando o tempo de exposição ao arco.
- **Bobinas de acionamento:** As bobinas convertem a energia elétrica em forças magnéticas necessárias para o funcionamento do mecanismo de abertura e fechamento. Elas desempenham um papel fundamental, assegurando que o movimento seja realizado com a energia e o tempo corretos para uma atuação segura.
- **Estrutura de suporte:** Composta por componentes mecânicos e materiais isolantes, a estrutura protege os elementos internos do dispositivo contra influências externas, garantindo a integridade elétrica e física do equipamento.

O diagrama apresentado na Figura 5 ilustra, de forma simplificada, o funcionamento do principal componente do disjuntor SF6 durante o processo de abertura, cujo objetivo é promover a extinção do arco elétrico.

A bobina é um enrolamento de fio condutor que, ao receber energia elétrica, cria um campo magnético, representado na Figura 6. Esse campo funciona como uma “força invisível” capaz de movimentar peças metálicas no seu interior.

Dentro do mecanismo do disjuntor, essas bobinas fazem o importante papel no acionamento do sistema de proteção. Quando o equipamento recebe o comando para abrir ou






Figura 5 – Funcionamento do disjuntor SF6 durante sua abertura e afastamentos de contatos representadas em duas etapas. Na parte superior os contatos estão fechados e energizados, o gás SF6 encontra-se em repouso em seu compartimento. A parte inferior representa o momento de afastamento dos contatos, comprimindo o gás isolante e ejetando contra a criação do arco voltaico.




Figura 6 – Representação do campo magnético em volta de uma bobina devido a energização do fio condutor.

fechar o circuito, a bobina correspondente (de disparo ou de fechamento) é energizada. Assim que a corrente elétrica atinge um valor específico, o campo magnético gerado desloca

uma peça chamada armadura, que atua como um gatilho mecânico. Esse gatilho libera a energia acumulada em um conjunto de molas, as quais, ao se expandirem, movimentam os contatos elétricos para abrir ou fechar o circuito. Todo esse processo ocorre em frações de segundo e está ilustrado na Figura 7.




Figura 7 – Etapas de funcionamento do conjunto de acionamento de um disjuntor SF6. (a) representa o estado de repouso e seus componentes identificados; (b) o momento que a bobina é energizada e o êmbolo inicializa sua movimentação; (c) Momento de contato entre o êmbolo e gatilho da mola; (d) liberação da mola; (e) extensão completa da mola e abertura de contatos principais e auxiliares; (f) Desenergização da bobina de trip.

Como levantado por [Nenning \(2013\)](#), [Razi-Kazemi e Niayesh \(2021\)](#), a forma de onda e os valores da corrente elétrica que atravessam essas bobinas, durante a abertura e o fechamento dos contatos principais, fornecem informações detalhadas sobre o desempenho de um sistema. [Nenning \(2013\)](#) apontam informações como as propriedades elétricas das bobinas, como a constante de tempo e a força que deve ser aplicada para acionamento da mola.

Ademais, por meio da análise da forma de onda, a combinação da medição da resistência dinâmica do contato e da análise de movimento pode ser usada para avaliar a condição dos contatos de arco em disjuntores sem a necessidade de desmontagem. Como esses contatos sofrem desgaste natural devido à formação de arcos elétricos, é essencial inspecioná-los regularmente para evitar falhas. Além disso, a análise de movimento pode identificar problemas mecânicos, como amortecedores desgastados e vazamentos do sistema de pressão, permitindo a detecção precoce de defeitos([NENNING, 2013](#)).

Apesar do sinal de energização da bobina possuir natureza assimétrica e não uniforme, como apresentado pela Figura 8, não é o melhor objeto de análise por sistemas classificadores como o Fuzzy. No entanto, ao aplicar a interpretação por intervalos de [Nenning \(2013\)](#), obtém-se uma abordagem essencial para diagnósticos baseados em lógica Fuzzy. A interpretação de [Nenning \(2013\)](#) analisa individualmente os intervalos da Figura 8, sendo possível compreender o comportamento e identificar possíveis falhas mecânicas e elétricas associadas:




Figura 8 – Forma de onda típica da energização de bobina de abertura e bobina de fechamento, de acordo com [Nenning \(2013\)](#), evidenciando pontos de interesse e intervalos característicos.

- **Intervalo 1-2:** Após a energização da bobina, a corrente aumenta dependendo da impedância e da posição da armadura. Qualquer variação na corrente pode indicar problemas na bobina ou na alimentação da tensão. Aqui a constante de tempo ( $RL$ ) pode ser encontrada e usada para diagnóstico.
- **Intervalo 2-3:** A armadura em movimento gera uma força eletromotriz inversa, reduzindo a corrente. Neste estágio, a armadura precisa superar a resistência mecânica do gatilho. Variações no sinal podem indicar presença de óleo ou graxa, desalinhamento da armadura ou obstruções.
- **Intervalo 3-4:** A armadura libera a mola carregada e se move até atingir sua posição final. A corrente diminui conforme o movimento prossegue. Um desvio na corrente mais baixa pode indicar que a armadura não chegou à posição final correta devido a problemas mecânicos.
- **Intervalo 4-5:** Quando a armadura para, a força eletromotriz inversa desaparece e a corrente volta a subir devido à mudança na indutância da bobina. Um desvio na constante de tempo pode indicar danos nos enrolamentos da bobina.

- **Intervalo 5-6:** A corrente se estabiliza até que o contato auxiliar abra e interrompa o fluxo elétrico. O tempo de abertura dos contatos pode precisar de ajuste se a interrupção ocorrer antes ou depois do esperado.
- **Intervalo 6-7:** O contato auxiliar interrompe a tensão da bobina, fazendo a armadura retornar à posição inicial. Uma redução lenta na corrente ou um aumento inesperado pode indicar atrito mecânico ou falha no diodo de recuperação.

### 2.1.2 Filtros

Os sinais elétricos adquiridos das bobinas frequentemente apresentam ruídos que dificultam a correta interpretação dos padrões de falha. Em ambientes ruidosos, é fundamental utilizar métodos que reduzam interferências sem comprometer as características essenciais do sinal original, permitindo uma análise mais precisa na etapa do SIF. Nesse contexto, técnicas de filtragem, como o filtro de Médias Móveis Exponenciais (MMEs) e o filtro de Savitzky–Golay, são aplicadas para suavizar e diferenciar os dados, permitindo uma análise mais precisa na etapa de inferência *Fuzzy* e garantindo a confiabilidade da classificação.

#### 2.1.2.1 Filtro de Médias Móveis Exponenciais

O filtro de Médias Móveis Exponenciais (MMEs), também conhecido como suavização exponencial, é uma técnica empregada para reduzir a volatilidade em séries temporais, atribuindo pesos decrescentes — de forma exponencial — às observações passadas. Ao contrário da média móvel simples (ou aritmética), que considera todas as observações com igual importância, a suavização exponencial confere maior relevância aos dados mais recentes, o que permite uma resposta mais ágil frente a variações no sinal.

A Figura 9 ilustra a aplicação dos dois filtros sobre um sinal ruidoso: a média móvel simples e a exponencial. Utilizando uma janela de 30 amostras, observa-se que o filtro exponencial evidencia com maior nitidez os movimentos de crescimento e queda do sinal original.

Seja  $S_t$  a observação no instante  $t$  e  $SF_t$  o valor suavizado filtrado nesse mesmo instante. O modelo recursivo para o cálculo do valor suavizado é dado por:

$$SF_t = \alpha S_t + (1 - \alpha) SF_{t-1}, \quad t \geq 2, \quad (2.1)$$

onde  $\alpha$  é o parâmetro de suavização, com  $0 < \alpha \leq 1$ . Em geral, define-se a condição inicial como:

$$SF_1 = S_1 \quad \text{ou} \quad SF_1 = \frac{1}{N} \sum_{i=1}^N S_i, \quad (2.2)$$

para compensar eventuais irregularidades nos dados iniciais.




Figura 9 – Exemplo da aplicação de filtros de média móvel simples e exponencial. Sinal extraído de dados do mercado financeiro, entre 2024 e 2025, através da biblioteca *yfinance* em Python.

Percorrendo a equação recursiva, a expressão de  $SF_t$  pode ser expandida como:

$$\begin{aligned} SF_t &= \alpha S_t + \alpha(1 - \alpha)S_{t-1} + \alpha(1 - \alpha)^2 S_{t-2} + \cdots + (1 - \alpha)^{t-1} SF_1 \\ &= \alpha \sum_{k=0}^{t-1} (1 - \alpha)^k S_{t-k}, \end{aligned} \quad (2.3)$$

na medida em que  $t$  aumenta, o termo  $(1 - \alpha)^{t-1} SF_1$  tende a ser irrelevante. Assim, observa-se que o peso atribuído à observação  $S_{t-k}$  é  $\alpha(1 - \alpha)^k$ , decaindo exponencialmente com o atraso  $k$ .

O valor do parâmetro  $\alpha$  pode ser definido como a “memória” do filtro. Assim, valores de  $\alpha$  próximos a 1 implicam uma alta sensibilidade às variações recentes. Por outro lado, com  $\alpha$  próximo de 0 implica em maior peso às observações anteriores, garantindo uma suavização mais robusta, porém menos reativa a mudanças súbitas. Dessa forma, a escolha de  $\alpha$  deve considerar a volatilidade e as características inerentes à série temporal analisada.

### 2.1.2.2 Filtro de Savitzky–Golay

O filtro de Savitzky–Golay é uma técnica amplamente empregada de suavização de sinais que busca atenuar o ruído sem distorcer características relevantes, como picos e largura das formas de onda. Proposto por [Savitzky e Golay \(1964\)](#), o método se baseia no ajuste polinomial por mínimos quadrados aplicado a uma janela móvel de pontos amostrados.

A Figura 10 mostra um exemplo prático da aplicação do filtro. Com uma janela de 31 amostras e polinômio de segunda ordem, o filtro consegue suavizar as variações rápidas do sinal, preservando sua forma geral, incluindo seus picos e vales mais expressivos.

Considere um sinal amostrado composto por  $k$  pontos denotados por  $\{(x_i, y_i)\}_{i=1}^k$  com espaçamento uniforme  $h$ . Para aplicar o filtro, define-se uma janela de  $n = 2m + 1$  pontos




Figura 10 – Exemplo da aplicação do filtro de Savitzky–Golay. Sinal extraído de dados do mercado financeiro, entre 2024 e 2025, através da biblioteca *yfinance* em Python.

centrada no ponto  $x_c$ . Em cada janela, ajusta-se um polinômio de grau  $r$  dado por:

$$P(x) = a_0 + a_1 (x - x_c) + a_2 (x - x_c)^2 + \cdots + a_r (x - x_c)^r, \quad (2.4)$$

de forma a minimizar a soma dos erros quadráticos:

$$\min_{a_0, a_1, \dots, a_r} \sum_{i=-m}^m \left[ y(x_c + i h) - P(x_c + i h) \right]^2. \quad (2.5)$$

A formulação matricial deste problema envolve a definição do vetor de observações:

$$\mathbf{y} = \begin{pmatrix} y(x_c - m h) \\ y(x_c - (m-1) h) \\ \vdots \\ y(x_c + m h) \end{pmatrix}, \quad (2.6)$$

e da matriz de projeto  $\mathbf{Z}$ , cujos elementos são definidos por:

$$Z_{ij} = (i h)^{j-1}, \quad \text{para } i = -m, \dots, m \quad \text{e } j = 1, \dots, r+1. \quad (2.7)$$

A solução do problema de mínimos quadrados para os coeficientes do polinômio é dada por:

$$\mathbf{a} = (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{y}. \quad (2.8)$$

O valor suavizado atribuído ao ponto central  $x_c$  é o coeficiente  $a_0$ , e, caso seja necessária a estimação da primeira derivada do sinal, utiliza-se:

$$P'(x_c) = a_1. \quad (2.9)$$

A eficácia do filtro depende criticamente da escolha dos parâmetros  $n$  (tamanho da janela) e  $r$  (grau do polinômio). Uma janela maior pode aumentar a atenuação do ruído, porém corre o risco de suavizar demais as variações locais importantes do sinal. Em contrapartida, um polinômio de grau elevado permite modelar variações mais complexas, mas eleva o risco de *overfitting* dos dados.

### 2.1.3 Classificação e Classificadores

Um *classificador* é um modelo ou algoritmo de aprendizado supervisionado que, a partir de um conjunto de exemplos rotulados, aprende a estabelecer um mapeamento entre um espaço de entrada — composto por variáveis ou características — e um conjunto finito de rótulos ou classes. Sua função central é atribuir a uma nova instância de dados à categoria mais provável, com base nos padrões aprendidos durante o treinamento.

Diversas abordagens podem ser empregadas para essa tarefa, incluindo métodos estatísticos, redes neurais artificiais, árvores de decisão, máquinas de vetores de suporte e sistemas de inferência *Fuzzy*. Cada uma apresenta vantagens e limitações próprias quanto à interpretabilidade, robustez e adequação aos diferentes tipos de dados.

No contexto do diagnóstico inteligente de falhas (*Intelligent Fault Diagnosis* — IFD), conforme discutido por [Lei et al. \(2020\)](#), classificadores são elementos essenciais para relacionar dados monitorados às condições operacionais de máquinas. Técnicas de aprendizado de máquina (*Machine Learning* — ML) têm reduzido a dependência da análise manual, permitindo diagnósticos automáticos com maior agilidade e consistência. Abordagens mais recentes, como o aprendizado profundo (*Deep Learning* — DL), viabilizam estratégias de processamento *end-to-end*, mapeando diretamente dados brutos para estados de saúde. Já o aprendizado por transferência (*Transfer Learning* — TL) busca reaproveitar conhecimento obtido em um domínio para resolver problemas em outro, superando limitações típicas na aplicação prática de classificadores, como a escassez de dados rotulados.

O classificador adotado neste trabalho baseia-se em lógica *Fuzzy*, capaz de lidar com incertezas e variações sutis nos sinais das bobinas. Essa escolha está alinhada com os desafios destacados por [Lei et al. \(2020\)](#), que incluem variações operacionais, presença de ruído e a necessidade de modelos com boa capacidade de generalização, mesmo em condições distintas das vistas no treinamento.

De forma geral, um problema de classificação consiste em associar a cada instância de entrada  $\mathbf{x}$  um rótulo específico  $\mathbf{y}$ , conforme a relação apresentada em 2.10.

$$\mathbf{x} \in R^n, \quad \text{e} \quad \mathbf{y} \in \mathcal{C} = \{c_1, c_2, \dots, c_k\}. \quad (2.10)$$

Na prática, essa tarefa envolve três partes:

- Um conjunto de dados com amostras rotuladas para treinamento e validação;
- Um conjunto de atributos (ou *features*) que descrevem cada instância;
- Um modelo de decisão que, treinado com base nos exemplos conhecidos, prediz o rótulo de novas instâncias.

Assim, o uso de classificadores está diretamente relacionado à capacidade de automatizar diagnósticos, reduzir custos e aumentar a confiabilidade de sistemas críticos, conforme evidenciado no panorama apresentado por [Lei et al. \(2020\)](#).

#### 2.1.4 Sistema Fuzzy

Os sistemas Fuzzy, ou sistemas difusos, são especialistas em classificação baseados na lógica Fuzzy, uma técnica matemática introduzida por [Zadeh \(1999\)](#) em 1965. A abordagem utilizando sistemas Fuzzy lida com variáveis linguísticas, incertezas e imprecisões, diferenciando-se dos métodos tradicionais de classificação. Ao contrário da interpretação binária utilizada pelos computadores, a lógica *Fuzzy* opera com um modelo de inferência baseado em graus de pertencimento dentro de uma variável linguística, que é aquela cujo valor é uma palavra ou expressão em linguagem natural, aproximando-se da forma como os humanos processam informações. Para isso, o sistema se baseia em um conjunto de regras que combinam variáveis linguísticas para gerar resultados gradativos entre 0 e 1.

Devido à sua capacidade de lidar com incertezas e verdades parciais, a lógica *Fuzzy* é amplamente utilizada em diversas áreas. No contexto dos sinais elétricos das bobinas, por exemplo, essa abordagem se mostra eficaz ao modelar variações sutis que passam despercebidas por classificadores tradicionais. Diferentemente dos métodos determinísticos, os sistemas *Fuzzy* atribuem graus de pertencimento aos padrões de sinais, proporcionando um diagnóstico mais intuitivo e robusto. A lógica *Fuzzy* é composta por dois conceitos principais: conjuntos *Fuzzy* e funções de pertinência. De acordo com [Zadeh \(1999\)](#), um conjunto *Fuzzy*  $F$  definido em um universo  $U$  é caracterizado por uma função de pertinência:

$$\mu_F : U \rightarrow [0, 1] \quad (2.11)$$

e pode ser representado pelo conjunto de pares ordenados:

$$F = \{(u, \mu_F(u)) \mid u \in U\} \quad (2.12)$$

em que  $\mu_F(u)$  indica o grau de pertinência (ou compatibilidade) do elemento  $u$  em relação ao conjunto  $F$ .

A variável linguística compõe um conjunto *Fuzzy* e representa um estado ou propriedade a ser avaliada. Suas funções de pertinência são funções que determinam o grau de pertinência



de um valor dentro das classificações linguísticas. Por exemplo, para um conjunto *Fuzzy* chamado "temperatura", uma de suas regiões dentro do conjunto pode ser "fria". Para uma temperatura de 13°C, de acordo com sua função de pertinência, o grau de pertinência dessa temperatura na região "fria" poderia ser 0,9.

O funcionamento dos sistemas *Fuzzy* consiste na inserção de valores de entrada, que resultam em um único valor de saída. Essa transformação de múltiplas variáveis de entrada em uma variável de saída pode ser estruturada em três etapas; *Fuzzificação*, Inferência Fuzzy, *Defuzzificação* conforme ilustrada na Figura 11:



Figura 11 – Diagrama exemplo de um sistema de inferência Fuzzy (SIF) com duas variáveis de entrada e uma de saída.

#### 2.1.4.1 Fuzzificação

A *fuzzificação* é o processo de conversão de valores precisos em variáveis linguísticas. Nesta etapa, as funções de pertinência podem apresentar diferentes características, como funções triangulares, trapezoidais ou gaussianas. Um determinado valor de entrada de um conjunto, através de suas funções de pertinência, pode ter graus distintos dentro de cada região de classificação.

#### 2.1.4.2 Inferência Fuzzy e base de regras

A base de regras é construída considerando as combinações das regiões acionadas dos conjuntos de entrada com as regiões dos conjuntos de saída esperadas. Essas regras dependem do método de inferência escolhido como Mandani, Sugeno entre outros (MAMDANI, 1977; SUGENO; KANG, 1986). As regras do tipo Mandani, por exemplo, são as mais tradicionais e baseadas na estrutura "se ... então". Durante a especificação da base de regras, o conhecimento de engenheiros, cientistas e especialistas é inserido, influenciando a congruência dos resultados do sistema.

### 2.1.4.3 defuzzificação

A *defuzzificação* é o processo inverso da *fuzzificação*, destinado a chegar a um valor preciso. Com as regiões do conjunto de saída acionadas pela execução das regras, cabe à *defuzzificação* transformar as variáveis linguísticas em um único valor numérico. Existem várias formas de realizar esse processo, incluindo:

- **Centroide:** Método de *defuzzificação* que calcula o centro de massa da função de pertinência, fornecendo um valor representativo da saída Fuzzy.
- **First-of-Maxima (FOM):** Escolhe o primeiro valor que atinge o máximo da função de pertinência, priorizando o menor entre os valores máximos.
- **Middle-of-Maxima (MOM):** Seleciona a média dos valores que possuem a pertinência máxima, equilibrando as opções possíveis.
- **Critério Máximo:** Determina a saída com base nos valores que apresentam o maior grau de pertinência, podendo seguir variações como FOM ou MOM.

## 2.2 Trabalhos Relacionados

Pesquisas em manutenção e monitoramento de equipamentos elétricos têm avançado significativamente com o surgimento de métodos de inteligência artificial e aprendizado de máquina. Diversos estudos exploram diferentes abordagens para avaliar a condição de disjuntores e transformar dados complexos em informações úteis para a tomada de decisão. Esta seção revisa alguns dos principais trabalhos relacionados, destacando metodologias que utilizam técnicas de inferência *Fuzzy*.

[Razi-Kazemi \(2015\)](#) apresenta um algoritmo de avaliação baseado em um sistema de análise *Fuzzy* com probabilidade para avaliar o desempenho de disjuntores a SF6. O estudo utiliza padrões dos sinais de corrente da bobina adquiridos de 60 disjuntores em condições normais e de falha. O método, proposto com base nos resultados das análises estatísticas das características, demonstra sua viabilidade e aplicabilidade na avaliação da condição dos disjuntores, distinguindo adequadamente condições normais de estados de falha. Comparado ao trabalho de [Razi-Kazemi \(2015\)](#), o método proposto neste trabalho também aborda o diagnóstico de forma probabilística e linguística. No entanto, enquanto [Razi-Kazemi \(2015\)](#) utiliza um único sistema *Fuzzy* com três entradas agrupadas, este trabalho emprega múltiplas camadas, associando segmentos do sinal para caracterizar mais especificamente um componente interno fundamental ao estado do disjuntor.

[Li et al. \(2015\)](#) apresenta um sistema de diagnóstico de falhas baseado em Máquina de Vetores de Suporte (SVM), utilizando características extraídas da corrente das bobinas de abertura e bobinas de fechamento. Embora a abordagem com SVM tenha demonstrado eficiência na classificação de falhas comuns, a precisão do diagnóstico pode ser compro-

metida pela presença de ruídos, mesmo após a aplicação dos filtros usados. Além disso, o desempenho do sistema é sensível ao ajuste de parâmetros específicos, o que pode afetar significativamente a discriminação entre falhas, caso configurados incorretamente. Para contornar essas limitações, o presente trabalho propõe um SIF, que, ao empregar conjuntos de amostras e variáveis linguísticas para auxiliar na tomada de decisões, reduz o impacto de ruídos e parâmetros sensíveis sobre o diagnóstico. Em vez de fornecer uma certeza absoluta, o SIF estabelece um grau de classificação adaptável.

Vianna et al. (2017) desenvolveram o Índice de Risco Composto para disjuntores, calculado a partir de inferência *Fuzzy* em cascata. No primeiro sistema *Fuzzy*, análises relacionadas às características do gás SF<sub>6</sub>, à resistência de contatos e aos tempos de acionamento, junto a variáveis intensificadoras como frequência de falhas e manutenções, determinam a condição básica do equipamento. A segunda inferência *Fuzzy* associa esta condição básica com a avaliação de especialistas quanto ao grau de severidade do dispositivo, resultando no índice de risco composto. Esse sistema especialista *Fuzzy* em cascata permite a identificação da condição de equipamentos, fundamental para decisões de manutenção custo-benefício. Embora o método de Vianna et al. (2017) priorize de maneira realista as ações de manutenção, ele utiliza apenas um valor matemático como entrada do sistema, dificultando a uniformização dos critérios de avaliação para diferentes disjuntores. O método deste trabalho busca uma avaliação especializada de uma grandeza, onde múltiplas características do sinal são entradas associadas para uma avaliação uniforme do componente.

Žarković e Stojković (2019) apresenta um sistema *Fuzzy* do tipo Mamdani para indicar a saúde do disjuntor SF<sub>6</sub> e sua probabilidade de falha. Devido à complexidade presente de 15 entradas para 1 saída, o autor divide as entradas em 3 grupos de subsistemas *Fuzzy*. Essa escolha permite a identificação da saúde de cada parte do equipamento, com grupos de entrada relacionados aos contatos, à câmara de extinção de arco e aos mecanismos de acionamento. Portanto, as ideias apresentadas fornecem uma base estrutural de sistemas especialistas baseados em múltiplos sistemas *Fuzzy*, evidenciando a importância de medições online e avaliações em tempo real de disjuntores. A abordagem de Žarković e Stojković (2019) possui alta complexidade ao combinar vários métodos de monitoramento e diagnóstico, além de depender do conhecimento de valores limites de parâmetros e condições de operação. A abordagem deste trabalho busca baixa complexidade, facilitando a escalabilidade, e não depende de valores limites de parâmetro, mas apenas de valores normais de operação.

Rudsari, Razi-Kazemi e Shoorehdeli (2019) utiliza a combinação de dois métodos de classificação para promover a detecção precoce de falhas iminentes em disjuntores de alta tensão. O estudo destaca os sinais de corrente da bobina e o deslocamento dos contatos como fundamentais para uma avaliação abrangente do estado do equipamento. Sinais saudáveis e defeituosos são simulados, variando tensões de controle, resistências da bobina

e coeficientes de amortecimento, abrangendo 475 amostras de teste e 200 amostras de validação. A combinação de Redes Neurais e Máquinas de Vetores de Suporte é utilizada para classificar os sinais, que são posteriormente comparados com sinais reais de um disjuntor. A metodologia apresenta precisão em detectar falhas em estágios iniciais, permitindo intervenções preditivas e adaptativas para outros equipamentos elétricos. [Rudsari, Razi-Kazemi e Shoorehdeli \(2019\)](#) recorrem a simulações para treinar os classificadores, visando dados abrangentes e precisos, sem utilizar dados reais. O algoritmo de distinção adicional exige um profundo entendimento dos padrões de falha e do comportamento dos disjuntores, elevando a complexidade. O método proposto neste trabalho busca um sistema eficiente de baixa complexidade que utiliza parâmetros baseados em amostras reais.

[Ruan et al. \(2022\)](#) apresenta um método para melhorar a identificação de falhas em disjuntores de alta tensão, correlacionando sinais de vibração e corrente da bobina. Características dos sinais são extraídas através da reconstrução do espaço de fase e, em seguida, a SVM é utilizada para criar um modelo de identificação de falhas. Testes de simulação avaliam variações dos sinais em condições de falha. A combinação dessas características aumenta a precisão na identificação de falhas no mecanismo de disparo. Diferentemente de [Ruan et al. \(2022\)](#), o presente trabalho visa o entendimento profundo das dinâmicas do mecanismo de disparo por meio somente do sinal da bobina, evitando a dificuldade de estabelecer correlação entre corrente e vibração.

[Medina et al. \(2022\)](#) apresenta uma metodologia para estimar o índice de risco de transformadores de potência, utilizando sistemas de inferência *Fuzzy*. O índice de risco é formado pela associação do índice de saúde com o fator de consequência, ambos resultados de uma inferência *Fuzzy*. Tanto o sistema *Fuzzy* para o Índice de Saúde quanto o sistema *Fuzzy* para o Fator de Consequência possuem cinco entradas: o primeiro se refere ao estado interno do equipamento, e o segundo aos potenciais impactos de falha. O sistema completo foi testado em 15 transformadores e comparado com métodos tradicionais. A metodologia propõe um robusto sistema de múltiplas camadas *Fuzzy* para determinar um índice de risco de transformadores de potência, evidenciando a flexibilidade do sistema *Fuzzy* dentro de uma rede elétrica. A metodologia de [Medina et al. \(2022\)](#) utiliza diversas grandezas diferentes associadas já na primeira camada, dificultando a uniformização dos critérios de avaliação, uma vez que elas exigem o conhecimento de valores limites e condições de operação. O método deste trabalho não exige o conhecimento dos valores limites, pois os parâmetros são determinados pela amostragem do comportamento padrão.

[Wang et al. \(2022\)](#) propõem um método para diagnóstico de falhas mecânicas em disjuntores de alta tensão através do Aprendizado por Transferência de Poucos Exemplos. A abordagem utiliza uma rede neural convolucional unidimensional para extrair características discriminativas dos sinais de falha, permitindo um diagnóstico confiável mesmo com dados limitados. No entanto, o método apresenta dependência da qualidade dos sinais

adquiridos, prejudicando sua eficácia pelas variações significativas nas condições de operação dos disjuntores. Diferentemente do método de Wang et al. (2022), o método proposto neste trabalho integra um SIF para tratar incertezas associadas aos sinais coletados, proporcionando robustez ao diagnóstico, mesmo diante de variações operacionais e flutuações no padrão dos sinais adquiridos.

(LIU et al., 2023) apresenta um método de diagnóstico de falhas em mecanismos de operação de disjuntores a SF6 baseado na análise de sinais de vibração, integrando técnicas como Transformada S Generalizada, Matriz de Co-ocorrência de Níveis de Cinza, Padrão Binário Local e o método de máxima relevância e mínima redundância, combinadas à Máquina de Aprendizado Extremo. Embora apresente alta precisão na classificação, o método depende de um grande número de parâmetros e pode ter sua eficácia reduzida pelas estruturas mecânicas de diferentes tipos de disjuntores. Em contrapartida, o modelo proposto simplifica a integração de técnicas e reduz a quantidade e a complexidade de parâmetros, além de entregar maior adaptabilidade a distintos equipamentos durante o treinamento.

Diante dos métodos de diagnóstico *Fuzzy* apresentados na literatura, observa-se uma tendência crescente na busca por soluções que conciliem precisão e eficiência computacional. No entanto, muitas abordagens ainda enfrentam desafios relacionados à escalabilidade e à sensibilidade a ruídos. Com isso, o modelo proposto nesta dissertação busca simplificar a implementação, reduzir a complexidade computacional e aprimorar a confiabilidade do diagnóstico de disjuntores através da classificação das bobinas do componente, servindo como uma ferramenta auxiliar de decisões por meio de um SIF adaptativo em cascata. A próxima seção detalha os fundamentos teóricos necessários para a construção deste modelo.

### 3 Metodologia

A metodologia adotada neste trabalho segue o fluxo de desenvolvimento apresentado na Figura 12, o qual orienta todas as fases da modelagem e implementação do sistema *fuzzy* proposto. O processo foi dividido em quatro etapas principais, cada uma delas desempenhando um papel essencial no desenvolvimento do classificador.




Figura 12 – Fluxograma do desenvolvimento da metodologia proposta no presente trabalho.

Na primeira etapa, realiza-se a aquisição dos sinais provenientes de sensores de corrente acoplados aos equipamentos monitorados, seguida do pré-processamento dos dados, visando a melhoria da qualidade dos sinais e a facilitação de sua análise. Na segunda etapa ocorre a interpretação e o armazenamento das informações obtidas, utilizando métodos computacionais para extrair características relevantes dos sinais. A terceira etapa contempla a modelagem e a parametrização dos modelos *fuzzy*, modelando as características relevantes para a entrada do sistema, com foco na adequação ao contexto de aplicação específico. Por último, ocorre a validação e os ajustes do modelo, por meio da comparação entre os sinais de referência e os resultados gerados pelo classificador, garantindo a

confiabilidade e o desempenho da solução proposta.

### 3.0.1 Sensoriamento e Tratamento de Dados

Na primeira fase de desenvolvimento, os dados foram coletados de um protótipo localizado na Universidade Federal de Itajubá - Campus de Itabira (UNIFEI), que utiliza um disjuntor HD4 12kV da ABB. Neste protótipo, apresentado na Figura 13, o circuito de potência foi montado com o intuito de monitorar eventos do disjuntor.

Posteriormente, foram incorporados ao desenvolvimento sinais provenientes de cenários distintos, utilizando o mesmo processo de sensoriamento. Especificamente, os dados incluíram os sinais do disjuntor 3AP 345kV da Siemens, registrados pelo laboratório da Furnas Centrais Elétricas S.A., e os sinais obtidos do disjuntor 3AP 245kV da Siemens, coletados na subestação de Tijuco Preto.




Figura 13 – Visão geral do Setup de Ensaio do Protótipo. (1) Transformador trifásico elevador de 15 kVA, 220 V - 13,8 kV; (2) Painel de comando e proteção, responsável pela energização e proteção do circuito de potência e de comando; (3) Painel de medição de sinais, onde estão abrigados os sensores de efeito Hall de corrente e tensão; (4) Transformadores de instrumentos (TPs e TCs) do circuito primário; (5) Disjuntor ABB HD4-RE sob ensaio em condições de tensão próxima da nominal (13,8 kV); (6) Transformador trifásico abaixador de 15 kVA, 13,8 kV - 220 V; (7) Carga resistiva de 7 kW, 220 V.

As informações de eventos e os dados periódicos de monitoramento, coletados por uma plataforma de sensoriamento, são enviados para uma Central de Dados e armazenados em um banco de dados temporal. Esse material é processado para identificar ocorrências, como manobras de abertura e fechamento do disjuntor. Durante cada evento, a plataforma transmite janelas de dados referentes aos momentos anterior, durante e posterior à ocorrência, que são armazenadas separadamente. Em seguida, essas janelas são agrupadas e analisadas para extrair características relevantes. Para identificar o tipo de manobra, o sistema examina os sinais de corrente das bobinas, buscando alterações significativas.



Devido à presença de ruídos foram aplicados filtros para tratar os ruídos inerentes ao sinal. Inicialmente, um filtro de média móvel exponencial adaptativo foi aplicado, apresentado em (3.1).

$$SF(i) = \alpha f(m)S(i) + (1 - \alpha)f(m)SF(i - 1) \quad (3.1)$$

onde  $SF(i)$  representa o sinal filtrado,  $S(i)$  representa o sinal da bobina,  $i$  a amostra do sinal,  $\alpha$  a componente de ponderação definida na Tabela 1, e  $f(m)$  sendo definida em (3.2):

$$f(m) = \begin{cases} \frac{1}{m^{10}}, & \text{se } m \geq 1.0 \\ m, & \text{se } m < 1.0 \end{cases} \quad (3.2)$$

O valor de  $m$  é calculado a partir da variação dos dados na janela deslizante em (3.3).

$$m = \frac{\max(|S(i) - S(i - 1)|, |S(i + 1) - S(i)|)}{md} \quad (3.3)$$

Em (3.4),  $md$  representa a média das variações absolutas dos dados dentro da janela de tamanho  $w$ , apresentada na Tabela 1.

$$md = \frac{1}{w} \sum_{k=1}^w |S(k) - S(k - 1)| \quad (3.4)$$

Os tamanhos de  $\alpha$  e  $w$  estão apresentados na Tabela 1.

Tabela 1 – Parâmetros de Filtros Utilizados.

| Constantes                            | Valor |
|---------------------------------------|-------|
| Tamanho de janela de média móvel $tw$ | 15    |
| Média móvel valor de $\alpha$         | 1     |
| Tamanho janela Savitzky-Golay         | 51    |
| <i>Polyorder</i> Savitzky-Golay       | 3     |

O segundo filtro aplicado é o **filtro de Savitzky-Golay**, que utiliza um ajuste polinomial de grau  $d$  sobre uma janela deslizante de dados. O polinômio ajustado pode ser descrito por (3.5).

$$P_d(x) = a_0 + a_1x + a_2x^2 + \cdots + a_dx^d \quad (3.5)$$

Em (3.6), os coeficientes  $a_k$  do polinômio são determinados minimizando o erro quadrático entre os valores originais da série de dados, representados por  $x_{i+j}$ , e os valores estimados pelo polinômio no mesmo ponto,  $P_d(j)$ .  $m$  representa metade do tamanho da janela



deslizante, com o comprimento total dado por  $2n + 1$ , onde  $n$  é o número de elementos de cada lado do ponto central.

$$\min \sum_{j=-m}^m (x_{i+j} - P_d(j))^2 \quad (3.6)$$

Após o ajuste do polinômio, o valor filtrado no ponto central da janela, denominado  $y_i$ , é calculado como uma combinação linear dos valores dentro da janela deslizante através de (3.7). Nesta equação,  $c_j$  representa os coeficientes durante o ajuste do polinômio, determinando a contribuição de cada ponto  $x_{i+j}$ .

$$y_i = \sum_{j=-m}^m c_j x_{i+j} \quad (3.7)$$

### 3.0.2 Composição do Conjunto de Dados

Conforme apresentado em [Nenning \(2013\)](#), a curva característica da corrente na bobina apresenta 6 a 7 pontos que carregam informações de saúde importantes da bobina. Devido à presença de ruído, a identificação dos pontos de início e término utiliza um limite de tolerância, apresentado na Tabela 2. Quando a corrente ultrapassa esse limite, pode-se admitir que a manobra foi iniciada e, após o início, é monitorado o momento em que a corrente retorna a valores abaixo desse limite para determinar o final da manobra.

Tabela 2 – Parâmetros de Identificação de Pontos.

| Constantes                            | Valor                 |
|---------------------------------------|-----------------------|
| <i>offset</i> de Corrente de inicio   | 0,4 A                 |
| <i>offset</i> de Corrente de termino  | 0,2 A                 |
| <i>Prominence</i>                     | 1 A                   |
| Limite mínimo para média acumulativa  | $1 \times 10^{-11}$ A |
| Valor esperado da derivada do ponto 6 | -30 (A/ms)            |

Após filtrar o sinal, a técnica utilizada para identificar pontos de interesse avalia as características predominantes em cada ponto. O primeiro e o último ponto marcam o início e fim da manobra, caracterizados por corrente nula, ajustada por um valor de *offset* devido a ruídos.

O segundo e quarto pontos são os máximos e mínimos locais, identificados utilizando funções e bibliotecas em Python, ajustando a constante *prominence*, que se trata da altura de um pico em relação a sua vizinhança. O terceiro ponto é caracterizado por uma estabilização relativa da corrente, identificada utilizando a derivada do sinal de corrente e o filtro Savitzky-Golay em (3.5).

Após o quarto ponto, os sinais dos tipos de bobina diferenciam-se. Na abertura, a corrente cai imediatamente para zero após atingir o valor máximo. No fechamento, o pico é mantido

por um certo tempo, com a estabilização marcada como o quinto ponto, determinado pela variação da média cumulativa da corrente a partir do quarto ponto, apresentada na Tabela 2.

O penúltimo ponto, presente em ambos os sinais da bobina de abertura e da bobina de fechamento, mostra uma queda abrupta da corrente para zero, gerando uma variação negativa forte na derivada do sinal, identificada por um valor fixo esperado para a derivada nesse ponto.

Após a identificação dos pontos, foram nomeados para melhor interpretação nos dois casos, conforme a Figura 14 para a abertura.

### 3.0.3 Treinamento do Modelo Classificador


Foram realizados dois treinamentos de modelo, cada um direcionado a um tipo específico de disjuntor: HD4 e 3AP. Para isso, utilizaram-se amostras de sinais de corrente das bobinas, sendo 139 amostras provenientes de disjuntores do protótipo da UNIFEI (modelo HD4) e 39 amostras de disjuntores do laboratório de Furnas (modelo 3AP). Essas amostras foram categorizadas conforme apresentado na Tabela 3.

Tabela 3 – Quantidade de Amostras por Tipo de Sinal e Origem dos Disjuntores.


| Origem / Modelo             | Sinais de Fechamento | Sinais de Abertura |
|-----------------------------|----------------------|--------------------|
| Protótipo UNIFEI (HD4)      | 70                   | 69                 |
| Laboratório de Furnas (3AP) | 39                   | -                  |

Para cada uma das manobras, foram calculados o tempo e a área de cada intervalo de pontos, apresentados na Figura 14a e 14b, sendo estas características as entradas do sistema. Conforme a interpretação de [Nenning \(2013\)](#) e análises feitas por [Li et al. \(2015\)](#), [Rudsari, Razi-Kazemi e Shoorehdeli \(2019\)](#) e [Ruan et al. \(2022\)](#), o tempo e a área do sinal de corrente são influenciados pelas propriedades da bobina e condições de operação. Assim, ao analisar os intervalos, é possível compreender o comportamento e identificar possíveis falhas mecânicas e elétricas associadas aos valores dessas etapas. Para contextualizar os intervalos do sinal que servem de entrada do classificador, eles foram identificados como:

1. **Energização:** Representa o intervalo em que a corrente começa a se elevar na bobina enquanto a armadura está estática na posição inicial.
2. **Deslocamento:** Etapa que o início do movimento da armadura ocorre, reduzindo a corrente da bobina pela indução da força eletromotriz.
3. **Recuperação:** Momento após a colisão com o gatilho da mola desacelerando o movimento de armadura momentaneamente.
4. **Parada:** Representa o intervalo que a armadura, ao final do curso, fica estática novamente sem induzir força eletromotriz.



- (a) 6 pontos de interesse: (1) Ponto inicial; (2) Primeiro ponto máximo; (3) Ponto central; (4) Ponto mínimo; (5) Segundo ponto máximo; (6) Ponto Final.



- (b) 7 pontos de interesse: (1) Ponto inicial; (2) Primeiro ponto máximo; (3) Ponto central; (4) Ponto mínimo; (5) Ponto de saturação; (6) Segundo ponto máximo, (7) Ponto Final.

Figura 14 – Sinal de energização da bobina de abertura e bobina de fechamento pertencente ao protótipo na UNIFEI, resultante dos filtros e algoritmos aplicados para a localização dos pontos de interesse.

5. **Saturação:** Intervalo em que o sistema atrasa o corte de energização da bobina (apenas de fechamento).
6. **Desligamento:** Desenergização da bobina, proporcionando o retorno da armadura a sua posição inicial.

Baseando-se no método descrito por [Razi-Kazemi \(2015\)](#), foram utilizados a média ( $\mu_T$  para o tempo e  $\mu_A$  para a área) e o desvio padrão ( $\sigma_T$  para o tempo e  $\sigma_A$  para a área) dos intervalos analisados. Esses parâmetros foram calculados para estimar o padrão normal de operação da bobina, através de 3.8 e 3.9 respectivamente. Nas Tabelas 4 e 5, são apresen-

tados os valores obtidos dos intervalos do protótipo UNIFEI com disjuntores do modelo HD4, e na Tabela 6 são apresentados os valores obtidos dos intervalos do laboratório de Furnas com o disjuntor de modelo 3AP.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.8)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.9)$$

Tabela 4 – Média e Desvio Padrão de Tempo e Área dos Intervalos de Sinais de Manobras de Abertura do Protótipo UNIFEI.

| <b>Intervalo</b> | $\mu_T$ | $\sigma_T$   | $\mu_A$ | $\sigma_A$   |
|------------------|---------|--------------|---------|--------------|
| Energização      | 15.5632 | $\pm 0.5371$ | 50.0084 | $\pm 2.3046$ |
| Deslocamento     | 5.6767  | $\pm 0.0375$ | 23.766  | $\pm 0.4098$ |
| Recuperação      | 11.5082 | $\pm 0.7667$ | 44.3626 | $\pm 2.9223$ |
| Parada           | 16.5908 | $\pm 0.2997$ | 64.0867 | $\pm 1.3826$ |
| Desligamento     | 1.7287  | $\pm 0.3464$ | 2.7216  | $\pm 1.2036$ |

Tabela 5 – Média e Desvio Padrão de Tempo e Área dos Intervalos de Sinais de Manobras de Fechamento do Protótipo UNIFEI.

| <b>Intervalo</b> | $\mu_T$ | $\sigma_T$    | $\mu_A$  | $\sigma_A$     |
|------------------|---------|---------------|----------|----------------|
| Energização      | 11.5457 | $\pm 1.8393$  | 66.4178  | $\pm 13.169$   |
| Deslocamento     | 6.2787  | $\pm 0.7602$  | 42.6923  | $\pm 5.2543$   |
| Recuperação      | 6.4423  | $\pm 1.8494$  | 40.5732  | $\pm 12.6477$  |
| Parada           | 97.0631 | $\pm 8.1826$  | 807.1426 | $\pm 71.9644$  |
| Saturação        | 40.1505 | $\pm 12.1313$ | 353.5177 | $\pm 107.3561$ |
| Desligamento     | 0.6784  | $\pm 0.2256$  | 4.4162   | $\pm 1.0249$   |

Tabela 6 – Média e Desvio Padrão de Tempo e Área dos Intervalos de Sinais de Manobras de Fechamento do Laboratório de Furnas.

| <b>Intervalo</b> | $\mu_T$ | $\sigma_T$   | $\mu_A$ | $\sigma_A$   |
|------------------|---------|--------------|---------|--------------|
| Energização      | 15,7016 | $\pm 1,4241$ | 13,4975 | $\pm 0,9487$ |
| Deslocamento     | 4,1554  | $\pm 0,6212$ | 6,2864  | $\pm 0.9336$ |
| Recuperação      | 1,1092  | $\pm 0,1071$ | 1,426   | $\pm 0,1489$ |
| Parada           | 14,5492 | $\pm 0,2868$ | 25,1458 | $\pm 0,8113$ |
| Saturação        | 11,1471 | $\pm 0.6626$ | 20,2872 | $\pm 1,1313$ |
| Desligamento     | 4,3984  | $\pm 0.5798$ | 4,9743  | $\pm 1,0415$ |

Cada um dos 5 intervalos tem seu subsistema *fuzzy*, associando seu tempo e área em uma única saída, resultando em 5 índices de qualidade para cada intervalo. O diagrama de um desses subsistemas é representado na Figura 15.




Figura 15 – Diagrama dos sistemas *fuzzy* da primeira camada do módulo.

A média e desvio padrão foram utilizados para parametrizar a primeira camada do SIF. A camada de *fuzzificação* utilizou a distribuição normal (Gaussiana) e 2 funções sigmóides deslocadas para orientar as equações de pertinência de entrada, definidas buscando transições suaves entre regiões. A Gaussiana foi centralizada no valor da média, e as funções sigmóides deslocadas em 1,5 vezes o valor de desvio padrão. Para a janela do universo de valores de entrada foi usado 10 vezes o valor do sigma em relação à média, com o intuito de abranger eventuais *outliers*. Dessas 3 regiões formadas, foram definidas como: Inferior, Normal e Superior, conforme ilustrado pela Figura 16a.

As Funções de pertinência das *defuzzificações* da primeira camada, que representam o índice de cada intervalo, são arbitrariamente divididas em níveis Normal, Moderado e Grave, representados na Figura 16b. O formato e alcance dessas funções foram escolhidos e ajustados de acordo com o contexto dos dados de teste.


As bases de regras para os subsistemas *fuzzy* da primeira camada são iguais, utilizam inferência do tipo *Mandani* com intuito de se aproximar das decisões humanas, e são apresentadas na Tabela 7. Posteriormente, os resultados da primeira camada de subsistemas *fuzzy* servem de valores de entrada para a segunda camada, que terá apenas um sistema *fuzzy*.

Tabela 7 – Base de Regras dos Subsistemas *Fuzzy* da Primeira Camada.


| Área/Tempo  | T. Inferior | T. Normal | T. Superior |
|-------------|-------------|-----------|-------------|
| A. Inferior | Grave       | Moderado  | Grave       |
| A. Normal   | Moderado    | Normal    | Moderado    |
| A. Superior | Grave       | Moderado  | Grave       |

Sabendo que a análise individual de cada manobra possibilita o desvio de classificação por conta de ruídos e condições atípicas, foi elaborado o Fator de Recorrência. Este fator é uma forma de considerar a persistência de características anômalas dos índices anteriores, semelhante ao método de Vianna et al. (2017). Este fator avalia a qualidade das demais entradas do sistema no tempo de vida da bobina.

Se os resultados da *defuzzificação* dos intervalos ultrapassam o valor pré-determinado de 50%, essas ocorrências são registradas em um histórico. Posteriormente, na próxima



(a) Funções de pertinência de entrada; Inferior, Normal e Superior.



(b) Funções de pertinência de saída; Normal, Moderado e Grave.

Figura 16 – Funções de pertinência de entrada e saída dos subsistemas da primeira camada.


classificação por manobra, uma janela de amostra com recorrência mais recente é coletada e a soma dessas recorrências é considerada.

Isso significa que, para cada associação de tempo e área do intervalo, se algum resultado exceder o valor estipulado, será levado em conta para a avaliação futura da persistência das características observadas.


O Fator de Recorrência fornece à segunda camada de inferência um valor de entrada com 5 Funções de pertinência: Novo, Usado, Gasto, Antigo e Velho, apresentado na Figura 17b. Estas regiões determinam a idade do disjuntor, considerando a interpretação de que disjuntores mais antigos tendem a apresentar maiores anomalias, exigindo classificações mais criteriosas.

O diagrama apresentado na Figura 19 corresponde à segunda camada de inferência do sistema. Nele, são associados os índices de qualidade dos intervalos anteriores e o valor do Fator de Recorrência, resultando na classificação final do Grau de Risco da bobina.

Apresentadas na Figura 18, baseando-se no método de Vianna et al. (2017), as regiões de



(a) Funções de pertinência da entrada do sistema; Normal, Moderado e Grave.



(b) Funções de pertinência da entrada do fator de recorrência; Novo, Usado, Gasto, Antigo e Velho.

Figura 17 – Funções de pertinência de entrada da recorrência e saída de classificação final.




Figura 18 – Funções de pertinência de saída do sistema principal; Confiável, Observação, Cuidado, Aviso e Risco.

saída foram classificadas em cinco categorias principais: Confiável, Observação, Cuidado, Aviso e Risco.




Figura 19 – Diagrama *fuzzy* da segunda camada do módulo da bobina de abertura, caracterizada por apenas 5 intervalos.

A base de regras empregada nesta camada é do tipo *Mandani*. Cada região de saída é ativada com base na quantidade de entradas nos níveis Normal, Moderada ou Grave, representados respectivamente pelas siglas N, M e G, conforme mostrado na Tabela 8. Essa configuração confere uma independência em quais intervalos destes três níveis, focando apenas na quantidade de classificações em cada região de saída. Por exemplo, para ativar a região Confiável, é necessário que todos os intervalos sejam classificados como Normal (5 para bobina de abertura e 6 para bobina de fechamento).

O sistema completo do módulo classificado de um bobina de abertura se encontra na Figura 20, evidenciando as duas etapas de SIF, primeira e segunda camada.




Figura 20 – Diagrama *fuzzy* completo do módulo da bobina de abertura, caracterizada por apenas 5 intervalos.



Tabela 8 – Número de Combinações de Entrada para Regras da Segunda Camada.

| Região ativada | Abertura |   |   | Fechamento |   |   |
|----------------|----------|---|---|------------|---|---|
|                | N        | M | G | N          | M | G |
| Confiável      | 5        | 0 | 0 | 6          | 0 | 0 |
| Confiável      | 4        | 1 | 0 | 5          | 1 | 0 |
| Confiável      | 3        | 2 | 0 | 4          | 2 | 0 |
| Observação     | 2        | 3 | 0 | 3          | 3 | 0 |
| Observação     | 1        | 4 | 0 | 2          | 4 | 0 |
| Cuidado        | 0        | 4 | 0 | 1          | 5 | 0 |
| Cuidado        | 0        | 5 | 0 | 0          | 6 | 0 |
| Cuidado        | 0        | 4 | 0 | 0          | 5 | 1 |
| Aviso          | 0        | 4 | 1 | 0          | 4 | 2 |
| Aviso          | 0        | 3 | 2 | 0          | 3 | 3 |
| Risco          | 0        | 2 | 3 | 0          | 2 | 4 |
| Risco          | 0        | 1 | 4 | 0          | 1 | 5 |
| Risco          | 0        | 0 | 5 | 0          | 0 | 6 |

### 3.0.4 Testes e Validações

Os testes iniciais foram realizados com o modelo de classificador para disjuntores HD4, com o protótipo desenvolvido na UNIFEI, averiguando o comportamento das amostras de parametrização, ao mesmo tempo permitindo a observação do comportamento de classificação, para este disjuntor considerado novo e em operação normal. Posteriormente, o modelo de classificador para disjuntores 3AP, configurado com dados do laboratório de Furnas, foi aplicado aos sinais das três fases do disjuntor de Tijuco Preto de mesmo tipo de disjuntor.


Cada estudo analisado apresenta sinais em diferentes escalas e valores nominais, mostrando que o comportamento e os valores de falha dependem do modelo do disjuntor e de sua bobina. Portanto, ajustes de amplitude foram realizados em cada modelo *fuzzy* treinado para garantir a mesma escala das dimensões do sinal.

Outra abordagem foi realizada ao gerar sinais simulados baseados no protótipo UNIFEI, dessa vez incluindo oscilações anômalas que abrangem atrasos e adiantamentos de tempo, bem como atenuações e amplificações, uma vez que não há diferentes disjuntores deste mesmo modelo. Essas oscilações são baseadas nas condições de falhas mecânicas e elétricas apresentadas por [Nenning \(2013\)](#), [Li et al. \(2015\)](#), [Rudsari, Razi-Kazemi e Shoorehdeli \(2019\)](#), [Ruan et al. \(2022\)](#), proporcionando à simulação uma proximidade a casos factíveis para o modelo de disjuntor HD4.

## 4 Resultados

Nesta seção, são apresentados e analisados os resultados obtidos com a aplicação do método baseado em inferência *fuzzy* desenvolvido neste trabalho. Os testes foram realizados a partir de diferentes bases de dados, abrangendo manobras registradas no protótipo da UNIFEI com disjuntores HD4, sinais simulados em cenários de falha, e registros reais de manobras oriundas do laboratório de Furnas e da subestação de Tijuco Preto, que utilizam disjuntores do modelo 3AP.

Os primeiros experimentos utilizaram o conjunto amostrado do protótipo para classificar cada manobra de forma individual, visando entender o comportamento do disjuntor e a variação instantânea de classificação. A análise gráfica apresentada nas Figuras 21(a) e (b) para disjuntores HD4, assim como nas Figuras 22(a) e (b), permitiu a identificação da tendência das classificações sem o Fator de Recorrência, através de uma regressão linear, para as classificações da bobina de abertura e da bobina de fechamento.



(a) Classificações de 69 manobras da bobina de abertura.



(b) Classificações de 70 manobras da bobina de fechamento.

Figura 21 – Classificação das manobras de forma individual para disjuntores HD4.




Figura 22 – Classificação das manobras da bobina de fechamento de Furnas de forma individual para disjuntores 3AP.

As classificações anômalas observadas nas manobras podem ser justificadas a partir da análise da dispersão de entrada dos intervalos. Especialmente as mais elevadas do sinal de bobina de abertura do modelo 3AP, destacadas na Tabela 9 são ilustradas na Figura 23. No caso do sinal de bobina de fechamento, essa análise não revelou informações relevantes. Ao examinar os dados dessas manobras, nota-se que seus pontos se afastam significativamente da média nos intervalos 1 (Energização) e 3 (Recuperação). Essa variação é atribuída tanto às flutuações naturais nos sinais medidos quanto à presença de ruídos intrínsecos que não foram totalmente eliminados pelos métodos de tratamento de dados discutidos na Seção 3.1.

Tabela 9 – Classificações Anômalas do Sinal de bobina de abertura do Disjuntor HD4.

| Nº das Manobras | Grau de Risco |
|-----------------|---------------|
| 20              | 6,0385%       |
| 46              | 1,4193%       |
| 51              | 1,4193%       |
| 52              | 10,8165%      |

Ao utilizar o Fator de Recorrência, o grau de classificação do conjunto aumenta conforme o tempo. Para bobinas do disjuntor HD4 do protótipo UNIFEI, como mostrado na Figura 24, tal comportamento é evidenciado pela elevação das classificações finais de bobina de abertura e iniciais de bobina de fechamento, identificada pela curva vermelha. Neste cenário, a análise dos testes de classificação se encontra na Tabela 10.

Tabela 10 – Classificações do Protótipo UNIFEI com Recorrência.

| Dado                  | Abertura       | Fechamento     |
|-----------------------|----------------|----------------|
| <b>Melhor Caso</b>    | 0,69%          | 0,00%          |
| <b>Pior Caso</b>      | 11,9%          | 3,00%          |
| <b>Região Predom.</b> | Confiável (69) | Confiável (70) |




Figura 23 – Dispersão de entrada do sistema *fuzzy*, provenientes do conjunto de sinais das manobras de abertura do disjuntor, apresentando a relação Tempo x Área dos intervalos, evidenciando valores anômalos provenientes das 4 maiores classificações de manobra, manobras 20, 46, 51 e 52.


Para bobinas do disjuntor 3AP do laboratório, 39 manobras, como mostrado na Figura 25, o Fator de Recorrência também é evidenciado pela elevação das últimas classificações identificadas pela curva vermelha. Neste cenário, a análise dos testes de classificação se encontra na Tabela 11.

Tabela 11 – Classificações do Laboratório de Furnas com Recorrência


| Dado           | Fechamento     |
|----------------|----------------|
| Melhor Caso    | 0,00%          |
| Pior Caso      | 3,00%          |
| Região Predom. | Confiável (39) |

Como apresentado por [Nenning \(2013\)](#), [Li et al. \(2015\)](#), [Rudsari, Razi-Kazemi e Shoorehdeli \(2019\)](#) e [Ruan et al. \(2022\)](#), a identificação dos indícios de falhas mecânicas e elétricas acontece pela modificação dos sinais de corrente, ou seja, o atraso/adiantamento do tempo e a atenuação/amplificação do sinal nominal. Essas variações nos eixos de tempo e amplitude da corrente resultam em 4 cenários de combinações possíveis, e podem ser visualizados na Figura 26

Com o objetivo de avaliar o desempenho do módulo de classificação aplicado aos disjuntores HD4, foram gerados sinais artificiais distintos daqueles utilizados na etapa de parametrização. Esses sinais foram obtidos por meio da aplicação aleatória de desvios nas seis coordenadas dos pontos de abertura e fechamento — incluindo atraso ou adiantamento no tempo, bem como atenuação ou amplificação da amplitude do sinal. Para as simulações do tipo da bobina de abertura, foram realizadas 4096 combinações possíveis; já para o tipo da bobina de fechamento, esse número chegou a 16.384 combinações. As classificações geradas, tanto de forma instantânea quanto com o uso do Fator de Recorrência,



(a) Cálculo de recorrência com manobras da bobina de abertura.



(b) Cálculo de recorrência com manobras da bobina de fechamento.

Figura 24 – Classificação de manobras com o uso do Fator de Recorrência, influenciando as classificações futuras.

utilizando o módulo calibrado com dados do protótipo da UNIFEI, estão apresentadas nas Tabelas 12 e 13, respectivamente.

Tabela 12 – 4096 Simulações de bobina de abertura Para Disjuntores HD4.

| Dado           | Sem Recorrência | Com Recorrência |
|----------------|-----------------|-----------------|
| Melhor Caso    | 0,71%           | 20,9%           |
| Pior Caso      | 53,3%           | 98,05%          |
| Média          | 34,57%          | 87,96%          |
| Desvio Padrão  | 22,97%          | 8,95%           |
| Região Predom. | Cuidado (4927)  | Risco (6847)    |

Após a calibração de um modelo para disjuntores 3AP, uma série de acionamentos foram





Figura 25 – Classificação de manobras de bobina de fechamento com o uso do Fator de Recorrência, influenciando as classificações futuras.

Tabela 13 – 16384 Simulações de bobina de fechamento Para Disjuntores HD4.


| Dado           | Sem Recorrência   | Com Recorrência |
|----------------|-------------------|-----------------|
| Melhor Caso    | 1,18%             | 2,38%           |
| Pior Caso      | 56,57%            | 98,88%          |
| Média          | 17,87%            | 79,21%          |
| Desvio Padrão  | 21,31%            | 20,25%          |
| Região Predom. | Confiável (13315) | Risco (13797)   |

realizados em Tijuco Preto, obtendo 11 sinais de bobina de fechamento registrados de cada fase, A, B e C. A partir disso, o classificador determinou o Grau de Risco utilizando o Fator de Recorrência. Ao observar atentamente os resultados apresentados nas Figuras 27, 28 e 29 é possível compreender o comportamento da evolução do Grau de Risco ao longo do tempo nas classificações da bobina de fechamento. Mesmo com a presença pontual de picos anômalos, os valores do Grau de Risco calculado permanecem, em sua maioria, baixos. Embora o número de amostras analisadas seja inferior à janela utilizada para a soma do Fator de Recorrência, classificações altas dos intervalos ainda proporcionam um crescimento das futuras classificações, mesmo que suaves. Após a vigésima amostra, espera-se que, na ausência de novas classificações anômalas, as anteriores sejam descartadas da soma de recorrência. Com isso, tem-se a possibilidade de que o Grau de Risco resultante seja gradualmente reduzido.

A Tabela 14 apresenta os principais parâmetros das classificações do Grau de Risco obtidas para cada bobina da subestação de Tijuco Preto. Ao confrontar esses dados com as análises descritas anteriormente, percebe-se uma forte semelhança entre os resultados obtidos. A maior parte das classificações se concentra na mesma região de risco — a categoria “Confiável” — e, em diversos casos, os valores são idênticos entre bobinas. Essa semelhança pode ser explicada pela ativação de um número similar de regras durante os processos de



(a) 4 sinais das simulações da bobina de abertura representando as dispersões máximas em cada eixo em relação ao sinal normal do protótipo.



(b) 4 sinais das simulações da bobina de fechamento representando as dispersões máximas em cada eixo em relação ao sinal normal do protótipo.

Figura 26 – Simulações de pontos em cenários de falha.

inferência *fuzzy* e *defuzzificação*.

Tabela 14 – Classificações de bobina de fechamento das fases de Tijuco Preto.

| Dado           | Fase A        | Fase B        | Fase C        |
|----------------|---------------|---------------|---------------|
| Melhor Caso    | 3,1%          | 8,68%         | 3,1%          |
| Pior Caso      | 62,28%        | 62,28%        | 62,28%        |
| Região Predom. | Confiável (9) | Confiável (8) | Confiável (9) |




Figura 27 – Sinais da bobina de fechamento de Tijuco Preto, fase A.




Figura 28 – Sinais da bobina de fechamento de Tijuco Preto, fase B




Figura 29 – Sinais da bobina de fechamento de Tijuco Preto, fase C.



## 5 Conclusão

A avaliação instantânea de equipamentos elétricos é essencial para prevenir interrupções na rede. O modelo de classificação apresentado neste artigo utiliza um Sistema de Inferência Fuzzy para avaliar o estado de disjuntores SF6, analisando de forma probabilística e comportamental os sinais de bobina de abertura e fechamento. O método demonstrou-se promissor ao associar de 10 a 12 características dos intervalos dos sinais, além de oferecer uma variável linguística que facilita a interpretação humana. A metodologia proposta simplifica a detecção de anomalias nos sinais de corrente das bobinas de disjuntores SF6, promovendo a disseminação da manutenção preditiva.

Os resultados obtidos com as classificações apresentaram um comportamento crescente e decrescente conforme esperado, distribuindo-se por toda a faixa de saída. Valores baixos foram observados predominantemente no início, enquanto classificações médias e altas mostraram distanciamentos do valor padrão predominantemente do meio até o final do conjunto de amostras. Essa variação ocorre à medida que o Fator de Recorrência se acumula ou se reduz no histórico de recorrência.

A inexistência de registro de sinais de manobras de disjuntores de modelos semelhantes ao do protótipo UNIFEI, somado ao número reduzido de amostras das coletas das fases de Tijuco Preto (11), impossibilitou a observação do modelo a longo prazo. Para disjuntores usados, ou próximos ao fim do seu ciclo de vida, espera-se um maior número de registros e intervalos mais espaçados, permitindo que o Grau de Risco das classificações aumente, mesmo com a influência negativa do Fator de Recorrência sobre as classificações instantâneas.

Devido à diferença no número de amostras entre os disjuntores do protótipo HD4 da UNIFEI, do laboratório de Furnas e da subestação de Tijuco Preto, o método aplicado aos dados do HD4 permitiu uma exploração mais eficaz da flutuação do Grau de Risco na saída do SIF. Os modelos do HD4 apresentaram variações entre 0,69% e 11,9% para os sinais da bobina de abertura, e entre 0% e 3% para os sinais da bobina de fechamento, evidenciando uma distribuição mais refinada dos resultados, conforme observado na Figura 24. Por outro lado, os modelos AP3 aplicados aos disjuntores de Tijuco Preto revelaram classificações de maior magnitude, porém com menor diversidade, concentrando-se entre 3,1% e 62,8% nas fases A, B e C, marcados por picos abruptos de classificação, indicando comportamento menos estável para a janela pequena amostrada, conforme evidenciado nas Figuras 27, 28 e 29. A semelhança entre os valores máximos e mínimos do Grau de Risco nas diferentes fases é atribuída ao método de inferência e ao processo de *defuzzificação* adotado, que tende a uniformizar as respostas em cenários com menor variabilidade de entrada.

Com base nas observações realizadas durante o processo de classificação dos modelos, observou-se que a especialização do Fator de Recorrência por intervalo pode contribuir significativamente para o aprimoramento da exatidão do sistema, ao permitir uma avaliação mais refinada da persistência de anomalias em cada etapa da manobra. No entanto, essa abordagem implicaria em um aumento considerável da complexidade estrutural do sistema, possivelmente exigindo a implementação de camadas adicionais de inferência *fuzzy*.

A análise dos sinais de falha pode não se mostrar eficaz para configurar o sistema conforme esperado, visto que, uma vez que a falha já ocorreu, o método proposto deixa de ser necessário. Isso acontece porque o modelo deste artigo busca prever o estado da bobina, analisando dados anteriores. Devido à possível discrepância entre os dados registrados antes da falha e os dados coletados no momento da ocorrência, um modelo calibrado com sinais de falha pode resultar em um cenário onde não haja significativa evolução no Grau de Risco entre valores ótimos e aqueles próximos a falhas.

Futuras investigações podem se concentrar na ampliação do número de amostras de corrente de disjuntores em ambientes controlados, como laboratórios, bem como na incorporação de sinais provenientes de cenários mais ruidosos e imprevisíveis, como instalações em campo. Essa diversificação contribuiria para aumentar a robustez do modelo e permitiria uma revisão mais precisa das regiões de pertinência nas etapas do SIF, ajustando-as de forma mais fiel ao comportamento real das bobinas analisadas.

Embora o método proposto tenha sido desenvolvido com foco em um único componente, ele abre caminho para aplicações em sistemas mais complexos. Ao ser complementado por outras grandezas e variáveis operacionais — como temperatura interna, tensão de alimentação, vibração, tempo de operação, tempo de atuação e deslocamento de contatos — a integração do modelo pode resultar em classificações mais precisas e confiáveis do estado dos equipamentos elétricos.

# Referências

- BENMOUYAL NORMANN FISCHER, D. T. M. T.-W. G.; CHOWDHURY, R. A unified approach to controlled switching of power equipment. p. 17, maio 2018. Disponível em: <[https://cdn.selinc.com/assets/Literature/Publications/Technical%20Papers/6810\\_AUnifiedApproach\\_GB\\_20170907\\_Web2.pdf?v=20180502-225723](https://cdn.selinc.com/assets/Literature/Publications/Technical%20Papers/6810_AUnifiedApproach_GB_20170907_Web2.pdf?v=20180502-225723)>.
- CHEN, Z. et al. Real-time transient stability status prediction using cost-sensitive extreme learning machine. **Neural Computing and Applications**, Springer Science and Business Media LLC, v. 27, n. 2, p. 321–331, abr. 2015. ISSN 1433-3058. Disponível em: <<http://dx.doi.org/10.1007/s00521-015-1909-9>>.
- JACOBSON, M. Z. et al. Low-cost solution to the grid reliability problem with 100**Proceedings of the National Academy of Sciences**, Proceedings of the National Academy of Sciences, v. 112, n. 49, p. 15060–15065, nov. 2015. ISSN 1091-6490. Disponível em: <<http://dx.doi.org/10.1073/pnas.1510028112>>.
- KAUSHAL, J.; BASAK, P. Power quality control based on voltage sag/swell, unbalancing, frequency, thd and power factor using artificial neural network in pv integrated ac microgrid. **Sustainable Energy, Grids and Networks**, Elsevier BV, v. 23, p. 100365, set. 2020. ISSN 2352-4677. Disponível em: <<http://dx.doi.org/10.1016/j.segan.2020.100365>>.
- LEI, Y. et al. Applications of machine learning to machine fault diagnosis: A review and roadmap. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 138, p. 106587, abr. 2020. ISSN 0888-3270. Disponível em: <<http://dx.doi.org/10.1016/j.ymssp.2019.106587>>.
- LI, H. et al. Support vector machine based fault diagnosis using trip and close coil current of circuit breakers. In: **TENCON 2015 - 2015 IEEE Region 10 Conference**. IEEE, 2015. p. 1–5. Disponível em: <<http://dx.doi.org/10.1109/TENCON.2015.7372772>>.
- LIU, Q. et al. Research on circuit breaker operating mechanism fault diagnosis method combining global-local feature extraction and kelm. **Sensors**, MDPI AG, v. 24, n. 1, p. 124, dez. 2023. ISSN 1424-8220. Disponível em: <<http://dx.doi.org/10.3390/s24010124>>.
- MAMDANI. Application of fuzzy logic to approximate reasoning using linguistic synthesis. **IEEE Transactions on Computers**, Institute of Electrical and Electronics Engineers (IEEE), C-26, n. 12, p. 1182–1191, dez. 1977. ISSN 0018-9340. Disponível em: <<http://dx.doi.org/10.1109/TC.1977.1674779>>.
- MEDINA, R. et al. A fuzzy inference-based approach for estimating power transformers risk index. **Electric Power Systems Research**, v. 209, p. 108004, 08 2022.
- NENNING, A. **Interpreting the results of circuit breaker analysis**. 2013. OMICRON Paper of the Month, Klaus, Austria. (Acesso em: 22 fev. 2025). Disponível em: <<https://studylib.net/doc/18787132>>.
- RAZI-KAZEMI, A. Circuit breaker condition assessment through a fuzzy-probabilistic analysis of actuating coil's current. **IET Generation, Transmission Distribution**, v. 10, 10 2015.

- RAZI-KAZEMI, A. A.; NIAYESH, K. Condition monitoring of high voltage circuit breakers: Past to future. **IEEE Transactions on Power Delivery**, Institute of Electrical and Electronics Engineers (IEEE), v. 36, n. 2, p. 740–750, abr. 2021. ISSN 1937-4208. Disponível em: <<http://dx.doi.org/10.1109/TPWRD.2020.2991234>>.
- RUAN, J. et al. Fault identification of high voltage circuit breaker trip mechanism based on psr and svm. **IET Generation, Transmission and Distribution**, Institution of Engineering and Technology (IET), v. 17, n. 6, p. 1179–1189, dez. 2022. ISSN 1751-8695. Disponível em: <<http://dx.doi.org/10.1049/gtd2.12725>>.
- RUDDSARI, F. N.; RAZI-KAZEMI, A. A.; SHOOREHDELI, M. A. Fault analysis of high-voltage circuit breakers based on coil current and contact travel waveforms through modified svm classifier. **IEEE Transactions on Power Delivery**, v. 34, n. 4, p. 1608–1618, 2019.
- SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, American Chemical Society (ACS), v. 36, n. 8, p. 1627–1639, jul. 1964. ISSN 1520-6882. Disponível em: <<http://dx.doi.org/10.1021/ac60214a047>>.
- SHAFIULLAH, M.; AHMED, S. D.; AL-SULAIMAN, F. A. Grid integration challenges and solution strategies for solar pv systems: A review. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 10, p. 52233–52257, 2022. ISSN 2169-3536. Disponível em: <<http://dx.doi.org/10.1109/ACCESS.2022.3174555>>.
- SUGENO, M.; KANG, G. Fuzzy modelling and control of multilayer incinerator. **Fuzzy Sets and Systems**, Elsevier BV, v. 18, n. 3, p. 329–345, abr. 1986. ISSN 0165-0114. Disponível em: <[http://dx.doi.org/10.1016/0165-0114\(86\)90010-2](http://dx.doi.org/10.1016/0165-0114(86)90010-2)>.
- VIANNA, E. et al. Substations sf6 circuit breakers: Reliability evaluation based on equipment condition. **Electric Power Systems Research**, v. 142, p. 36–46, 01 2017.
- WANG, Y. et al. Few-shot transfer learning with attention mechanism for high-voltage circuit breaker fault diagnosis. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 58, n. 3, p. 3353–3360, maio 2022. ISSN 1939-9367. Disponível em: <<http://dx.doi.org/10.1109/TIA.2022.3159617>>.
- ZADEH, L. Fuzzy sets as a basis for a theory of possibility. **Fuzzy Sets and Systems**, Elsevier BV, v. 100, p. 9–34, jan. 1999. ISSN 0165-0114. Disponível em: <[http://dx.doi.org/10.1016/S0165-0114\(99\)80004-9](http://dx.doi.org/10.1016/S0165-0114(99)80004-9)>.
- ŽARKOVIĆ, M.; STOJKOVIĆ, Z. Artificial intelligence sf6 circuit breaker health assessment. **Electric Power Systems Research**, v. 175, p. 105912, 2019. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779619302317>>.