



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

DAVI DA SILVA CARVALHO

**METODOLOGIA PARA DIAGNÓSTICO EM SISTEMAS ELÉTRICOS DE
POTÊNCIA BASEADA EM APRENDIZADO DE MÁQUINA E SISTEMAS
*FUZZY***

Recife

2024

DAVI DA SILVA CARVALHO

**METODOLOGIA PARA DIAGNÓSTICO EM SISTEMAS ELÉTRICOS DE
POTÊNCIA BASEADA EM APRENDIZADO DE MÁQUINA E SISTEMAS
*FUZZY***

Trabalho apresentado ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática (CIn) da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Área de Concentração: Inteligência Computacional

Orientador (a): Paulo Salgado Gomes de Mattos Neto

Coorientador (a): Eraylson Galdino da Silva

Recife

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Carvalho, Davi da Silva.

Metodologia para diagnóstico em sistemas elétricos de potência baseada em aprendizado de máquina e sistemas Fuzzy / Davi da Silva Carvalho. - Recife, 2024.

110f.: il.

Universidade Federal de Pernambuco, Centro de informática, Programa de Pós-Graduação em Ciência da Computação, 2024.

Orientação: Paulo Salgado Gomes de Mattos Neto.

Coorientação: Eraylson Galdino da Silva.

Inclui referências e apêndice.

1. Sistemas elétricos de potência; 2. Aprendizado de máquina; 3. Árvores de decisão; 4. Sistemas fuzzy; 5. Geração automática de regras fuzzy. I. Neto, Paulo Salgado Gomes de Mattos. II. Silva, Eraylson Galdino da. III. Título.

UFPE-Biblioteca Central

Davi da Silva Carvalho

“METODOLOGIA PARA DIAGNÓSTICO EM SISTEMAS ELÉTRICOS DE POTÊNCIA BASEADA EM APRENDIZADO DE MÁQUINA E SISTEMAS FUZZY”

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação. Área de Concentração: Inteligência Computacional.

Aprovado em: 26/06/2024.

BANCA EXAMINADORA

Prof. Dr. Andson Marreiros Balieiro
Centro de Informática / UFPE

Prof. Dr. João Fausto Lorenzato de Oliveira
Departamento de Engenharia Química / UFCG

Prof. Dr. Paulo Salgado Gomes de Mattos Neto
Centro de Informática / UFPE
(orientador)

Dedico este Mestrado aos meus pais, Demetrios e Maria Lúcia, minha avó, Marta, ao meu irmão, Lucas, e às minhas irmãs, Juliette, Luciana e Cristina.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, por me dar força, saúde e sabedoria para superar todos os desafios ao longo desta jornada.

Aos meus pais, Demétrios Andrade Carvalho e Maria Lucia da Silva Carvalho, pelo amor incondicional, apoio constante e por sempre acreditarem em meu potencial. Aos meus irmãos, por estarem ao meu lado em todos os momentos e aos meus amigos, pelo suporte e companheirismo durante essa caminhada.

Expresso minha profunda gratidão ao meu orientador, Prof. Paulo Salgado Gomes de Mattos Neto, por sua orientação, paciência e ensinamentos que foram fundamentais para a realização deste trabalho. Ao meu coorientador, Prof. Eraylson Galdino da Silva, pela valiosa contribuição, dedicação e incentivo.

Aos professores do Centro de Informática da UFPE, que contribuíram significativamente para minha formação acadêmica e profissional. Agradeço também à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo apoio financeiro indispensável para a concretização deste projeto.

Ao Programa de Pesquisa, Desenvolvimento e Inovação da Agência Nacional de Energia Elétrica (PD&I ANEEL) e à EVOLTZ, pela oportunidade de participar de um projeto de pesquisa enriquecedor e pela confiança depositada em meu trabalho.

A todos, meu sincero agradecimento.

“Por vezes sentimos que aquilo que fazemos não é senão uma gota de água no mar. Mas o mar seria menor se lhe faltasse uma gota.”

Madre Teresa de Calcutá

RESUMO

Os sistemas elétricos, embora operem majoritariamente em condições normais, estão sujeitos a falhas que podem comprometer a confiabilidade e a continuidade do fornecimento de energia. Nesse contexto, o desenvolvimento de soluções que permitam a detecção e classificação de falhas de forma rápida e precisa é essencial. Entre as técnicas mais promissoras está a lógica *fuzzy*, que apresenta grande potencial para modelar incertezas nos sistemas de potência. No entanto, uma das principais limitações dessa abordagem está na complexidade da configuração adequada das regras *fuzzy*, o que pode impactar a precisão dos resultados. Esta dissertação propõe uma metodologia baseada em aprendizado de máquina e lógica *fuzzy*, fazendo uso de árvores de decisão para a geração automática das regras *fuzzy*, eliminando a necessidade de configuração manual e aumentando a adaptabilidade do sistema. O objetivo é aprimorar a eficiência na detecção e classificação de falhas em sistemas de potência. A metodologia foi testada em um conjunto de dados público, e seu desempenho foi avaliado com base em critérios como acurácia, precisão e tempo computacional. Os resultados mostraram que o sistema alcançou uma acurácia de 87%, com um tempo médio de processamento de 38,5 segundos para a geração das regras *fuzzy*. Esses resultados ressaltam o potencial da abordagem em aprimorar a confiabilidade e a robustez dos sistemas elétricos, reduzindo os impactos decorrentes de falhas e interrupções.

Palavras-chaves: sistemas elétricos de potência, aprendizado de máquina, árvores de decisão, lógica *fuzzy*, sistemas *fuzzy*, geração automática de regras *fuzzy*.

ABSTRACT

Electrical systems, although they operate predominantly under normal conditions, are subject to failures that can compromise the reliability and continuity of power supply. In this context, the development of solutions that enable fast and accurate fault detection and classification is essential. Among the most promising techniques is fuzzy logic, which presents great potential for modeling uncertainties in power systems. However, one of the main limitations of this approach lies in the complexity of properly configuring fuzzy rules, which can impact the accuracy of the results. This dissertation proposes a methodology based on machine learning and fuzzy logic, making use of decision trees for the automatic generation of fuzzy rules, eliminating the need for manual configuration and increasing the adaptability of the system. The objective is to enhance the efficiency of fault detection and classification in power systems. The methodology was tested on a publicly available dataset, and its performance was evaluated based on criteria such as accuracy, precision, and computational time. The results indicate that the system achieved an accuracy of 87%, with an average processing time of 38.5 seconds for generating the fuzzy rules. These results highlight the potential of the approach in improving the reliability and robustness of electrical systems, reducing the impacts caused by failures and interruptions.

Keywords: power systems, machine learning, decision trees, *fuzzy* logic, *fuzzy* systems, automatic *fuzzy* rule generation.

LISTA DE FIGURAS

Figura 1 – Subsistemas do sistema elétrico de potência	24
Figura 2 – Diagrama unifilar de um sistema elétrico de potência	25
Figura 3 – Tipos de curto-circuito	27
Figura 4 – Universo do discurso.	39
Figura 5 – Função triangular.	41
Figura 6 – Função trapezoidal	42
Figura 7 – Função gaussiana.	43
Figura 8 – Função sigmoide.	44
Figura 9 – Etapas de um sistema <i>fuzzy</i>	52
Figura 10 – Método de inferência com duas regras.	53
Figura 11 – Visão geral da metodologia.	57
Figura 12 – Árvore de decisão.	58
Figura 13 – Processo de conversão de variáveis e limiares <i>fuzzy</i>	62
Figura 14 – Exemplo de variável crisp e seus limites.	62
Figura 15 – Exemplo de variável fuzzyficada.	63
Figura 16 – Base de variáveis.	64
Figura 17 – Tela de visualização de gráficos da variável.	65
Figura 18 – Processo de conversão de regras <i>fuzzy</i>	66
Figura 19 – Visualização de base geral de regras.	67
Figura 20 – Primeira parte do antecedente da regra.	68
Figura 21 – Segunda parte do antecedente da regra.	69
Figura 22 – Consequente da regra.	70
Figura 23 – Base de regras completa.	71
Figura 24 – Processo de inferência <i>fuzzy</i>	71
Figura 25 – Visualização do módulo de Sistemas <i>Fuzzy</i>	72
Figura 26 – Sistema simulado no MATLAB.	75
Figura 27 – Frequência das falhas.	79
Figura 28 – Distribuição de corrente por classe de falha.	80
Figura 29 – Distribuição de tensão por classe de falha.	81

Figura 30 – Matriz de confusão obtida através das classificações da árvore de Decisão no conjunto de teste.	87
Figura 31 – Matriz de confusão obtida através das classificações do XGBoost no conjunto de teste.	87
Figura 32 – Matriz de confusão obtida através das classificações do LightGBM no conjunto de teste.	88
Figura 33 – Matriz de confusão obtida através das classificações do CatBoost no conjunto de teste.	88
Figura 34 – Variável “Ia” modelada.	93
Figura 35 – Variável “Ib” modelada.	93
Figura 36 – Variável “Ic” modelada.	93
Figura 37 – Modelagem das variáveis de Corrente.	93
Figura 38 – Variável “Va” modelada.	94
Figura 39 – Variável “Vb” modelada.	94
Figura 40 – Variável “Vc” modelada.	94
Figura 41 – Modelagem das variáveis de Tensão.	94
Figura 42 – Variável consequente “Classe” modelada.	95

LISTA DE TABELAS

Tabela 1 – Artigos, algoritmos, métricas e inputs utilizados.	36
Tabela 2 – Limiares desordenados.	60
Tabela 3 – Limiares ordenados.	60
Tabela 4 – Amostra do conjunto de dados simulado.	76
Tabela 5 – Identificação das classes de falha com base na sequência de valores cate- góricos.	77
Tabela 6 – Adição da coluna de classes de falhas.	77
Tabela 7 – Estatísticas descritivas das variáveis.	78
Tabela 8 – Métricas para avaliar a classificação.	82
Tabela 9 – Parâmetros utilizados pelos modelos da literatura avaliados nos experimentos.	83
Tabela 10 – Resultados das métricas para os modelos em cada classe.	84
Tabela 11 – Número de regras por classe.	89
Tabela 12 – Variáveis <i>fuzzy</i> e universo do discurso.	91
Tabela 13 – Limiares por variável ordenados.	92
Tabela 14 – Resultados dos Métodos de defuzzificação.	96

LISTA DE ABREVIATURAS E SIGLAS

BA	Bissetriz da Área
CEN	Centroide
MATLAB	Matrix Laboratory
MDM	Média dos máximos
MVS	Máquina de Vetores de Suporte
PDM	Primeiro dos Máximos
RNAs	Redes Neurais Artificiais
SEP	Sistemas Elétricos de Potência
TW	Transformada de Wavelet
UDM	Último dos Máximos

LISTA DE SÍMBOLOS

π	Número pi
\cup	União
\cap	Intersecção
μ	Função de Pertinência
\subseteq	Subconjunto
U	Conjunto Universo
\emptyset	Conjunto vazio
\in	Pertence ao conjunto
\notin	Não pertence ao conjunto
:	Tal que
\exists	Existe
\forall	Para todo
$=$	Operador de igualdade
\neq	Operador de desigualdade
\wedge	Operador lógico “e”
\vee	Operador lógico “ou”

SUMÁRIO

1	INTRODUÇÃO	18
1.1	MOTIVAÇÃO	18
1.2	OBJETIVOS	21
1.3	QUESTÕES DA PESQUISA	22
1.4	ORGANIZAÇÃO DA TESE	22
2	CONCEITOS E TÉCNICAS	23
2.1	SISTEMAS ELÉTRICOS DE POTÊNCIA	23
2.1.1	subestações de energia elétrica - conceito e classificação	24
2.1.2	Falhas em sistemas de potência	26
2.1.3	Sistema de proteção	27
2.1.4	Automação dos sistemas de potência	28
2.2	TÉCNICAS UTILIZADAS NA LITERATURA	29
2.2.1	Transformadas de <i>Wavelet</i>	29
2.2.2	Redes Neurais Artificiais	30
2.2.3	Máquina de Vetores de Suporte	32
2.2.4	Árvores de decisão	33
2.2.5	Lógica <i>luzzy</i>	34
2.3	CONCLUSÃO	35
3	LÓGICA FUZZY	38
3.1	TEORIA DOS CONJUNTOS <i>FUZZY</i> E FUNÇÕES DE PERTINÊNCIA	38
3.1.1	Variável <i>fuzzy</i>	38
3.1.2	Funções de pertinência e sua tipologia	40
3.1.3	Operadores lógicos	45
3.1.3.1	<i>União (OU)</i>	45
3.1.3.2	<i>Intersecção (E)</i>	46
3.1.3.3	<i>Complemento (\neg)</i>	46
3.1.4	Propriedades Algébricas	47
3.2	RELAÇÃO FUZZY	48
3.2.1	relações clássicas	48
3.2.2	Relações <i>Fuzzy</i>	49

3.2.3	Composição de Relações <i>Fuzzy</i>	49
3.2.4	Regra Composicional de Inferência	50
3.3	REGRA <i>FUZZY</i> E SUA ESTRUTURA	51
3.4	ETAPAS DE UM SISTEMA <i>FUZZY</i>	51
3.4.1	Fuzzificação	52
3.4.2	Defuzzificação	53
3.4.2.1	<i>Métodos de Defuzzificação</i>	54
3.5	MÉTODOS DE SISTEMAS <i>FUZZY</i>	55
3.5.1	Método Mamdani	55
3.5.2	Método Sugeno	56
4	METODOLOGIA PROPOSTA	57
4.1	VISÃO GERAL DA METODOLOGIA PROPOSTA	57
4.2	MÓDULO CLASSIFICADOR	58
4.2.1	Estrutura do módulo e funcionamento	58
4.2.1.1	<i>Preparação dos dados</i>	59
4.2.1.2	<i>Treinamento da Árvore de Decisão</i>	59
4.2.1.3	<i>Poda da Árvore</i>	59
4.2.1.4	<i>Teste do Modelo</i>	59
4.2.1.5	<i>Geração de Regras</i>	60
4.3	MÓDULO DE CONVERSÃO	61
4.3.1	Submódulo de gerenciamento de variáveis	62
4.3.1.1	<i>Conjuntos gerados automaticamente</i>	62
4.3.1.2	<i>Conjuntos gerados manualmente</i>	63
4.3.2	Submódulo de gerenciamento de regras	65
4.3.2.1	<i>Regras geradas automaticamente</i>	65
4.3.2.2	<i>Regras geradas manualmente</i>	67
4.3.2.3	<i>Exemplo de criação manual de regra</i>	67
4.4	MÓDULO DE SISTEMAS <i>FUZZY</i>	71
4.5	IMPLEMENTAÇÃO TÉCNICA	72
4.5.1	Ferramenta utilizadas na construção dos módulos	72
5	EXPERIMENTOS E RESULTADOS	74
5.1	INTRODUÇÃO	74
5.2	BASE DE DADOS UTILIZADA	74

5.3	ANÁLISE DOS DADOS	76
5.3.1	Visão geral dos dados	76
5.3.2	Estatística descritiva dos dados	77
5.3.2.1	<i>Correntes (Ia, Ib, Ic)</i>	78
5.3.2.2	<i>Tensões (Va, Vb, Vc)</i>	78
5.3.3	Visualização dos tipos de falha	79
5.3.4	Distribuição de variáveis por tipo de falha	79
5.3.4.1	<i>Distribuição de Corrente por Classe de Falha</i>	80
5.3.4.2	<i>Distribuição de Tensão por Classe de Falha</i>	80
5.4	PROTOCOLO DOS EXPERIMENTOS	81
5.5	RESULTADOS DO MÓDULO DE CLASSIFICAÇÃO	83
5.5.1	Regras crisp extraídas	88
5.6	MÓDULO DE CONVERSÃO - MODELAGEM DAS VARIÁVEIS FUZZY E DAS REGRAS FUZZY	90
5.6.1	Variáveis fuzzy, Variáveis linguísticas e funções de pertinência . . .	90
5.6.2	Regras fuzzy modeladas	95
5.7	RESULTADO DO MÓDULO DE SISTEMAS FUZZY	96
5.7.1	Comparação de Desempenho entre Métodos	96
5.7.1.1	<i>Desempenho Geral</i>	96
5.7.1.2	<i>Método Centroide</i>	97
5.7.2	Sensibilidade e Precisão	97
5.7.3	F1-Score	97
5.7.4	Conclusão	97
6	CONCLUSÃO	98
6.1	RESUMO DO TRABALHO	98
6.2	QUESTÕES DA PESQUISA	98
6.2.1	Como a conversão de uma base de regras extraída de um árvore de decisão em uma base de regras fuzzy pode contribuir para a modelagem de conhecimento no diagnóstico de sistemas elétricos de potência?	98

6.2.2	De que forma a metodologia proposta contribui para o desenvolvimento de modelos precisos e regras representativas na construção de sistemas <i>fuzzy</i> voltados à detecção de falhas em sistemas elétricos de potência?	99
6.3	PRINCIPAIS CONTRIBUIÇÕES DA TESE	99
6.4	LIMITAÇÕES DA PESQUISA	100
6.5	TRABALHOS FUTUROS	100
	REFERÊNCIAS	102
	APÊNDICE A – PARÂMETROS DAS FUNÇÕES TRAPEZOIDAIS PARA CADA VARIÁVEL	107

1 INTRODUÇÃO

Este capítulo estabelece as bases da pesquisa, apresentando as principais questões que orientarão o estudo. A Seção 1.1 discute a motivação para a realização deste trabalho, contextualizando as razões e fundamentos da pesquisa. A Seção 1.2 define os objetivos do estudo, destacando as metas principais a serem alcançadas. Em seguida, a Seção 1.3 expõe as questões de pesquisa que guiarão a investigação. Por fim, a Seção 1.4 descreve a estrutura da tese, oferecendo uma visão geral da organização dos capítulos subsequentes.

1.1 MOTIVAÇÃO

Os Sistemas Elétricos de Potência (SEP) são infraestruturas complexas e interconectadas, responsáveis pela geração, transmissão e distribuição eficiente e confiável de energia elétrica em larga escala (BICHELS, 2018). Incluem usinas geradoras, redes de transmissão, subestações, linhas de distribuição e dispositivos de controle, assegurando o fornecimento seguro e estável de energia para consumidores residenciais, comerciais e industriais.

Em SEP, a ocorrência de eventos transitórios e condições operacionais anormais, provocados por falhas ou manobras de equipamentos na rede, é uma realidade frequente (JANARTHANAM et al., 2022), que, além de indesejável, apresenta riscos significativos para os equipamentos e usuários dos SEP. Entre esses riscos, incluem-se os danos a equipamentos de geração, transmissão e distribuição de energia. Por exemplo, os surtos de tensão podem causar falhas em isoladores e transformadores, enquanto as flutuações de frequência podem levar a danos em motores e equipamentos eletrônicos sensíveis. Para os usuários, esses eventos podem resultar em interrupções no fornecimento de energia, afetando residências, indústrias e serviços essenciais.

Além disso, há um risco elevado de incidentes de segurança, como incêndios e eletrocussões, especialmente em cenários onde as proteções falham em isolar rapidamente as partes afetadas do sistema (FRAZAO, 2019). Portanto, torna-se essencial a pronta detecção e diagnóstico do início de distúrbios, bem como a determinação da necessidade de atuação dos dispositivos de proteção para atenuar os impactos e restaurar a normalidade operacional do sistema.

Dentro de SEP, os componentes exigem atenção especial tanto na operação quanto na manutenção (JAMIL; SHARMA; SINGH, 2015), o que torna indispensável a adoção de estraté-

gias de proteção eficazes. Por essa razão, diversas estratégias de proteção são continuamente propostas e avaliadas para assegurar a operação eficiente desses equipamentos, evitando funcionamentos inadequados em situações adversas, como falhas internas (FRAZAO, 2019).

Tradicionalmente, o diagnóstico de falhas em SEP dependia quase exclusivamente da habilidade e experiência dos operadores humanos, que confiavam em sua perícia e intuição para interpretar os sinais e alertas exibidos nos painéis de controle (MAIA, 1998), (FERREIRA et al., 2016). Com base nessas informações, esses profissionais tomavam decisões cruciais, focadas em identificar e corrigir rapidamente as falhas emergentes, visando minimizar o impacto no funcionamento geral do sistema.

No entanto, durante ocorrências de falha, a sobrecarga de informações e a complexidade dos sinais podem sobrecarregar até mesmo os profissionais mais experientes, levando a possíveis atrasos ou decisões equivocadas. Esses profissionais desempenham um papel crítico na identificação das causas das interrupções e na tomada de decisões ágeis para garantir a recuperação segura dos SEP. Contudo, a confiança exclusiva na capacidade humana para gerenciar falhas apresenta limitações inerentes, já que mesmo operadores experientes estão sujeitos a erros, que podem ser agravados por fatores como fadiga, estresse e a crescente complexidade dos SEP (MEDEIROS et al., 2007). Portanto, torna-se essencial buscar soluções que reduzam a dependência exclusiva da expertise humana, a fim de aprimorar ainda mais a gestão de falhas em SEP.

Neste contexto, a adoção de metodologias baseadas em inteligência artificial representa um avanço significativo ao combinar a experiência humana com capacidades computacionais avançadas, possibilitando diagnósticos de falhas mais precisos e sofisticados. Essas metodologias de inteligência artificial podem detectar, classificar e localizar anormalidades de forma mais eficiente, especialmente em ambientes complexos como as subestações elétricas. Essa integração entre a intuição humana e a análise computacional detalhada promete transformar a maneira como os sistemas elétricos são monitorados e mantidos, levando a uma operação mais segura, confiável e eficiente (JR; ROLIM; ZÜRN, 2004). Essa evolução é vital para evitar danos significativos, como perdas financeiras e danos à reputação das empresas distribuidoras, enquanto fortalece a segurança e a eficácia do SEP como um todo.

Diversos algoritmos, como redes neurais, algoritmos genéticos, sistemas especialistas e árvores de decisão, têm sido amplamente utilizados na literatura (NANDHINI; PRAJITH, 2023). Entre eles, a lógica fuzzy se destaca pela sua capacidade de lidar com incertezas e informações imprecisas, características comuns nesses sistemas (ANDRADE-BENAVIDES; VALLEJO-HUANGA;

MORILLO, 2022). A lógica fuzzy utiliza um sistema de regras de inferência, que imita o processo de tomada de decisão humana, permitindo o processamento de sinais ruidosos e dados fragmentados, e oferecendo decisões robustas mesmo em condições de informação parcial ou incerta.

No entanto, para o funcionamento eficiente de um sistema *fuzzy*, é necessária a intervenção de um especialista para criar uma base de regras eficaz e ajustá-la para incluir novas ocorrências não cobertas pelas regras atuais. Para mitigar essa dependência da subjetividade do especialista e a complexidade associada à criação de regras, tem-se empregado o aprendizado de máquina com árvores de decisão (SAMANTARAY et al., 2010), (SAMANTARAY, 2010), (PARADAVA; SHIVANI; CHAUDHARI, 2017), (KONTOGIANNIS; BARGIOTAS; DASKALOPULU, 2021). Apesar da eficiência dessas abordagens, elas apresentam limitações importantes, como a ausência de interfaces interativas e ferramentas de visualização em tempo real, o que restringe sua aplicabilidade prática e dificulta o ajuste e validação das regras *fuzzy*. Além disso, geralmente utilizam apenas um único modelo de árvore de decisão para a geração de regras e não consideram diferentes métodos de defuzzificação, o que pode limitar a flexibilidade e a eficácia do sistema em diferentes contextos.

Para superar essas limitações, é proposta uma metodologia que inclui uma interface interativa que facilita a criação, ajuste e teste das regras *fuzzy*, com visualização dos resultados em tempo real. Além disso, a abordagem explora múltiplos modelos de árvores de decisão e diferentes métodos de defuzzificação, aumentando a adaptabilidade e eficácia do sistema em situações variadas. Essa metodologia é composta por duas instâncias essenciais: a aplicação de aprendizado de máquina por meio de árvores de decisão e a utilização de sistemas de regras *fuzzy*. A combinação dessas duas abordagens oferece uma solução abrangente e eficaz para a tarefa desafiadora de diagnosticar falhas em sistemas elétricos, abrindo caminho para um novo método de manutenção preditiva e preventiva.

A primeira etapa da metodologia consiste na aplicação de técnicas de aprendizado de máquina utilizando algoritmos baseados em árvores de decisão. Conhecidas por sua habilidade em capturar padrões complexos a partir de dados históricos (LIU et al., 2013), as árvores de decisão são usadas para analisar o comportamento dos SEP, identificando padrões e relações entre variáveis, que são então sintetizados em regras de diagnóstico. O modelo com o melhor desempenho é selecionado para fornecer essas regras ao sistema *fuzzy*, garantindo maior precisão na inferência.

A segunda instância da metodologia se baseia em um sistema de regras *fuzzy*, uma fer-

ramenta que permite a tradução das regras identificadas na etapa anterior em termos *fuzzy* compreensíveis. O sistema permite que especialistas apliquem seu conhecimento e intuição de forma precisa e flexível, criando regras de diagnóstico com base em variáveis linguísticas. Isso resulta em um conjunto de regras *fuzzy* que refletem a experiência e a expertise humana no domínio.

A integração entre as duas instâncias principais da metodologia — aprendizado de máquina com árvores de decisão e sistema *fuzzy* — é efetivada por meio de um módulo de conversão. Este módulo tem a função de transformar variáveis e regras definidas de maneira precisa (*crisp*) em suas correspondentes expressões *fuzzy*. Tal processo não apenas facilita a transição entre diferentes paradigmas de análise, mas também garante que o conhecimento extraído durante a fase de aprendizado de máquina seja adequadamente adaptado para aplicação no contexto *fuzzy*. Dessa forma, variáveis e regras *crisp* são reinterpretadas sob a ótica *fuzzy*, permitindo uma manipulação mais flexível e uma interpretação que reflete melhor a incerteza e a ambiguidade inerentes aos dados de SEP.

1.2 OBJETIVOS

O objetivo geral desta pesquisa é propor e desenvolver uma metodologia de diagnóstico de falhas em SEP, empregando aprendizado de máquina e lógica *fuzzy*. Esta metodologia será projetada para oferecer um conjunto abrangente de ferramentas, incluindo a criação automática e manual de variáveis *fuzzy*, criação automática e manual de regras *fuzzy* e modelos de decisão sob diferentes métodos de defuzzificação. Além disso, terá um design focado na facilidade de uso, garantindo que os usuários possam compreender e aplicar as regras *fuzzy* eficientemente no diagnóstico de falhas.

O objetivo geral deste trabalho pode ser decomposto nos seguintes objetivos específicos:

1. Investigar as metodologias disponíveis na literatura para classificação de falhas, identificando suas forças e fraquezas;
2. Criar interfaces para os módulos que sejam intuitivas e robustas, facilitando a criação de componentes por usuários sem conhecimento avançado em lógica *fuzzy*;
3. Desenvolver um método que permita a conversão automática das variáveis e regras *crisp* em variáveis e regras *fuzzy*;
4. Analisar o comportamento da metodologia proposta sob diferentes configurações de defuzzificação.

1.3 QUESTÕES DA PESQUISA

Baseado nos objetivos da pesquisa, este estudo pretende responder as seguintes questões de pesquisa:

1. “Como a conversão de uma base de regras extraída de um árvore de decisão em uma base de regras *fuzzy* pode contribuir para a modelagem de conhecimento no diagnóstico de sistemas elétricos de potência?”
2. “De que maneira a metodologia proposta contribui para o desenvolvimento de modelos acurados e com regras representativas na construção de sistemas *fuzzy* para detecção de falhas em sistemas elétricos de potência?”

1.4 ORGANIZAÇÃO DA TESE

Este texto será organizado da seguinte forma: No Capítulo 1 - Introdução, são introduzidos o contexto do diagnóstico em sistemas elétricos, bem como a motivação e os objetivos deste trabalho. No Capítulo 2 - Conceitos e Técnicas, são apresentados os fundamentos dos sistemas elétricos de potência e os tipos de falhas que podem ocorrer nesses sistemas. Além disso, revisam-se as principais abordagens da literatura especializada relacionadas ao diagnóstico de falhas em sistemas de potência. O Capítulo 3 - Lógica *fuzzy*, oferece um esboço sobre lógica *fuzzy* e sistemas *fuzzy* ajustados ao problema tratado neste trabalho. No Capítulo 4 - Metodologia Proposta, é detalhada a metodologia proposta para o diagnóstico de falhas. O Capítulo 5 - Experimentos e Resultados, descreve a base de dados, os parâmetros dos modelos, as métricas de avaliação, o processo de execução, além dos resultados e discussões dos experimentos. Por fim, o Capítulo 6 - Conclusão, apresenta as considerações finais e sugestões para trabalhos futuros.

2 CONCEITOS E TÉCNICAS

Este capítulo apresenta os conceitos fundamentais e os principais trabalhos relacionados à pesquisa. Na Seção 2.1, são abordadas a definição e as características dos SEP, fornecendo o contexto necessário para compreender sua complexidade e os desafios inerentes ao seu funcionamento. Em seguida, a Seção 2.2 apresenta uma revisão das publicações correlatas que utilizam técnicas comuns na literatura para detecção e classificação de falhas em SEP. Nessa revisão, são discutidas técnicas relacionadas à extração de características, como a Transformada de Wavelet (TW), bem como técnicas de inteligência artificial, incluindo Redes Neurais Artificiais (RNAs), Máquina de Vetores de Suporte (MVS), árvores de decisão e lógica *fuzzy*. A análise abrange métodos recentes e inovadores, destacando as abordagens mais eficazes e os desafios enfrentados na aplicação dessas técnicas. Por fim, a Seção 2.3 apresenta as considerações finais do capítulo.

2.1 SISTEMAS ELÉTRICOS DE POTÊNCIA

Os SEP são complexos sistemas responsáveis pela produção, transmissão e distribuição de energia elétrica. Eles incluem usinas de geração de energia, subestações de transformação e interligação, linhas de transmissão e distribuição, e as cargas (BICHELS, 2018).

Fisicamente, os SEP são compostos por três subsistemas (GUIMARAES, 2021):

1. Geração: O sistema de geração abrange as unidades geradoras de grande porte, normalmente tensões na faixa de 30 Kv ou inferiores. Este sistema tem como função principal transformar algum tipo de energia primária em elétrica, como uso das águas por meio das hidrelétricas, queima de algum combustível (usinas termoeletricas), ventos na forma de energia eólica, luz solar, na forma de energia fotovoltaica, ou ainda, geração por meio de fissão nuclear.
2. Transmissão: A função primordial da transmissão de energia elétrica é o deslocamento da energia gerada nos centros de produção até os locais de consumo. Esses sistemas são principalmente compostos por torres, que são estruturas de metal que elevam os cabos a uma altura segura acima do solo; isoladores, frequentemente feitos de cerâmica, vidro ou polímeros para evitar vazamento de corrente para as torres e suportar o peso dos cabos; e subestações, que são projetadas para ajustar os níveis de tensão, elevando ou

diminuindo conforme necessário.

3. Distribuição: Os sistemas de distribuição de energia elétrica abrangem desde subestações de distribuição até os pontos de conexão dos consumidores finais. Eles são divididos em rede de distribuição primária (média tensão, geralmente 13,8 kV) e rede de distribuição secundária (baixa tensão, como 220/127 V ou 380/220 V). As subestações podem ser alimentadas por linhas de subtransmissão ou transmissão, e os alimentadores primários transportam a energia até os transformadores de distribuição. Estes, por fim, fornecem energia aos consumidores finais por meio dos alimentadores secundários na rede secundária.

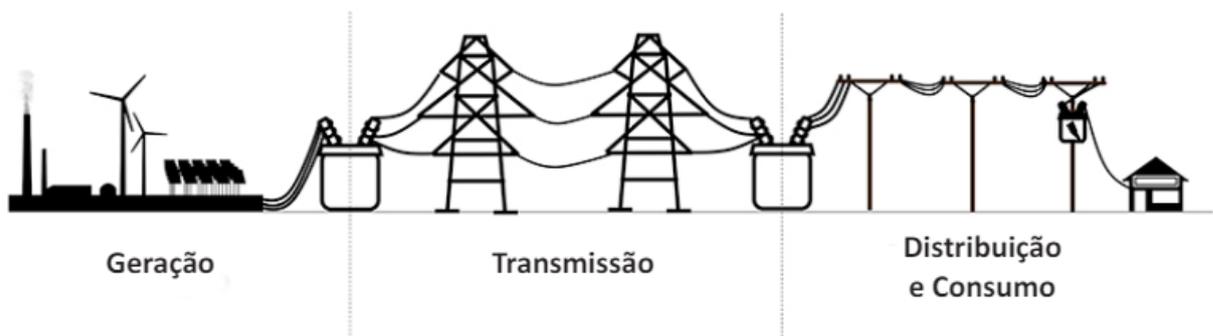


Figura 1 – Subsistemas do sistema elétrico de potência.
Fonte: (SILVA, 2019)

Na Figura 1 é ilustrada a organização dos subsistemas de energia. Esses subsistemas podem ser representados de forma simplificada por meio de diagramas unifilares, nos quais cada conjunto de equipamentos, como geradores, transformadores e linhas de transmissão, é mostrado como uma única linha. Isso facilita a visualização das conexões e do fluxo do sistema, como ilustrado na Figura 2 que destaca a presença de três usinas, um conjunto de linhas de transmissão, uma rede de subtransmissão, uma rede de distribuição primária e três redes de distribuição secundária.

2.1.1 subestações de energia elétrica - conceito e classificação

Uma subestação representa um componente crítico do sistema elétrico, incorporando equipamentos para manobras, controle, proteção e transformação, assim como outros dispositivos, cabos e acessórios, incluindo infraestrutura civil e estruturas de montagem (Agência Nacional de Energia Elétrica (ANEEL), 2021).

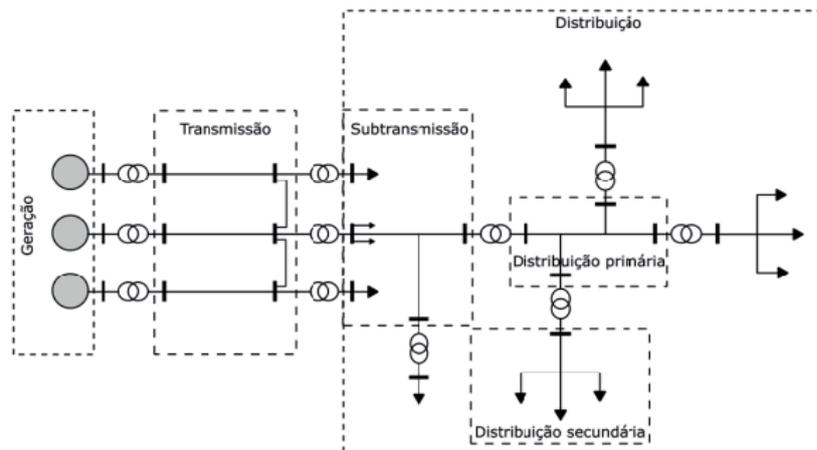


Figura 2 – Diagrama unifilar de um sistema elétrico de potência.
 Fonte: (KAGAN; OLIVEIRA; ROBBA, 2010)

As subestações elétricas são fundamentais para os sistemas de energia elétrica. Elas são responsáveis por ajustar os níveis de tensão para a transmissão eficiente da eletricidade e para adequá-los aos requisitos de distribuição.

Além disso, desempenham um papel crucial em várias operações essenciais para garantir a continuidade e a confiabilidade do fornecimento de energia. As subestações agem como pontos de conexão entre os diferentes sistemas de geração, transmissão e distribuição de energia.

Elas não são apenas pontos de interconexão na rede elétrica, mas também locais onde se realizam operações de controle e proteção. Os equipamentos nas subestações fornecem informações valiosas para a análise do estado geral do sistema, tornando-as peças-chave na automação dos sistemas elétricos.

Segundo Gedra (GEDRA; BARROS; BORELLI, 2014), as subestações podem ser categorizadas em dois tipos: subestações de energia das concessionárias e subestações de energia dos consumidores. As subestações das concessionárias desempenham a função de elevar a tensão na geração e reduzi-la na transmissão e distribuição. Na fase de transmissão, são chamadas de Estações Transformadoras de Transmissão (ETT) e operam com várias tensões alternadas, como 69 kV, 88 kV, 138 kV, 230 kV, 345 kV, 440 kV, 500 kV e 750 kV, além de 600 kV em corrente contínua no Brasil. Nas áreas de distribuição, são denominadas Estações Transformadoras de Distribuição (ETD) e reduzem a tensão para distribuição em postes de rua, com valores típicos de 3,8 kV, 11,9 kV, 13,2 kV, 13,8 kV, 20 kV, 23,5 kV e 34,5 kV. As subestações dos consumidores, conhecidas como Estações Transformadoras de Consumidor (ETC), têm a função de reduzir a tensão para alimentar equipamentos internos quando a carga ultrapassa

75 kW e a demanda contratada chega a 2.500 kW, conectando-se a tensões primárias de distribuição inferiores a 69 kV.

As subestações de transmissão desempenham um papel crucial no controle do fluxo de potência, na regulação dos níveis de tensão e na entrega de energia elétrica a consumidores industriais. Os principais componentes incluem transformadores de potencial para medição de tensão, transformadores de corrente para medição de corrente, transformadores de potência para ajuste de tensão, disjuntores para desconexão, chaves seccionadoras para isolação, fio terra para proteção contra descargas atmosféricas e para-raios para escoamento de corrente excessiva devido a descargas atmosféricas.

As redes de transmissão frequentemente adotam topologias malhadas ou reticuladas para maior disponibilidade e segurança, especialmente com automação avançada.

As redes de subtransmissão, com tensões entre 35 kV e 160 kV, têm características semelhantes e visam transportar energia para cidades pequenas e consumidores industriais.

A escolha de modelar casos de falha em linhas de transmissão nesta dissertação se deve à complexidade das condições de transmissão, já que subestações de transmissão enfrentam desafios únicos, como longas distâncias e altas tensões, tornando-as cenários críticos para a análise da estabilidade e eficiência do sistema (VASCONCELOS, 2017).

2.1.2 Falhas em sistemas de potência

Segundo (GEDRA; BARROS; BORELLI, 2014), os SEP operam normalmente em regime permanente, sua condição ideal de funcionamento. No entanto, mesmo com equipamentos de alta qualidade e manutenção eficaz, defeitos inevitáveis ocorrem, levando o sistema a estados transitórios de curta duração, conhecidos como curto-circuitos, que resultam em sobrecorrentes e sobretensões. Após a eliminação desses defeitos, o sistema retorna ao regime normal, frequentemente com a exclusão de uma linha, transformador ou gerador.

(GEDRA; BARROS; BORELLI, 2014) também destacam que todos os sistemas estão sujeitos a curtos-circuitos em seus componentes e devem estar preparados para detectá-los, suportá-los e eliminá-los rapidamente para evitar danos aos equipamentos e riscos à segurança humana. Curtos-circuitos podem ocorrer em qualquer parte do sistema, entre pontos energizados ou entre um ponto energizado e a terra, resultando em diferentes tipos de curtos como trifásico (a), bifásico (b), bifásico à terra (c), monofásico (d), ilustrados na Figura 3.

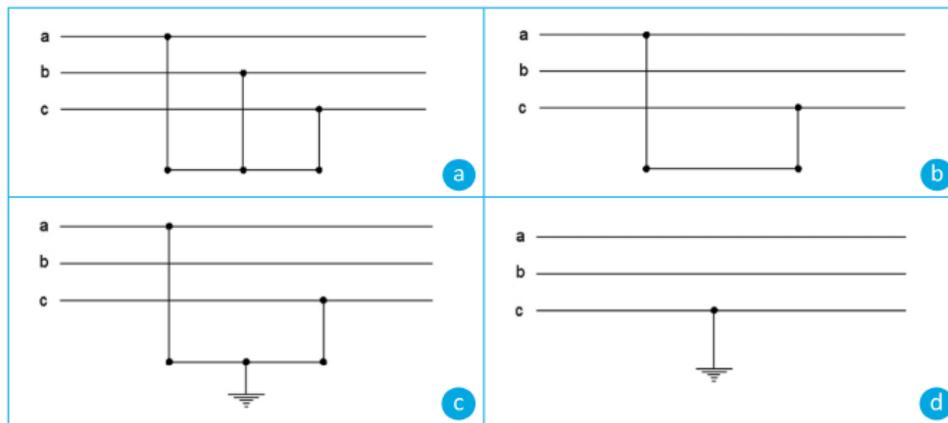


Figura 3 – Tipos de curto-circuito.
Fonte: (BICHELS, 2018)

Segundo (VASCONCELOS, 2017), as consequências dos curtos-circuitos variam de mínimas a catastróficas, dependendo da eficácia dos sistemas de proteção. As interrupções causam perdas financeiras e sociais significativas, incluindo perdas de receita para concessionárias e insatisfação dos clientes. A função dos sistemas de proteção é crucial para desconectar partes do sistema em condições anormais, detectando falhas por meio de indicadores como alterações de corrente e tensão, direção da corrente, variações de impedância e diferenças no módulo e ângulo de fase. A rápida identificação, localização e implementação de estratégias de restauração são essenciais para manter a integridade e a eficiência dos SEP.

2.1.3 Sistema de proteção

Segundo Frazão (FRAZAO, 2019), a principal função de um sistema de proteção é desativar imediatamente os elementos afetados por curtos-circuitos ou em operação anormal, evitando impactos na operação geral do sistema elétrico. Sua estrutura básica consiste em uma organização de dispositivos inter-relacionados com funções bem definidas, trabalhando juntos para um objetivo comum:

1. **Transformadores de Instrumentação:** Usados para medir correntes e tensões, adaptando sinais de alta tensão para níveis manejáveis.
2. **Relés Digitais:** Avaliam os sinais dos transformadores para identificar possíveis curtos-circuitos.
3. **SCADA (Supervisor de Controle e Aquisição de Dados):** Um sistema computacional que processa dados dos relés, gerencia informações operacionais em tempo real e

apoia na tomada de decisões.

4. **Disjuntores e Fusíveis de Proteção:** Disjuntores desconectam seções do sistema elétrico sob comando dos relés, quando um curto-circuito é detectado. Os fusíveis de proteção são usados para proteção adicional, especialmente em subestações e na rede de distribuição.

Existem critérios fundamentais que um sistema de proteção deve atender para garantir a operação segura e eficaz de SEP. Esses requisitos são essenciais para a correta atuação dos dispositivos de proteção em caso de falhas ou condições anormais. Segundo (VASCONCELOS, 2017), os requisitos básicos de um sistema de proteção são:

1. **Seletividade:** Capacidade de isolar apenas a seção afetada por um defeito, evitando impactar outras partes do sistema, mantendo a maior parte do sistema em operação durante uma falha.
2. **Zonas de Atuação:** Estabelecimento de áreas de responsabilidade definidas para cada dispositivo de proteção, garantindo que eles reajam apenas a falhas dentro de sua área designada.
3. **Velocidade:** Necessidade de uma resposta rápida para limitar danos, reduzir a duração de interrupções de energia, e facilitar a recuperação e resincronização de equipamentos.
4. **Sensibilidade:** Configuração de limites operacionais precisos para os dispositivos de proteção, permitindo a detecção e resposta adequadas a diversas condições anormais.
5. **Confiabilidade:** Refere-se à eficácia e segurança com que os dispositivos de proteção desempenham suas funções, evitando falhas na detecção ou na ação.
6. **Automação:** A capacidade dos dispositivos de proteção de operarem automaticamente, baseando-se exclusivamente em leituras de grandezas elétricas, sem a necessidade de intervenção humana, e de ignorar flutuações normais do sistema para evitar atuações desnecessárias.

2.1.4 Automação dos sistemas de potência

Em (ACKERMAN, 1999) é discutida a crescente importância da automação em SEP devido aos avanços tecnológicos e à necessidade de maior eficiência e competitividade na indústria de energia. A automação permite a coleta e análise de grandes volumes de dados, melhorando significativamente o monitoramento e o controle dos SEP. A desregulamentação da indústria de energia e a necessidade de redução de custos impulsionaram a adoção da automação, que

oferece benefícios como maior eficiência, confiabilidade do sistema e qualidade de energia. No entanto, o aumento da complexidade e do volume de dados exige novas abordagens para a construção e manutenção de bancos de dados, processamento de dados em tempo real e técnicas de visualização para operadores.

Em (ZHAO; ZHANG, 2016), os autores discutem que a automação com técnicas de inteligência artificial auxilia os operadores na verificação e tomada de decisões, reduzindo significativamente a carga de trabalho e melhorando a eficiência no tratamento de incidentes. Segundo eles, esta é uma das principais causas que, nos últimos anos, têm levado as pesquisas sobre a aplicação de inteligência artificial no setor elétrico a se intensificarem.

No contexto das técnicas de inteligência artificial, a lógica *fuzzy* é essencial na automação de SEP, devido à sua habilidade em gerenciar incertezas e informações imprecisas, comuns nesse campo. A lógica *fuzzy* facilita a captura do comportamento de sistemas complexos, oferecendo uma formulação de regras de controle mais natural e flexível, imitando a tomada de decisão humana. Isso permite a integração eficiente de múltiplos sistemas e processos, otimizando o funcionamento global do sistema de energia. Além disso, sistemas baseados em lógica *fuzzy* podem se adaptar dinamicamente a mudanças no ambiente operacional, crucial para manter a estabilidade e eficiência do sistema de energia, tornando a gestão mais acessível e compreensível para operadores humanos.

2.2 TÉCNICAS UTILIZADAS NA LITERATURA

2.2.1 Transformadas de *Wavelet*

Os dados provenientes das redes de energia nos SEP, como tensão e corrente, são cruciais para monitorar e manter a estabilidade e eficiência dessas redes. No entanto, esses dados, por si só, muitas vezes são brutos e complexos, tornando desafiador aplicar regras específicas para extrair diretamente insights úteis deles.

Técnicas de extração de características são utilizadas para identificar e isolar informações relevantes desses dados brutos. Uma dessas técnicas, a TW (MALLAT, 1999), destaca-se por sua capacidade de decompor sinais elétricos em componentes de diferentes frequências, mantendo a informação temporal. Isso permite uma visão detalhada das características do sinal, tanto em frequência quanto no tempo, ideal para detectar e classificar falhas em sistemas elétricos. A TW é capaz de identificar transientes e anomalias nos sinais que são indicativos de falhas,

como curtos-circuitos ou interrupções, ao analisar as mudanças abruptas e as características únicas dos sinais durante eventos de falha.

O artigo de Sundararaman *et al.* (SUNDARARAMAN; JAIN, 2023) descreve o uso de uma técnica baseada em TW para a detecção e classificação acurada de falhas em sistemas de energia. A análise de *wavelet* é aplicada nas perturbações transitórias causadas por diversas falhas para examinar os coeficientes de detalhe das correntes de fase. Esses coeficientes, que mudam de maneira notável em situações de falha, são usados para diferenciar os tipos de falhas no sistema. O estudo (VALSAN; SWARUP, 2009) propõe um esquema digital eficiente e de alta velocidade para proteção de linhas de transmissão utilizando a TW. A abordagem é composta por três etapas principais: proteção direcional, classificação de falhas e localização de falhas. A transformada *wavelet* é usada para analisar transientes de falhas, focando nos detalhes de alta frequência das correntes e tensões. O método se mostrou confiável em condições adversas, como resistência de falhas e saturação de transformadores.

Apesar dos benefícios oferecidos pela TW, sua aplicação em diagnósticos de sistemas de potência não está isenta de desafios. Os sistemas construídos com base em TW apresentam complexidade e exigem conhecimentos avançados em processamento de sinais, tornando-se pouco intuitivos para operadores que precisam manipular conceitos abstratos. Dentre as limitações associadas ao uso de TW em diagnósticos de sistemas elétricos, destacam-se:

1. A seleção da função de TW apropriada e de seus parâmetros pode ser desafiadora, influenciando significativamente os resultados da análise. Escolhas inadequadas podem levar a informações imprecisas ou à perda de detalhes cruciais nos sinais.
2. A decomposição e recomposição dos sinais usando TW podem ser computacionalmente intensivas, especialmente para sinais de alta frequência e grandes volumes de dados. Isso requer recursos computacionais substanciais e pode impactar a eficiência do diagnóstico em tempo real.
3. A sensibilidade ao ruído nos sinais elétricos é uma consideração crítica. Sinais ruidosos podem introduzir falsos positivos ou falsos negativos na detecção de falhas, comprometendo a confiabilidade do diagnóstico.

2.2.2 Redes Neurais Artificiais

As RNAs são modelos computacionais inspirados no funcionamento do cérebro humano, amplamente utilizados em diversas aplicações, incluindo diagnósticos em sistemas de potên-

cia (XU, 2018).

As RNAs imitam o aprendizado do cérebro humano com camadas de neurônios que processam sinais. Cada neurônio pondera os sinais recebidos e se ativa se ultrapassar um limiar, passando o sinal para a próxima camada. O processo vai da camada de entrada até a de saída. Durante o treinamento, a rede ajusta os pesos sinápticos para minimizar erros entre previsões e resultados reais, utilizando algoritmos como *backpropagation*. Essa capacidade de ajuste torna as RNAs eficazes em reconhecer padrões complexos em grandes conjuntos de dados.

Chopdar *et al.* (CHOPDAR; KOSHTI, 2022) abordam o aumento na demanda de carga elétrica e, conseqüentemente, no número de linhas de transmissão. Com mais linhas, cresce a probabilidade de falhas, tornando crucial a rápida detecção e classificação dessas falhas para minimizar danos ao sistema de energia. O artigo apresenta uma abordagem baseada em RNAs para a classificação e detecção de falhas no sistema de energia. Para treinar a rede neural, são utilizados como entrada a tensão e corrente dos barramentos, além dos componentes de sequência zero de corrente e tensão. Exemplos semelhantes podem ser encontrados em (JAMIL; SHARMA; SINGH, 2015) e (OGAR; HUSSAIN; GAMAGE, 2023).

Apesar de serem amplamente utilizadas em diagnósticos de sistemas de potência, As redes Neurais apresentam limitações quando comparadas à lógica *fuzzy*:

1. Interpretabilidade e Transparência: As RNAs são modelos “caixa preta” e têm baixa interpretabilidade, ao contrário da lógica *fuzzy*, que é baseada em regras intuitivas e fáceis de compreender.
2. Dependência de Dados de Treinamento: As RNAs necessitam de grandes conjuntos de dados para treinamento eficaz, enquanto a lógica *fuzzy* pode ser implementada com um conhecimento especializado mais limitado, sendo menos dependente de grandes volumes de dados.
3. Sensibilidade a dados ruidosos e Anômalos: RNAs são sensíveis a dados ruidosos, diferentemente da lógica *fuzzy*, que pode lidar melhor com incertezas e imprecisões nos dados.
4. Custo Computacional: RNAs, especialmente as mais complexas, têm alto custo computacional, em contraste com sistemas baseados em lógica *fuzzy*, que geralmente são mais simples e menos custosos em termos computacionais.
5. Generalização e Sobreajuste: RNAs correm o risco de sobreajuste, enquanto a lógica *fuzzy*, com suas regras baseadas em conhecimento humano, pode ser mais robusta contra o sobreajuste e oferecer melhor generalização.

6. **Atualizações e Manutenção:** As RNAs exigem atualizações frequentes para se adaptar a novos padrões, ao passo que sistemas baseados em lógica *fuzzy* podem ser mais fáceis de ajustar e manter, pois as mudanças geralmente envolvem a modificação de regras ou funções de pertinência.

Portanto, embora as RNAs sejam poderosas na modelagem de relações complexas, a lógica *fuzzy* oferece vantagens em termos de interpretabilidade, manuseio de incertezas e facilidade de manutenção, o que é desejável em diagnósticos de SEP.

2.2.3 Máquina de Vetores de Suporte

MVS é um algoritmo de aprendizado supervisionado utilizado para tarefas de classificação e regressão. A ideia básica por trás de um MVS é encontrar o hiperplano de separação que maximiza a margem entre as classes. O hiperplano é escolhido de forma que fique o mais longe possível das observações de treinamento mais próximas, chamadas vetores de suporte. Isso permite que o MVS generalize bem para novos dados.

No trabalho de Venkata *et al.* (VENKATA *et al.*, 2022), é apresentado um novo método para detecção e classificação de falhas em linhas de transmissão, utilizando MVS treinado com parâmetros extraídos de séries temporais e de frequência gerados em cenários simulados de falhas e condições normais de operação. O método proposto é testado com uma ampla variedade de dados, variando os parâmetros mais importantes como resistência de falha, ângulo de início de falha e localização da falha. O modelo proposto pode classificar as falhas com 100% de precisão para o conjunto de dados sem ruído. Outras aplicações podem ser vistas em (AWALIN; NAIDU; SUYONO, 2019), (SAHOO; MOHANTY, 2021).

Apesar do MVS ser uma técnica poderosa de aprendizado de máquina, amplamente utilizada para classificação em sistemas de potência, ele apresenta algumas limitações:

1. **Sensibilidade aos Parâmetros do Kernel:** A escolha do kernel e seus parâmetros (como o parâmetro de regularização e o parâmetro de largura do kernel Gaussiano) tem um impacto significativo no desempenho do MVS. Uma escolha inadequada pode levar a um desempenho subótimo.
2. **Escalabilidade e Grande Volume de Dados:** O MVS pode não ser a melhor escolha para conjuntos de dados muito grandes, pois seu tempo de treinamento tende a aumentar de forma significativa com o aumento do número de amostras, enquanto a lógica *fuzzy* é geralmente mais escalável e menos intensiva em termos de cálculo.

3. Interpretabilidade: O modelo resultante do MVS geralmente não é fácil de interpretar. Ao contrário da lógica *fuzzy* que é mais interpretável, com regras linguísticas intuitivas.

2.2.4 Árvores de decisão

Árvores de decisão são modelos de aprendizado supervisionado usados tanto para classificação quanto para regressão. Elas funcionam como um processo de tomada de decisão estruturado em forma de árvore, onde cada nó interno representa uma decisão com base em uma característica (atributo) específica, cada ramo representa o resultado dessa decisão, e cada folha representa uma saída ou resultado final (classe ou valor predito). O processo de construção de uma árvore de decisão envolve a divisão recursiva dos dados em subconjuntos cada vez menores. Em cada etapa, o algoritmo seleciona o atributo que melhor separa os dados, baseado em métricas como Gini ou entropia, e cria nós e ramos até que um critério de parada seja alcançado, como a profundidade máxima da árvore ou o número mínimo de amostras em um nó.

Diversos trabalhos têm explorado essa técnica no diagnóstico de falhas em sistemas de energia. (JAMEHBOZORG; SHAHRTASH, 2010) propõe um método baseado em árvores de decisão para classificação de falhas em linhas de transmissão de circuito duplo. O objetivo do estudo é melhorar a precisão e rapidez na detecção de falhas, essenciais para manter a confiabilidade dos sistemas de energia. (SWETAPADMA; YADAV, 2016) propõe um método baseado em mineração de dados para identificar falhas que ocorrem durante oscilações de potência em sistemas de transmissão de energia elétrica.

Essa técnica também apresenta algumas limitações:

1. As árvores de decisão utilizam limiares rígidos para classificar os dados, como “se $x > 10$, então A; senão, B”. Esse tipo de decisão abrupta pode ser problemático quando os dados não são claramente separados ou apresentam transições graduais. Em um cenário onde os valores das variáveis mudam de forma contínua, a classificação rígida das árvores de decisão pode resultar em decisões pouco representativas da realidade. Em contraste, a lógica *fuzzy* permite transições suaves entre estados. Em vez de classificações binárias, ela atribui graus de pertinência, o que permite capturar de maneira mais precisa situações intermediárias, tornando o sistema mais flexível e capaz de lidar com dados imprecisos ou variáveis contínuas.
2. As árvores de decisão podem gerar muitas regras, especialmente em problemas comple-

xos. Ao utilizar lógica *fuzzy*, essas regras podem ser simplificadas, já que as transições não precisam ser exatas, e valores intermediários podem ser geridos de forma contínua. Isso evita a explosão combinatória de regras e melhora a interpretabilidade do sistema, ao mesmo tempo em que mantém a capacidade de lidar com condições complexas de forma eficiente. Além disso qualquer mudança nas regras requer um novo treinamento no modelo, já a lógica *fuzzy* permite a pronta modificação e ajuste destas regras.

2.2.5 Lógica *fuzzy*

Os sistemas baseados em lógica *fuzzy* são construídos a partir do conhecimento fornecido por especialistas, refletindo sua experiência (BIH, 2006). Como o cérebro humano opera com conceitos linguísticos, a lógica difusa se destaca em emular a tomada de decisão humana (RAMOT et al., 2003). Sua principal vantagem está na simplicidade dos elementos manipulados, como variáveis *fuzzy*, linguísticas e regras, permitindo uma visualização intuitiva da estrutura do problema e fácil ajuste dos componentes. Assim, entidades do mundo real são representadas por variáveis *fuzzy*, com seus estados modelados como variáveis linguísticas, e suas relações descritas por regras de inferência.

Diversos estudos aplicam a lógica *fuzzy* em casos envolvendo sistemas de potência e seus componentes. Por exemplo, Razi *et al.* (RAZI; HAGH; AHRABIAN, 2007) apresentam um esquema *fuzzy* para a classificação de falhas em linhas de transmissão, alcançando mais de 97% de acurácia.

(ADHIKARI; SINHA; DORENDRAJIT, 2016) apresenta uma abordagem baseada em lógica *fuzzy* para a detecção e classificação de falhas em linhas de transmissão em tempo real. O sistema utiliza amostras de corrente e tensão como entradas e aplica regras *fuzzy* para identificar o tipo de falha, proporcionando maior precisão e rapidez no diagnóstico de falhas elétricas. A técnica demonstrou ser eficiente na melhoria da confiabilidade e segurança das operações em sistemas de transmissão de energia.

Mahanty *et al.* (MAHANTY; GUPTA, 2007) apresentam uma abordagem baseada em lógica *fuzzy* para a classificação de falhas na proteção de linhas de transmissão, utilizando amostras de correntes trifásicas e validando o método com simulações de dados no Matrix Laboratory (MATLAB) (MathWorks Inc., 2010). Althi *et al.* (ALTHI; KOLEY; GHOSH, 2021) propõem um esquema de detecção e classificação de falhas baseado em lógica *fuzzy* para linhas de transmissão de seis fases, focando em falhas em série e demonstrando a aplicabilidade da lógica

fuzzy em sistemas mais complexos. Benavides *et al.* (ANDRADE-BENAVIDES; VALLEJO-HUANGA; MORILLO, 2022) propõem um sistema especialista para modelar os dados históricos de falhas em uma empresa de distribuição de eletricidade, avaliando a gestão do tempo de reconexão do serviço após uma falha. O modelo *fuzzy* desenvolvido é baseado exclusivamente em uma análise pós-operatória, sendo capaz de estimar o grau de eficiência da gestão de falhas.

Apesar dos sistema *fuzzy* apresentarem vantagens significativas em relação aos outros métodos ele apresenta limitações:

1. Dependência de Especialistas: A definição das funções de pertinência e das regras *fuzzy* geralmente requer conhecimento especializado sobre o sistema elétrico em análise. Isso pode tornar a modelagem complexa, especialmente em sistemas de potência onde as condições de operação e falhas podem ser muito variadas.
2. Número de Regras: À medida que o número de variáveis e estados possíveis aumenta, a quantidade de regras *fuzzy* necessárias cresce exponencialmente, levando a uma complexidade computacional significativa. Isso pode tornar a implementação do sistema *fuzzy* mais complicada e difícil de manter.
3. Dificuldade de Manutenção: Sistemas de potência estão sujeitos a mudanças ao longo do tempo, como atualizações de infraestrutura e mudanças nas condições operacionais. Manter um sistema *fuzzy* atualizado pode ser difícil, pois requer uma reavaliação frequente das regras e funções de pertinência.

2.3 CONCLUSÃO

Neste capítulo, foram apresentados os conceitos fundamentais dos sistemas elétricos modernos, incluindo a descrição de seus subsistemas, os principais tipos de falhas que podem ocorrer e os sistemas de proteção utilizados para mitigá-las.

Adicionalmente, realizou-se uma análise concisa dos principais trabalhos que propõem técnicas de diagnóstico de falhas em SEP, resumida na Tabela 1. Essa análise teve como objetivo contextualizar a proposta desta dissertação de mestrado em relação às abordagens existentes.

Muitas metodologias *fuzzy* propostas na literatura concentram-se no desenvolvimento teórico e na aplicação de algoritmos para sistemas elétricos, mas frequentemente carecem de uma interface interativa e de ferramentas para visualização em tempo real dos resultados. Essa limitação torna a aplicação dessas metodologias menos prática, especialmente para operadores e engenheiros que precisam monitorar e diagnosticar sistemas elétricos de forma dinâmica. Sem

Tabela 1 – Artigos, algoritmos, métricas e inputs utilizados.

Título do Artigo	Algoritmo	Métrica	Input
Wavelet transform based digital protection for transmission lines	Wavelet	Acurácia	Corrente e tensão
Fault Detection and Classification in Electrical Power Transmission System Using Wavelet Transform	Wavelet	Coeficiente de detalhe	Corrente
Fault detection and classification in electrical power transmission system using artificial neural network	Rede Neural	Acurácia	Tensão e corrente
The use of artificial neural network for low latency of fault detection and localisation in transmission line	Rede Neural	Acurácia	Corrente e tensão
Fault Detection and Classification in Power System Using Artificial Neural Network	Rede Neural	MSE	Tensões e correntes trifásicas
Fault types classification using support vector machine (SVM)	Máquina de Vetores de Suporte	Acurácia	Tensão
Support vector machine for fast fault detection and classification in modern power systems using quarter cycle data	Máquina de Vetores de Suporte	Acurácia, Precisão, Sensibilidade, F1-Score	Corrente e tensão
A Novel Approach of SVM for Fault Detection and Classification in a Series Compensated Line	Máquina de Vetores de Suporte	Acurácia	Corrente e tensão
AMEHBOZORG, A.; SHAHRTASH, S. A decision tree-based method for fault classification	Árvore de Decisão	Acurácia	Corrente das seis fases
Data-mining-based fault during power swing identification in power transmission system	Árvore de Decisão	Acurácia	Tensão e corrente
A fuzzy logic based fault classification approach using current samples only	Lógica Fuzzy	Acurácia	Corrente
High accurate fault classification of power transmission line using fuzzy logic	Lógica Fuzzy	Acurácia	Componentes de sequência da corrente
Fuzzy logic based on line fault detection and classification in transmission line	Lógica Fuzzy	Acurácia	Corrente e tensão
Fuzzy Logic based Fault Detection and Classification scheme for Series Faults in Six Phase Transmission Line	Lógica Fuzzy	Tempo de resposta	Corrente
Fuzzy Logic Model for Failure Analysis in Electric Power Distribution Systems	Lógica Fuzzy	Tempo de resposta	Corrente, tensão, condições ambientais

uma interface amigável e uma visualização em tempo real, a implementação dessas técnicas pode se tornar uma tarefa complexa e demorada, dificultando a identificação de padrões e a tomada de decisões rápidas em situações críticas.

A abordagem proposta neste trabalho inclui a implementação de uma interface interativa que permite criar, ajustar e testar regras *fuzzy* com facilidade, além de visualizar os resultados em tempo real. Isso facilita o monitoramento contínuo do sistema elétrico, oferecendo uma visão clara e imediata do impacto de qualquer ajuste nas regras *fuzzy*, possibilitando

diagnósticos mais precisos e intervenções eficazes.

Além disso, ao contrário de outras abordagens que se limitam a um único algoritmo para a geração de regras, esta metodologia adota uma estratégia mais abrangente ao utilizar algoritmos baseados em árvores, seja por meio de uma única árvore de decisão ou de um conjunto de árvores. Essa diversidade permite gerar um conjunto de regras mais robusto e adaptável, capturando de maneira mais eficaz os padrões complexos e as interações não lineares presentes nos sistemas elétricos.

Outro diferencial significativo é a inclusão de múltiplos métodos de defuzzificação, disponibilizando ao especialista uma variedade de opções para interpretar os resultados *fuzzy* de forma mais precisa. Muitas propostas da literatura não oferecem essa flexibilidade, o que pode limitar a capacidade de ajuste do sistema para obter os melhores resultados em situações específicas. A abordagem aqui apresentada, ao oferecer diferentes métodos de defuzzificação e uma interface interativa, torna-se mais completa e ajustável, podendo ser adaptada às características e necessidades únicas de diferentes ambientes e cenários operacionais. A metodologia completa será detalhada no Capítulo 4, apresentando os passos e a estrutura que suportam a implementação da metodologia.

3 LÓGICA FUZZY

3.1 TEORIA DOS CONJUNTOS FUZZY E FUNÇÕES DE PERTINÊNCIA

A lógica *fuzzy*, também conhecida como lógica difusa, foi desenvolvida pelo professor e engenheiro Lotfi A. Zadeh da Universidade da Califórnia em Berkeley, e seu conceito fundamental foi introduzido em seu artigo seminal de 1965, "Fuzzy Sets" (ZADEH, 1965). A ideia por trás da lógica *fuzzy* era lidar com a incerteza e a imprecisão inerentes em muitos problemas do mundo real, uma lacuna que as abordagens tradicionais de lógica binária e teoria dos conjuntos não conseguiam preencher.

A proposta de Zadeh consistiu na introdução do conceito de pertinência, permitindo que elementos pertençam a conjuntos *fuzzy* com graus variáveis entre 0 e 1. Essa flexibilidade representacional abriu caminho para uma modelagem mais adaptável de cenários complexos e imprecisos.

O desenvolvimento subsequente da lógica *fuzzy* testemunhou uma expansão significativa tanto no âmbito teórico quanto prático com pesquisadores de diversas disciplinas contribuindo para o enriquecimento da teoria e a aplicação prática da lógica *fuzzy*. Segundo (CARTER et al., 2021), a lógica *fuzzy* encontrou aplicações em diversos campos, como análise de sentimentos, diagnóstico médico, controle de sistemas de transportes inteligentes e controle de personagens em jogos eletrônicos. Essas aplicações mostram sua eficácia em lidar com problemas complexos e incertos em várias áreas do conhecimento.

O reconhecimento crescente da lógica *fuzzy* conduziu à sua padronização e integração em diversas ferramentas e linguagens de programação, solidificando seu papel como uma ferramenta essencial em uma diversidade de contextos.

3.1.1 Variável *fuzzy*

Segundo (ZIMMERMANN, 2010), a modelagem de uma variável *fuzzy* baseia-se na teoria dos conjuntos *fuzzy*, que aprimora a teoria dos conjuntos clássicos. Enquanto os conjuntos clássicos lidam com a pertinência binária (um elemento pertence ou não a um conjunto), os conjuntos *fuzzy* permitem uma pertinência parcial, com um grau específico entre 0 e 1. O universo do discurso é essencial nessa modelagem, pois define o domínio de todos os valores possíveis que a variável pode assumir. Por exemplo, ao modelar a temperatura ambiente como

uma variável *fuzzy*, o universo do discurso incluiria todas as temperaturas possíveis em um determinado contexto.

Outro conceito fundamental relacionado às variáveis *fuzzy* é o de termos linguísticos, que são rótulos escolhidos a partir da linguagem natural, como “baixo”, “médio” e “alto”. Cada termo linguístico está associado a um conjunto *fuzzy*, que descreve como os valores da variável se enquadram nesses termos. Esses conjuntos são caracterizados por funções de pertinência que atribuem um grau de pertinência a cada valor da variável.

A Figura 4 ilustra uma variável *fuzzy* com um universo do discurso que varia de 0 a 10 no eixo x. Essa variável é composta por três termos linguísticos: “baixo”, com parâmetros 0, 2, 5; “médio”, com parâmetros 2, 5, 8; e “alto”, com parâmetros 5, 8, 10.

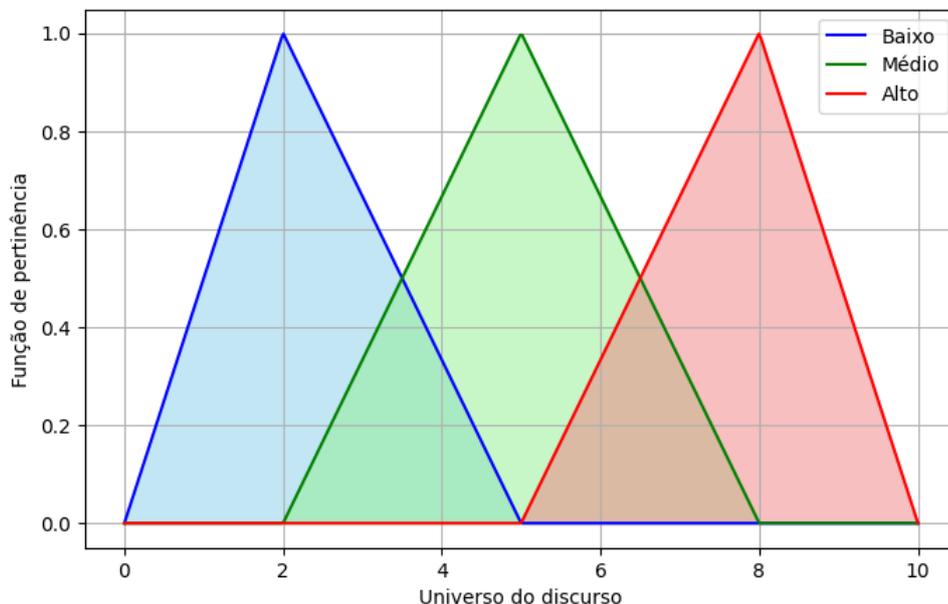


Figura 4 – Universo do discurso.
Fonte: o autor (2023)

Vários componentes de um sistema de elétrico podem ser modeladas usando conjuntos *fuzzy*. Como exemplos podem ser citados:

1. Demanda de Energia: A demanda de energia elétrica é uma variável que pode ser modelada como *fuzzy*, uma vez que varia ao longo do tempo de maneira contínua e pode ser afetada por vários fatores. Ibrahim *et al.* (IBRAHIM *et al.*, 2023) apresentam um sistema de gerenciamento de energia que modela quatro parâmetros como a horário do dia, o custo dinâmico diário de energia, o status da bateria fotovoltaica e a potência da rede como entrada para a tomada de decisão que garanta o melhor mix energético entre custo de energia e desempenho do sistema;

2. Níveis de Tensão: Os níveis de tensão em diferentes pontos do sistema de potência podem ser modelados como variáveis *fuzzy* (USIDA, 2007). A incerteza nas cargas e nas condições de operação pode levar a variações nos níveis de tensão. Modelar esses níveis como conjuntos *fuzzy* permite uma representação mais flexível da incerteza associada;
3. Condições Operacionais: As condições operacionais de equipamentos, como transformadores, linhas de transmissão e geradores, podem ser modeladas como variáveis *fuzzy* (GIL et al., 2023). Isso é útil para lidar com a incerteza nas características físicas e nas condições de carga;
4. Qualidade de Energia: Parâmetros relacionados à qualidade de energia, como distorção harmônica, variação de frequência e fator de potência, podem ser modelados como conjuntos *fuzzy* para lidar com a variabilidade e incerteza nessas grandezas (BRANCO, 2009).

3.1.2 Funções de pertinência e sua tipologia

Uma função de pertinência é utilizada para quantificar o grau de pertencimento de elementos a um conjunto *fuzzy*. Denotada geralmente por $\mu_A(x)$, essa função atribui a cada elemento x do universo do discurso um valor numérico no intervalo $[0, 1]$. Esse valor representa o grau de pertinência de x ao conjunto *fuzzy* A , onde 0 indica que o elemento não pertence ao conjunto, 1 indica pertencimento completo, e valores intermediários indicam graus parciais de pertencimento.

Ao contrário dos conjuntos clássicos, que só permitem a associação binária (pertence ou não pertence), a função de pertinência permite uma representação mais flexível e realista de situações onde a transição entre estados é gradual. Por exemplo, ao modelar a noção de “temperatura alta”, a função de pertinência permite definir de forma contínua e suave como diferentes valores de temperatura (como 25°C, 30°C, 35°C, etc.) pertencem ao conjunto “alta”, capturando nuances que são ignoradas por abordagens tradicionais.

As funções de pertinência podem assumir várias formas, dependendo da aplicação e do contexto em que são utilizadas. Os tipos mais comuns incluem as funções triangular, trapezoidal, gaussiana e sigmoideal. Cada tipo de função de pertinência oferece um grau diferente de flexibilidade e é escolhido com base nas características específicas do problema que se deseja modelar.

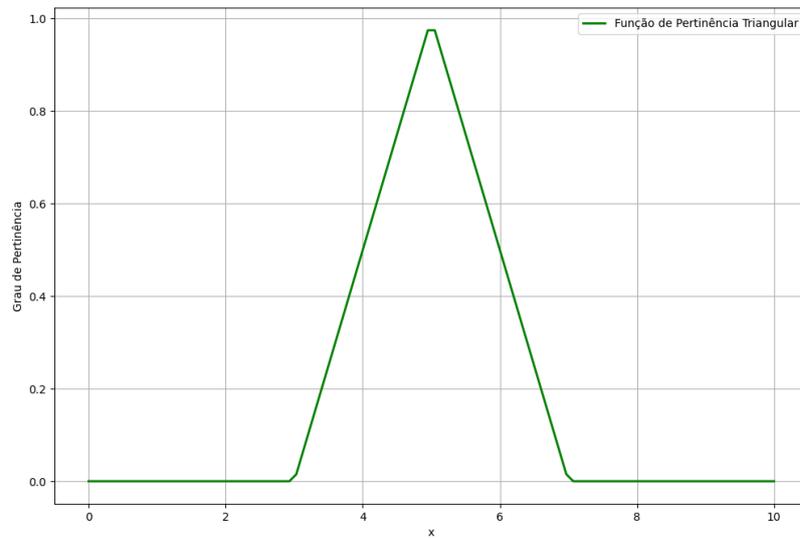


Figura 5 – Função triangular.
Fonte: o autor (2023)

1. Triangular:

a) *Definição*: A função de pertinência triangular, ilustrada na Figura 5 é definida por uma forma triangular, caracterizada por ser linear em ambos os lados do pico.

b) *Equação*:

$$\text{trimf}(x; a; b; c) = \max\left(\min\left(\frac{x - a}{b - a}, \frac{c - x}{b - x}\right), 0\right) \quad (3.1)$$

c) *Parâmetros*: a , b , e c . Estes são os três pontos que definem a base e o pico do triângulo. a e c são os pontos extremos da base do triângulo, onde a pertinência é nula, enquanto b é o ponto onde a pertinência atinge o valor máximo.

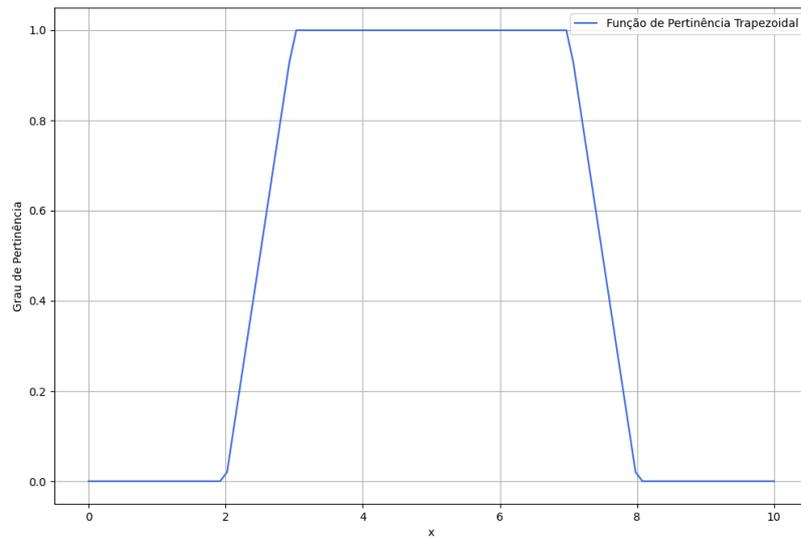


Figura 6 – Função trapezoidal.
Fonte: o autor (2023)

2. Trapezoidal:

a) *Definição*: A função trapezoidal ilustrada na Figura 6 é semelhante à triangular, mas com uma parte superior plana.

b) *Equação*:

$$\text{trapmf}(x; a; b; c; d) = \max\left(\min\left(\frac{x - a}{b - a}, 1, \frac{d - x}{d - c}\right), 0\right) \quad (3.2)$$

c) *Parâmetros*: a , b , c , e d . Esses pontos definem os vértices do trapézio. Os pontos a e d são os extremos da base, onde a pertinência é nula, enquanto b e c são os pontos onde a pertinência atinge o valor máximo.

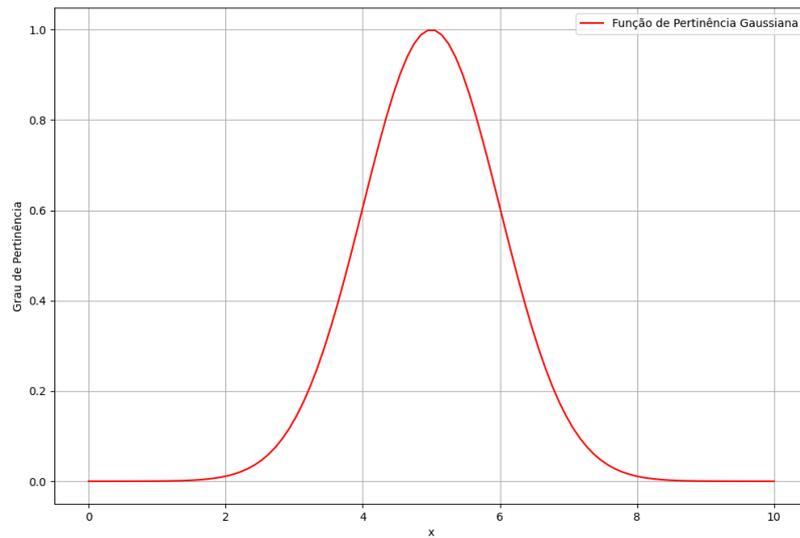


Figura 7 – Função gaussiana.
Fonte: o autor (2023)

3. Gaussiana:

a) *Definição*: A função gaussiana definida na Figura 7 tem uma forma de sino simétrica e é suave em toda a sua extensão.

b) *Equação*:

$$Gaussmf(x; a; b; c) = e^{-1/2 \left(\frac{x - c}{\sigma}\right)^2} \quad (3.3)$$

c) *Parâmetros*: μ (média) e σ (desvio padrão). A média determina o centro da curva, enquanto o desvio padrão controla a largura da “sino”.

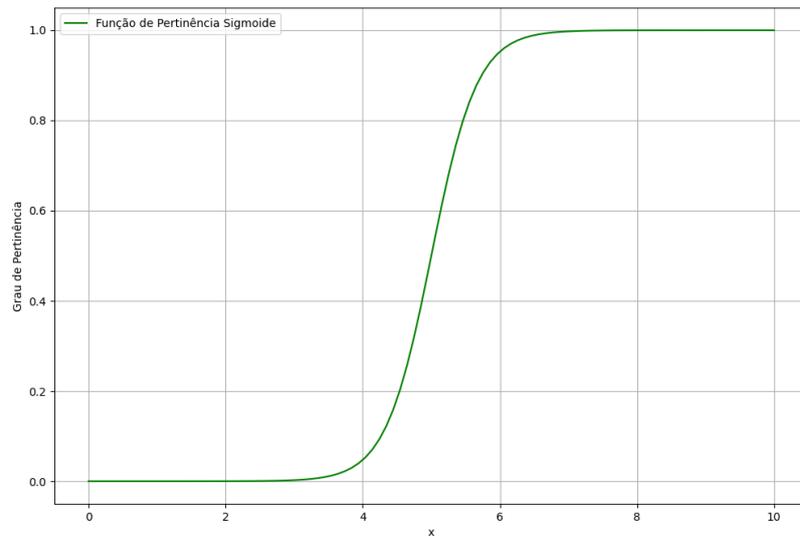


Figura 8 – Função sigmoide.
Fonte: o autor (2023)

4. Sigmoide:

a) *Definição*: A função sigmoide definida na Figura 8 tem uma forma de “S” e é útil para representar transições graduais entre dois estados.

b) *Equação*:

$$\text{Sigm}f(x; \text{mean}; \text{sigma}) = \frac{1}{1 + e^{-a(x-c)}} \quad (3.4)$$

c) *Parâmetros*: a e c . O parâmetro a controla a inclinação da curva, enquanto c é o valor de x onde a função é igual a 0,5 (ponto médio da transição).

Segundo (JANG; SUN; MIZUTANI, 1997), além das funções de pertinência mais comuns como a triangular, trapezoidal, gaussiana e sigmoide, outras funções de pertinência também são amplamente utilizadas na lógica *fuzzy*, cada uma com características distintas que as tornam adequadas para modelar diferentes cenários.

A função de pertinência em formato de sino é caracterizada por uma curva suavemente arredondada, que permite controlar de maneira flexível a largura e a forma da curva. Ela é definida por três parâmetros principais: o centro da curva, sua inclinação e a largura da base, o que a torna útil para representar variáveis cujo comportamento é simétrico em torno de um ponto central.

A função de pertinência tipo S é utilizada para modelar conceitos que possuem dois extremos bem definidos, como uma transição gradual de “baixo” para “alto” ao longo de uma

escala. Sua curva tem o formato da letra “S” e é ideal para representar transições suaves e graduais em sistemas *fuzzy*.

A função de pertinência tipo Z é semelhante à função tipo S, mas com o comportamento inverso, sendo usada para modelar conceitos que diminuem gradualmente. Sua curva em forma de “Z” representa uma transição de um “alto” para um “baixo”, com uma inclinação suave, sendo particularmente útil para modelar a saída de um sistema à medida que uma variável diminui.

Por fim, a função de pertinência gaussiana de duas caudas é uma variação da função gaussiana tradicional, com dois picos de probabilidade. Essa função permite modelar fenômenos que apresentam duas zonas de maior relevância ou frequência, sendo frequentemente aplicada em sistemas que requerem uma modelagem mais detalhada de extremos.

3.1.3 Operadores lógicos

As operações entre conjuntos *fuzzy* são um componente fundamental da teoria dos conjuntos *fuzzy*, que é uma extensão da teoria dos conjuntos clássicos. Os conjuntos *fuzzy* permitem representar a incerteza e a imprecisão em diferentes áreas, como lógica, controle de sistemas, inteligência artificial, entre outros. As operações básicas entre conjuntos *fuzzy* incluem a união, a interseção e a complementação.

3.1.3.1 União (OU)

A união de dois conjuntos *fuzzy*, A e B, é denotada por $A \cup B$ e é definida em termos da função de pertinência, que atribui a cada elemento de um universo de discurso um valor que representa o grau de pertinência desse elemento ao conjunto *fuzzy*.

Para a união *fuzzy*, o grau de pertinência do elemento em $A \cup B$ é o máximo dos graus de pertinência nos conjuntos A e B para esse elemento (KLIR; YUAN, 1995).

$$\mu(A \cup B)(x) = \max(\mu A(x), \mu B(x)) \quad (3.5)$$

3.1.3.2 *Intersecção (E)*

A intersecção de dois conjuntos *fuzzy*, A e B , é denotada por $A \cap B$. Similar à união, a intersecção é definida em termos da função de pertinência. Na intersecção *fuzzy*, o grau de pertinência do elemento em $A \cap B$ é o mínimo dos graus de pertinência nos conjuntos A e B para esse elemento. Essa operação é um caso específico de uma t-norma (MAMDANI, 1974), que é uma função utilizada para generalizar a intersecção de conjuntos *fuzzy*. Assim, temos:

$$\mu(A \cap B)(x) = \min(\mu_A(x), \mu_B(x)) \quad (3.6)$$

3.1.3.3 *Complemento (\neg)*

O operador de complemento (\neg) é utilizado para encontrar o conjunto *fuzzy* que contém elementos que não pertencem a um determinado conjunto *fuzzy*. Na lógica *fuzzy*, o complemento é frequentemente utilizado para modelar a negação. Se um conjunto *fuzzy* A representa uma condição, então o complemento de A representa a negação dessa condição. Isso é útil ao criar regras *fuzzy* que envolvem a exclusão de certas condições.

O complemento de um conjunto *fuzzy* é denotado por $\neg A$ e é definido como:

$$\mu_{\neg A}(x) = 1 - \mu_A(x) \quad (3.7)$$

, onde $\mu_A(x)$ é o grau de pertinência de x em A .

É importante destacar que segundo (KLIR; YUAN, 1995), existem outras formas de realizar a união e a intersecção de conjuntos *fuzzy* além das operações clássicas de máximo e mínimo. Para a união, essas operações alternativas incluem a soma algébrica, a soma limitada e a união drástica, que permitem combinar conjuntos de maneira mais flexível dependendo do contexto. Da mesma forma, para a intersecção, existem operações como o produto algébrico, o produto limitado e a intersecção drástica. Essas operações oferecem diferentes abordagens para modelar a sobreposição ou a combinação de conjuntos *fuzzy*, proporcionando maior adaptabilidade e precisão na modelagem de sistemas complexos.

3.1.4 Propriedades Algébricas

Ao aplicar as definições de união e interseção, que são operacionalizadas pelos operadores de máximo e mínimo, bem como a operação de complemento, observa-se que propriedades algébricas similares às dos conjuntos clássicos se mantêm nos conjuntos *fuzzy*:

Involução:

$$(\complement A)^{\complement} = A \quad (3.8)$$

onde \complement indica o complemento de um conjunto fuzzy.

Idempotência:

$$A \cap A = A \quad (3.9)$$

$$A \cup A = A \quad (3.10)$$

Comutatividade:

$$A \cap B = B \cap A \quad (3.11)$$

$$A \cup B = B \cup A \quad (3.12)$$

Associatividade:

$$(A \cap B) \cap C = A \cap (B \cap C) \quad (3.13)$$

$$(A \cup B) \cup C = A \cup (B \cup C) \quad (3.14)$$

Distributividade:

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C) \quad (3.15)$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C) \quad (3.16)$$

Transitividade:

$$\text{se } A \subseteq B \text{ e } B \subseteq C, \text{ então } A \subseteq C \quad (3.17)$$

Considerando que as funções de pertinência para os conjuntos vazio e universal são definidas como 0 e 1 em todo o universo U , respectivamente, tem-se que as propriedades a seguir também são satisfeitas:

$$A \cap \emptyset = \emptyset \quad (3.18)$$

$$A \cap U = A \quad (3.19)$$

$$A \cup \emptyset = A \quad (3.20)$$

$$A \cup U = U \quad (3.21)$$

As seguintes propriedades dos conjuntos clássicos não se aplicam aos conjuntos *fuzzy* quando se usa os operadores max e min:

$$A \cap \complement A \neq \emptyset \quad (3.22)$$

$$A \cup \complement A \neq U \quad (3.23)$$

3.2 RELAÇÃO FUZZY

No contexto das relações *fuzzy*, o conceito de relação é formalizado matematicamente com base na teoria dos conjuntos. Isso implica que é possível pensar intuitivamente em uma relação como sendo “*fuzzy*” quando optamos pela teoria dos conjuntos *fuzzy*, e como sendo “clássica” quando utilizamos a teoria clássica de conjuntos para definir a relação em questão. A escolha entre esses dois modelos depende do fenômeno que está sendo estudado. No entanto, a opção pela teoria dos conjuntos *fuzzy* é geralmente mais robusta, pois ela inclui a teoria clássica de conjuntos como um caso especial.

3.2.1 relações clássicas

Uma relação (clássica) R sobre o produto cartesiano $U_1 \times U_2 \times \dots \times U_n$ é um subconjunto (clássico) desse produto cartesiano, onde “ n ” representa o número de conjuntos envolvidos no produto cartesiano. Especificamente, n é um inteiro positivo que indica a quantidade de conjuntos U_i utilizados na formação do produto cartesiano. Se este produto cartesiano for formado por apenas dois conjuntos, $U_1 \times U_2$, a relação é denominada binária. Quando todos os conjuntos U_1, U_2, \dots, U_n são iguais, a relação R é descrita como uma relação n -ária sobre U . As relações clássicas podem ser representadas por meio de uma função característica $\chi_R : U_1 \times U_2 \times \dots \times U_n \rightarrow \{0, 1\}$, onde $\chi_R(x_1, x_2, \dots, x_n)$ é igual a 1 se (x_1, x_2, \dots, x_n) pertence a R e igual a 0 se (x_1, x_2, \dots, x_n) não pertence a R .

3.2.2 Relações Fuzzy

Uma relação *fuzzy* R sobre o produto cartesiano $U_1 \times U_2 \times \dots \times U_n$ é um subconjunto *fuzzy* desse produto cartesiano. Quando o produto cartesiano é formado por apenas dois conjuntos, $U_1 \times U_2$, chamamos a relação de binária *fuzzy* sobre $U_1 \times U_2$. Assim, uma relação *fuzzy* é definida por meio de uma função de pertinência $\phi_R : U_1 \times U_2 \times \dots \times U_n \rightarrow [0, 1]$. A principal vantagem da abordagem *fuzzy* é que ela não apenas indica a presença ou ausência de uma relação, mas também fornece informações sobre o grau ou intensidade dessa relação.

O produto cartesiano *fuzzy* $A_1 \times A_2 \times \dots \times A_n$ de subconjuntos *fuzzy* A_1, A_2, \dots, A_n de U_1, U_2, \dots, U_n é caracterizado pela função de pertinência associada à relação *fuzzy* R sobre $A_1 \times A_2 \times \dots \times A_n$, que é definida como:

$$\phi_R(x_1, x_2, \dots, x_n) = \phi_{A_1}(x_1) \wedge \phi_{A_2}(x_2) \wedge \dots \wedge \phi_{A_n}(x_n). \quad (3.24)$$

Nessa definição, a operação \wedge representa a t-norma "min", ou seja, $\phi_{A_1}(x_1) \wedge \phi_{A_2}(x_2) = \min(\phi_{A_1}(x_1), \phi_{A_2}(x_2))$.

3.2.3 Composição de Relações Fuzzy

A composição de relações é fundamental em sistemas de inferência *Fuzzy*. Ela combina duas ou mais relações, utilizando um conjunto em comum. No caso das relações clássicas, a composição é representada por operações como max-min ou max-produto. A composição *fuzzy* segue a mesma lógica, mas usa funções de pertinência, e a t-norma (min ou produto) é aplicada.

Dadas duas relações *fuzzy* binárias, R e S , em $U \times V$ e $V \times W$, respectivamente, a composição $R \circ S$ é uma relação *fuzzy* binária em $U \times W$, cuja função de pertinência é definida como:

$$\phi_{R \circ S}(u, w) = \max_{v \in V} [\min(\phi_R(u, v), \phi_S(v, w))] \quad (3.25)$$

onde:

$$\phi_R(u, v) = \phi_U(u) \wedge \phi_V(v) \quad (3.26)$$

e

$$\phi_S(v, w) = \phi_V(v) \wedge \phi_W(w) \quad (3.27)$$

Aqui, \wedge representa uma t-norma.

3.2.4 Regra Composicional de Inferência

A Regra Composicional de Inferência em lógica *fuzzy* descreve como a inferência é realizada em sistemas *fuzzy* quando uma regra “SE X é A, ENTÃO Y é B” é aplicada. Existem diferentes métodos de inferência, alguns dos métodos mais comuns são o método de implicação de Mamdani e o de Larsen.

1. Método de Implicação de Mamdani: Proposto por Mamdani, este é um dos métodos mais comuns e intuitivos. Ele utiliza operadores de mínimo “min” para a agregação das regras e o cálculo da implicação. Ele é expresso da seguinte maneira:

$$\mu_{\text{Conclusão}(y)} = \min(\mu_A(x), \mu_B(y)) \quad (3.28)$$

Nesta fórmula: - $\mu_{\text{Conclusão}(y)}$ é a função de pertinência resultante no conseqüente Y. - $\mu_A(x)$ é a função de pertinência do antecedente X. - $\mu_B(y)$ é a função de pertinência do conseqüente Y.

Essa fórmula calcula a função de pertinência resultante no conseqüente Y usando o mínimo “min” das funções de pertinência do antecedente X e do conseqüente Y. Isso significa que a função de pertinência resultante é a menor das duas funções de pertinência.

2. Método de Larsen: Proposto por Robert Larsen, este método é similar ao Mamdani, mas usa o produto em vez do mínimo para a operação de implicação. Isto é, a saída *fuzzy* de cada regra é o produto da função de pertinência da entrada e da função de pertinência da saída da regra. Pode ser expresso da seguinte maneira:

$$\mu_{\text{Conclusão}(y)} = \mu_A(x) \cdot \mu_B(y) \quad (3.29)$$

Nesta fórmula: - $\mu_{\text{Conclusão}(y)}$ é a função de pertinência resultante no conseqüente Y. - $\mu_A(x)$ é a função de pertinência do antecedente X. - $\mu_B(y)$ é a função de pertinência do conseqüente Y.

Essa fórmula calcula a função de pertinência resultante no conseqüente Y multiplicando as funções de pertinência do antecedente X e do conseqüente Y.

3.3 REGRA FUZZY E SUA ESTRUTURA

Uma regra *fuzzy* é uma proposição na forma “Se X é A , então Y é B ”, onde A e B são conjuntos *fuzzy* em X e Y , respectivamente. Essa regra pode ser entendida como uma relação *fuzzy* R entre A e B , cuja função de pertinência $\phi_R(x, y)$ depende das funções de pertinência $\phi_A(x)$ e $\phi_B(y)$ para cada par (x, y) pertencente ao conjunto $X \times Y$. Neste contexto, utiliza-se a função mínimo para essa dependência, ou seja,

$$\phi_R(x, y) = \phi_A(x) \wedge \phi_B(y). \quad (3.30)$$

Dessa forma, podemos representar R como o produto cartesiano $A \times B$. Essa foi a abordagem proposta por Mamdani para expressar a regra “Se X é A , então Y é B ”. Na teoria de raciocínio aproximado, essas proposições são modeladas por meio de implicações *fuzzy*.

Em um sistema baseado em regras *fuzzy*, a entrada é avaliada em termos de seu grau de pertinência (μ) aos conjuntos *fuzzy* definidos. Este grau de pertinência determina o grau de ativação de uma regra *fuzzy*.

1. **Grau de Pertinência:** É uma medida que indica quão bem uma entrada específica (como a temperatura em um termostato) corresponde a um conjunto *fuzzy* definido (como “quente” ou “frio”). Por exemplo, $\mu_A(x')$ é o grau de pertinência da entrada x' no conjunto *fuzzy* A .
2. **Ativação de Regras:** Quanto maior o grau de pertinência de uma entrada em relação ao antecedente (a parte “se” de uma regra), maior é a ativação dessa regra. Se $\mu_A(x') = 1$, isso indica uma compatibilidade total com o conjunto A , e o conseqüente (a parte “então” da regra) é totalmente aplicado.

3.4 ETAPAS DE UM SISTEMA FUZZY

Conforme a Figura 9, um sistema *fuzzy* possui um processo com algumas etapas essenciais para sua operação. Estas etapas permitem que o sistema lide com informações imprecisas ou incertas e forneça uma saída que imita a tomada de decisão humana. A seguir, cada uma dessas etapas será descrita detalhadamente:

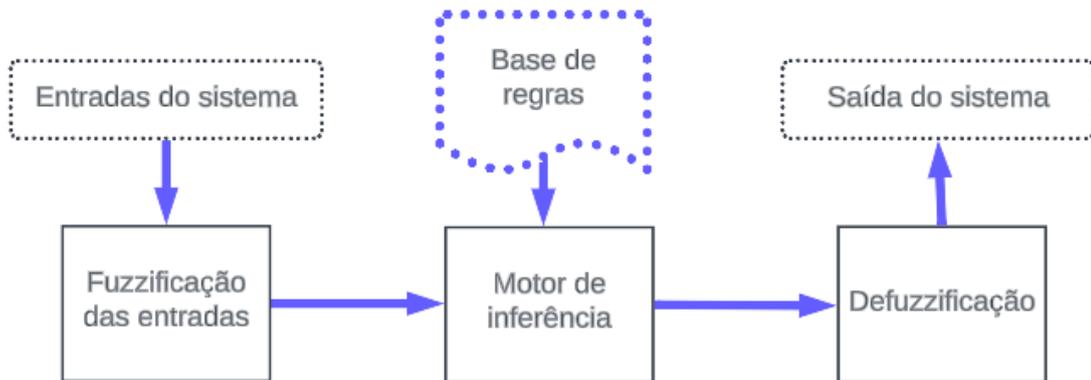


Figura 9 – Etapas de um sistema *fuzzy*.

3.4.1 Fuzzificação

O processo de fuzzificação é uma etapa fundamental em sistemas de lógica *fuzzy*, responsável por transformar entradas “*crisp*” (ou seja, valores precisos e não *fuzzy*) em valores *fuzzy* que podem ser processados pelo sistema. Este processo é essencial em qualquer aplicação de lógica *fuzzy*, como controle *fuzzy*, tomada de decisão e análise de sistemas.

A fuzzificação permite que sistemas de lógica *fuzzy* lidem com incertezas e ambiguidades inerentes em muitos processos do mundo real. Aqui está uma visão geral do processo de fuzzificação:

1. **Definição de Conjuntos *Fuzzy* e Funções de Pertinência:** Antes de começar a fuzzificação, é necessário definir conjuntos *fuzzy* e suas respectivas funções de pertinência. Essas funções, que podem ser de várias formas (como triangular, trapezoidal, gaussiana, etc.), determinam o grau de pertinência de uma entrada a um conjunto *fuzzy*.
2. **Conversão de Entradas *Crisp* em *Fuzzy*:** No processo de fuzzificação, valores de entrada “*crisp*” são convertidos em graus de pertinência *fuzzy*. Por exemplo, se a temperatura é uma entrada e os conjuntos *fuzzy* são “baixo”, “médio” e “alto”, a fuzzificação determinará o grau de pertinência da temperatura atual a cada um desses conjuntos.
3. **Determinação de Graus de Pertinência:** Para cada conjunto *fuzzy*, a função de pertinência correspondente é aplicada à entrada para calcular o grau de pertinência. Por exemplo, uma temperatura de 25°C pode pertencer ao conjunto “médio” com um grau de pertinência de 0.7 e ao conjunto “alto” com um grau de 0.3.
4. **Uso em Regras *Fuzzy*:** Os graus de pertinência resultantes são então usados nas regras

fuzzy do sistema. Estas regras são tipicamente formuladas no formato “SE-ENTÃO” e determinam a saída do sistema com base nas entradas fuzzificadas.

3.4.2 Defuzzificação

A defuzzificação é um processo crucial em sistemas de lógica *fuzzy*, e ocorre após a etapa de inferência *fuzzy*. Enquanto a fuzzificação converte entradas precisas em valores *fuzzy* para processamento, a defuzzificação faz o inverso, convertendo a saída *fuzzy* resultante em um valor preciso e acionável.

A defuzzificação é necessária porque, embora a lógica *fuzzy* seja excelente para lidar com incertezas e fornecer uma saída baseada em regras *fuzzy*, os sistemas do mundo real frequentemente exigem uma saída clara e definitiva. Por exemplo, um sistema de controle de tensão em uma rede elétrica precisa de um valor específico de tensão para ajustar seus reguladores.

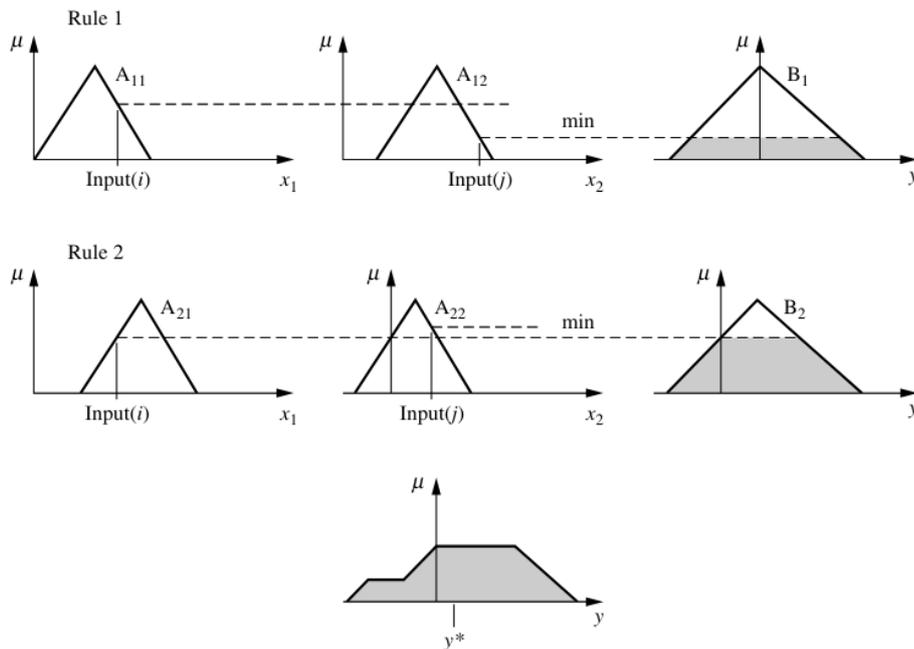


Figura 10 – Método de inferência com duas regras.
Fonte: (ROSS, 2004)

Na Figura 10 é ilustrado o processo de defuzzificação de um sistema *fuzzy* de duas regras, onde os símbolos A_{11} e A_{12} referem-se ao primeiro e segundo antecedentes *fuzzy* da primeira regra, respectivamente, e o símbolo B_1 refere-se ao conseqüente *fuzzy* da primeira regra; os símbolos A_{21} e A_{22} referem-se ao primeiro e segundo antecedentes *fuzzy*, respectivamente, da segunda regra, e o símbolo B_2 refere-se ao conseqüente *fuzzy* da segunda regra.

A operação de mínimo é usada porque os pares de antecedentes dados, na estrutura geral de regra deste sistema, estão conectados por um conectivo lógico “AND”. O valor mínimo de pertinência dos antecedentes é propagado até o conseqüente, truncando a função de pertinência do conseqüente em cada regra. Esse processo de inferência é aplicado a cada regra individualmente. Posteriormente, as funções de pertinência truncadas de todas as regras são agregadas, resultando em uma função de pertinência agregada que é composta pelo envelope externo das formas de pertinência truncadas de cada regra.

Para determinar um valor crisp para a saída agregada, um método de defuzzificação é empregado sobre a função de pertinência agregada. O resultado desse processo é representado por um valor como y^* , conforme ilustrado na Figura 10.

3.4.2.1 Métodos de Defuzzificação

1. Centróide (CEN):

É o método mais comumente utilizado. Calcula o valor que seria o centro de gravidade se a área sob a curva da função de saída *fuzzy* fosse um objeto físico. Este método é bem equilibrado e fornece um resultado que considera todas as possíveis saídas *fuzzy*.

$$CEN = \frac{\sum_{i=1}^N \mu(x_i) \cdot x_i}{\sum_{i=1}^N \mu(x_i)} \quad (3.31)$$

2. Bissetriz da Área (BA):

O método do bissetor encontra o ponto no universo de discurso que divide a área sob a curva de pertinência do conjunto *fuzzy* resultante em duas partes iguais. Este método tenta encontrar um equilíbrio justo entre os valores possíveis, considerando a distribuição de massa do conjunto *fuzzy*.

O bissetor é calculado encontrando um ponto x_b tal que:

$$BA = \sum_{x \leq x_b} \mu(x) = \sum_{x \geq x_b} \mu(x) \quad (3.32)$$

Essa fórmula equilibra as áreas sob a curva de pertinência à esquerda e à direita do ponto x_b , efetivamente dividindo a área em duas partes iguais.

3. Primeiro dos Máximos (PDM): Este método foca nos valores máximos dos conjuntos de saída *fuzzy*. Entre todos os máximos identificados no conjunto *fuzzy* de saída, o método seleciona o menor desses máximos como o valor de defuzzificação.

$$PDM = \min\{x | \mu_A(x) = \max \mu_A(x)\} \quad (3.33)$$

4. Média dos máximos (MDM): Calcula a média dos valores máximos da função de saída *fuzzy*. Este método é simples e útil quando a saída *fuzzy* é relativamente simétrica.

$$MDM = \frac{\sum_{i=1}^M x_{max,i}}{M} \quad (3.34)$$

5. Último dos Máximos (UDM): Escolhe o valor máximo da função de saída *fuzzy*. Pode ser útil em sistemas onde a decisão mais extrema é preferível.

$$UDM = \max\{x_i | \mu(x_i) = \max(\mu(x_i))\} \quad (3.35)$$

Em sistemas elétricos de potência, a escolha do método de defuzzificação pode ter um impacto significativo na resposta do sistema. O método Centro de Gravidade, por exemplo, é preferível quando uma resposta equilibrada e bem ponderada é necessária, enquanto a Média dos Máximos pode ser mais adequada para situações em que a saída é relativamente uniforme ou simétrica. A escolha do método adequado depende da natureza específica do sistema e do problema em questão, bem como das características das funções de pertinência utilizadas.

3.5 MÉTODOS DE SISTEMAS FUZZY

Os métodos Mamdani e Sugeno são duas abordagens fundamentais na teoria de conjuntos *fuzzy*, utilizadas para processar informações e tomar decisões em sistemas de lógica *fuzzy*.

3.5.1 Método Mamdani

Desenvolvido por Ebrahim Mamdani em 1975 (MAMDANI, 1974), é amplamente empregado na inferência de sistemas *fuzzy*, especialmente em aplicações de controle onde as variáveis são contínuas. Este método utiliza regras “SE-ENTÃO” com termos linguísticos e emprega operações de “min” para calcular a implicação. A defuzzificação é comumente realizada pelo método do centroide, transformando a saída *fuzzy* em um valor numérico. Sua simplicidade e interpretação intuitiva tornam o método Mamdani particularmente adequado para situações onde a lógica dos especialistas e a compreensão humana são prioritárias.

3.5.2 Método Sugeno

O método Sugeno, desenvolvido por Michio Sugeno em 1985 (TAKAGI; SUGENO, 1985), é uma técnica eficiente para sistemas de controle e modelagem, onde as regras “SE-ENTÃO” produzem saídas numéricas diretas através de funções matemáticas, geralmente lineares ou constantes. Embora essa abordagem ofereça vantagens como eficiência computacional e facilidade na defuzzificação, ela apresenta algumas limitações, especialmente quando comparada ao método Mamdani.

O método Mamdani, optado por sua abordagem intuitiva e facilidade de interpretação, se destaca onde o Sugeno pode ter desvantagens. Primeiramente, o método Mamdani é altamente intuitivo e fácil de entender, o que o torna alinhado com a lógica e o conhecimento de especialistas. Em contraste, o método Sugeno, embora eficiente, pode ser menos intuitivo devido à sua natureza matemática e menos direto para quem procura uma interpretação linguística das regras *fuzzy*.

Além disso, o método mamdani é particularmente robusto e menos sensível a variações nos dados de entrada, tornando-o mais adequado para ambientes incertos ou não estruturados. Em contrapartida, o método Sugeno, com sua ênfase em funções matemáticas para a saída das regras, pode não ser tão flexível ou robusto em cenários onde a precisão linguística e a robustez são mais críticas do que a pura eficiência computacional e a precisão numérica.

Essas diferenças tornam o método Mamdani mais apropriado para situações em que a interpretação linguística e a robustez são essenciais, enquanto o método Sugeno pode ser preferível em aplicações que demandam alta eficiência computacional e onde as saídas podem ser adequadamente representadas por modelos matemáticos.

4 METODOLOGIA PROPOSTA

4.1 VISÃO GERAL DA METODOLOGIA PROPOSTA

A metodologia proposta foi desenvolvida de forma modular para permitir a manipulação de suas funcionalidades de maneira isolada sem prejudicar a conexão entre os módulos, conforme ilustrado na Figura 11.

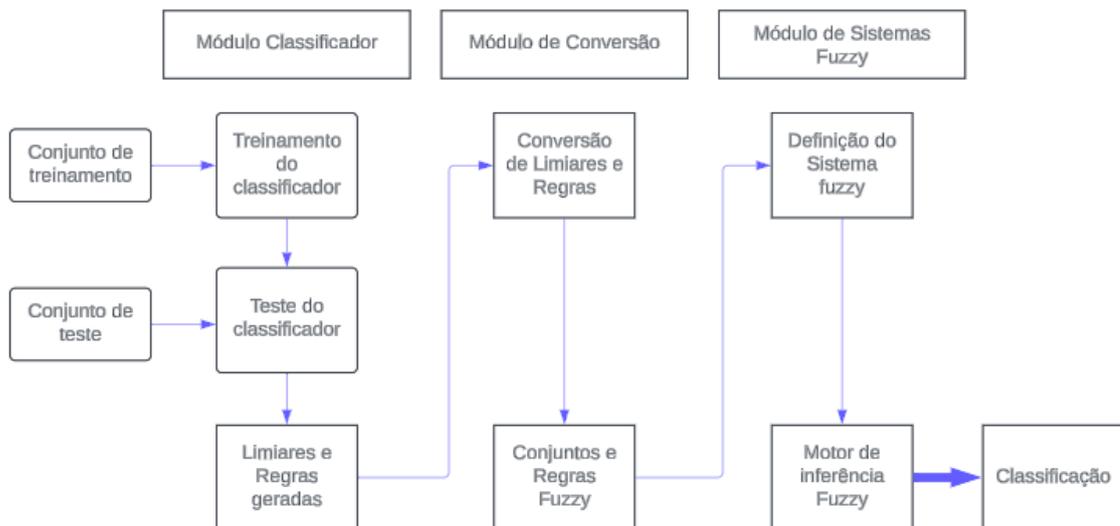


Figura 11 – Visão geral da metodologia.

Esta seção descreve detalhadamente os três módulos principais do sistema: o Módulo Classificador, o Módulo de Conversão e o Módulo de Sistemas *Fuzzy*. Cada módulo desempenha um papel fundamental no processamento, análise e visualização de dados.

1. Módulo Classificador: classifica o estado atual do sistema fornecendo os limiares para variáveis e as regras de decisão;
2. Módulo de Conversão: permite a conversão de limiares *crisp* em conjuntos *fuzzy* e a partir deles a conversão de regras *crisp* em regras *fuzzy*;
3. Módulo de Sistemas *Fuzzy*: permite o uso das regras *fuzzy* geradas em um mecanismo de inferência para classificação *fuzzy*.

Cada módulo é equipado com funcionalidades para a criação, edição e remoção de seus componentes, sejam limiares, conjuntos, regras, esquemas, proporcionando uma manipulação eficiente e simplificada dos elementos que constituem o módulo. Estas ferramentas foram

projetadas para otimizar a interação do usuário com o módulo, tornando o processo mais ágil.

Após uma visão geral da metodologia proposta, o funcionamento de cada módulo componente será abordado.

4.2 MÓDULO CLASSIFICADOR

O Módulo Classificador tem como objetivo criar uma base de regras de decisão a partir do treinamento e teste de um algoritmo baseado em árvore de decisão.

A escolha de uma árvore de Decisão para este módulo é motivada pela sua capacidade de gerar regras que podem ser interpretadas. Este modelo é capaz de identificar padrões e relações significativas em grandezas elétricas, facilitando a interpretação das características elétricas complexas e o diagnóstico de condições operacionais.

4.2.1 Estrutura do módulo e funcionamento

O processo de treinamento, teste e geração de regras completas em uma árvore de decisão para classificação envolve várias etapas. Nesta seção será detalhado o processo, desde o treinamento até a chegada em uma regra completa para uma classe.

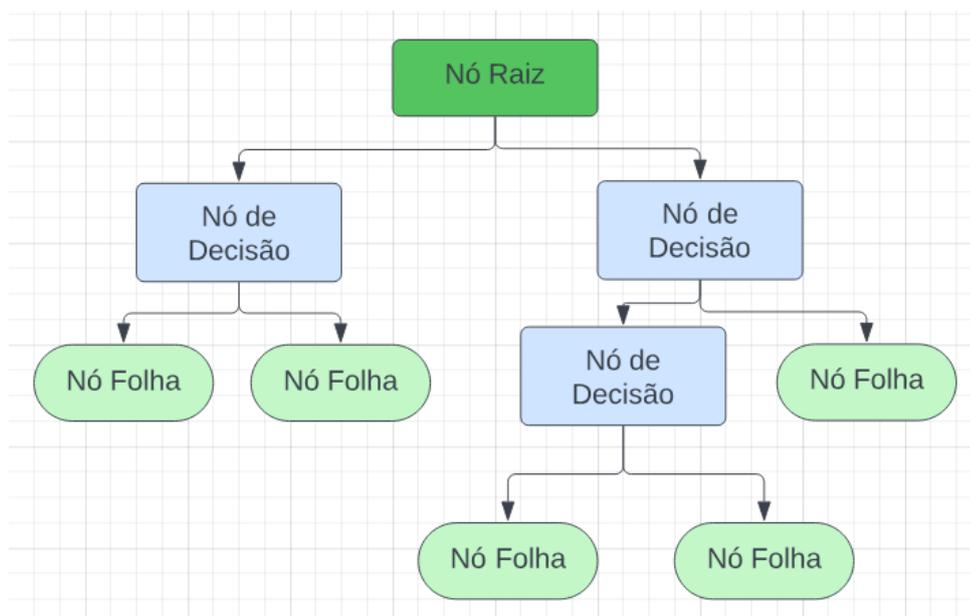


Figura 12 – Árvore de decisão.

4.2.1.1 Preparação dos dados

Antes do treinamento, os dados são preparados, o que pode incluir organização, limpeza e transformação dos dados brutos em um formato adequado para análise e modelagem.

4.2.1.2 Treinamento da Árvore de Decisão

Como ilustrado na Figura 12, o algoritmo de árvore de decisão analisa todas as possíveis divisões baseadas nos valores dos atributos dos dados. Para atributos numéricos, as divisões podem ser feitas com base em um valor limiar; para atributos categóricos, as divisões são feitas com base na pertença a diferentes categorias.

Cada divisão potencial é avaliada utilizando uma métrica específica, como a impureza de Gini, a entropia, ou alguma função de perda específica do problema. A divisão que mais reduz a impureza ou oferece o maior ganho de informação é selecionada para ser implementada no nó.

O processo de escolha da melhor divisão é repetido para cada novo subnó até que se atinja uma condição de parada, como um nó contendo exemplos de uma única classe, a ausência de ganho adicional, atingimento de uma profundidade máxima, ou um número mínimo de exemplos no nó.

4.2.1.3 Poda da Árvore

Após o treinamento, a árvore pode ser podada para evitar *overfitting*. A poda remove partes da árvore (subárvores) que fornecem pouco poder preditivo adicional, simplificando o modelo final. Isso pode ser feito através de técnicas de pré-poda, que limitam a construção da árvore, ou de pós-poda, como a poda por custo-complexidade, que remove nós após a árvore estar completamente construída baseada em uma análise de custo-benefício do erro de classificação versus complexidade da árvore.

4.2.1.4 Teste do Modelo

O modelo treinado e podado é então testado usando o conjunto de dados de teste, que não foi visto pelo modelo durante o treinamento. Isso fornece uma estimativa de como o modelo

provavelmente se comportará em dados não vistos. O desempenho é avaliado usando métricas como acurácia, precisão, sensibilidade e F1-Score.

4.2.1.5 Geração de Regras

Uma vez que o modelo está treinado, podado e avaliado, é possível extrair regras de classificação completas para cada classe. Cada caminho da raiz da árvore até uma folha representa uma regra. O caminho consiste em uma série de testes baseados nos atributos dos dados. Por exemplo, uma regra pode aparecer da seguinte forma:

$$SE (Atributo1 \leq Valor1) E (Atributo2 > Valor2) ENTÃO Classe = X$$

Cada folha da árvore de decisão representa uma classe predita, e o caminho da raiz até essa folha define as condições que levam a essa classificação. O conjunto completo de regras para todas as classes pode ser obtido analisando todos os caminhos da árvore da raiz até cada folha.

Tabela 2 – Limiares desordenados.

695.723	-882.930	62.364	-882.737	-657.224	-73.677	-61.660	-55.682	-47.663
---------	----------	--------	----------	----------	---------	---------	---------	---------

Como explicado, a árvore de decisão é uma estrutura hierárquica onde cada caminho da raiz até uma folha representa uma regra de classificação, englobando uma variedade de atributos e seus respectivos limiares. Estes são definidos considerando o contexto específico de cada trajetória, influenciados pelas divisões anteriores, de modo que a sequência em que os limiares aparecem reflete a abordagem adotada para as divisões locais e a ordem na qual os atributos e limiares são selecionados para melhorar a precisão da classificação. Dado que esta sequência não segue uma ordem preestabelecida, a extração dos limiares revela uma disposição não ordenada, conforme ilustrado na Tabela 2. Para abordar isso, este módulo organiza os limiares em um vetor em ordem ascendente, conforme ilustrado na Tabela 3 e categoriza a base de regras por classe, reconhecendo e adaptando-se à natureza intrínseca da construção da árvore de decisão.

Tabela 3 – Limiares ordenados.

-882.930	-882.737	-657.224	695.723	-73.677	-61.660	-47.663	-55.682	62.364
----------	----------	----------	---------	---------	---------	---------	---------	--------

4.3 MÓDULO DE CONVERSÃO

O Módulo de Conversão tem sua essência na transformação e gestão dos limiares e das regras de decisão gerados pelo módulo anterior. Ele se dedica a converter os limiares e as regras crisp originadas do Módulo Classificador, baseado na árvore de decisão, em limiares e regras *fuzzy*, conforme ilustrado na Figura 13. A árvore de decisão é utilizada para gerar regras de classificação que, inicialmente, são regras crisp. Essas regras ativam uma decisão apenas quando os limiares exatos são atingidos. No entanto, ao fuzzificar essas regras, o sistema *fuzzy* permite que elas sejam ativadas gradualmente, mesmo antes de os limiares exatos serem alcançados.

Essa conversão é particularmente útil em sistemas reais, onde os eventos podem não ocorrer de maneira tão abrupta. Com as regras fuzzificadas, uma regra pode ser ativada parcialmente quando o sistema começa a se aproximar de um limiar, em vez de esperar que ele seja atingido exatamente. Isso significa que a regra pode ser ativada com uma certa “força” ou “certeza” antes mesmo de se atingir o ponto definido originalmente pela árvore de decisão. Essa abordagem permite que o sistema lide com dados e situações de maior complexidade e incerteza, características comuns em aplicações práticas, tornando a tomada de decisão mais adaptativa e realista.

Essa transição suave oferece várias vantagens. Primeiro, ela permite uma resposta antecipada: em vez de esperar uma condição exata ser atendida, o sistema *fuzzy* pode começar a reagir antecipadamente, proporcionando uma resposta mais proativa. Isso pode ser crucial em sistemas elétricos, onde a antecipação pode evitar falhas ou otimizar o desempenho.

Segundo, ela possibilita uma modelagem mais realista. A maioria dos fenômenos no mundo real não ocorre de maneira abrupta. Ao permitir que as regras sejam ativadas gradualmente, o sistema *fuzzy* fornece uma representação mais realista do comportamento do sistema.

Finalmente, a fuzzificação proporciona maior robustez. Em vez de se basear em limiares rígidos, que podem ser sensíveis ao ruído ou a pequenas variações nos dados, a fuzzificação permite ao sistema lidar com incertezas de forma mais eficaz.

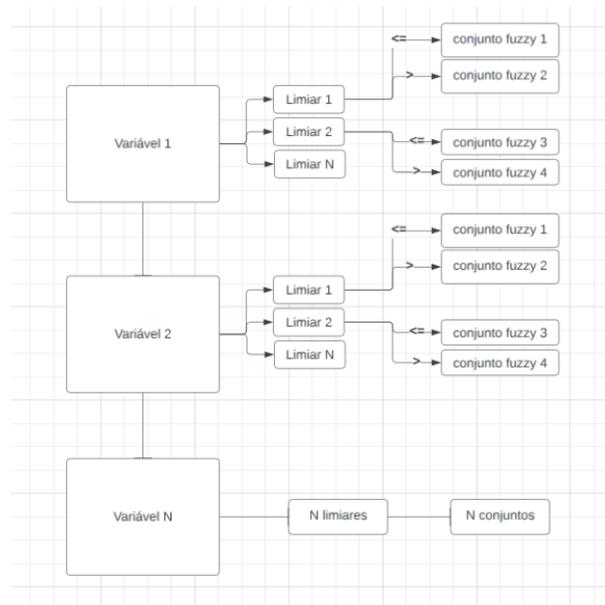


Figura 13 – Processo de conversão de variáveis e limiares *fuzzy*.

4.3.1 Submódulo de gerenciamento de variáveis

4.3.1.1 Conjuntos gerados automaticamente

O módulo classificador gera uma série de limiares para cada variável do conjunto de dados, como ilustrado na Figura 14 para a variável "Ia". Esses limiares transformam as variáveis precisas (*crisp*) em suas contrapartes *fuzzy*, criando dois conjuntos *fuzzy* que se interseccionam no limiar original. Essa abordagem reflete a transição suave entre diferentes estados e captura a complexidade e ambiguidade dos fenômenos reais, permitindo uma modelagem mais sofisticada das incertezas.

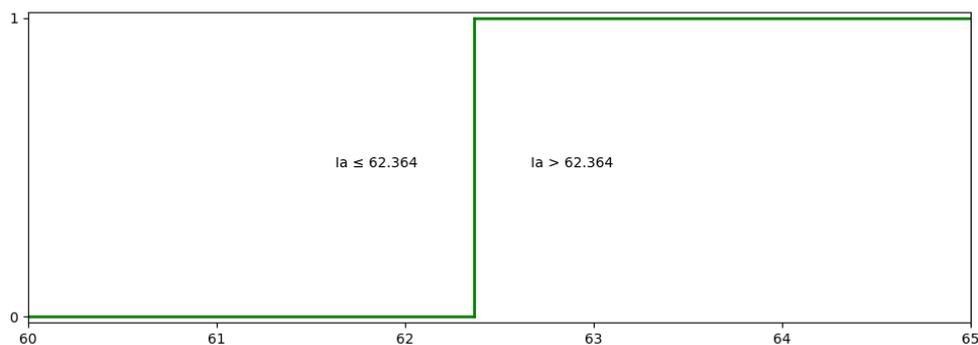


Figura 14 – Exemplo de variável *crisp* e seus limites.

A metodologia baseia-se na segmentação do domínio de cada variável em regiões delimitadas pelos limiares, que formam pares de conjuntos *fuzzy* correspondentes aos operadores lógicos de “ \leq ” e “ $>$ ”. Com N representando o número de limiares, o processo resulta na criação de $2 \times 2 \times N$ conjuntos *fuzzy*, assegurando uma representação abrangente das nuances de pertinência. Essa estrutura é complementada por uma sobreposição espelhada entre os conjuntos adjacentes, onde o conjunto à esquerda do limiar é uma imagem refletida do conjunto à direita. Essa escolha favorece transições suaves e melhora a interpretação de casos limítrofes ou ambíguos.

A interação entre os conjuntos *fuzzy* adjacentes nas áreas de sobreposição introduz flexibilidade e robustez ao sistema, tornando-o menos sensível a ruídos e variações sutis nos dados de entrada. Como ilustrado na Figura 15, essa estratégia aprimora a capacidade de inferência gradativa e adapta o sistema a condições variáveis e informações parcialmente incertas. Assim, a modelagem baseada em conjuntos *fuzzy* não apenas lida com incertezas de maneira eficiente, mas também contribui para decisões mais confiáveis em ambientes complexos.

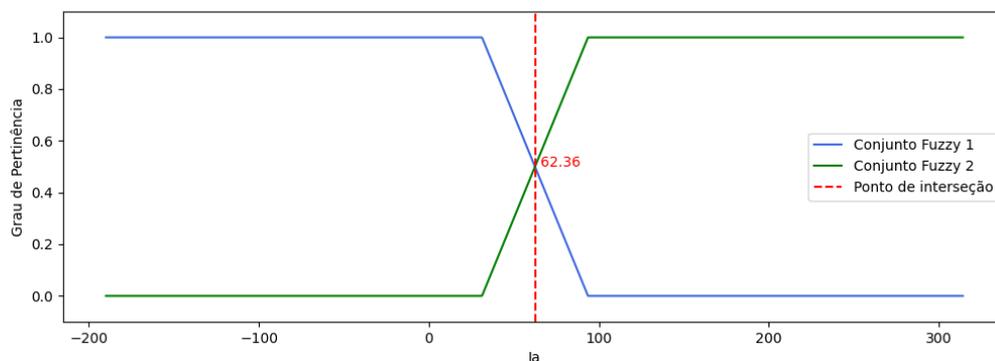


Figura 15 – Exemplo de variável fuzzyficada.

4.3.1.2 Conjuntos gerados manualmente

Além do processo automatizado de geração de conjuntos *fuzzy*, a metodologia oferece aos especialistas um conjunto de ferramentas interativas. Essas ferramentas são projetadas para aprimorar a flexibilidade e a eficácia da modelagem *fuzzy*, permitindo a manipulação detalhada dos conjuntos gerados.

Com esses recursos, os usuários têm a liberdade de excluir conjuntos que não contribuem significativamente para o modelo, editar aqueles que requerem ajustes finos para melhor repre-

sentar os dados ou até mesmo criar novos conjuntos que refletem insights ou conhecimentos específicos do domínio. Essa capacidade de personalização é crucial para afinar o modelo *fuzzy* às nuances particulares do conjunto de dados em análise.

The screenshot shows a web interface titled "Fuzzy Variables List". It features a search bar and a button to "Add New Variables". Below is a table listing three variables: Vb (Id 26), Va (Id 25), and Ic (Id 24). Each variable is of type "Input" and has a range of [0.0,10.0]. The table details linguistic values (Low, Medium, High), their notations (L, M, H), and their ranges. For Vb and Va, the functions are "Triangular". For Ic, the functions are "to define". Each entry has a set of action icons: a plus sign, a pencil, a document, and a trash can.

Id	Variable Name	Type	Range	Values	Actions																				
26	Vb	Input	[0.0,10.0]	<table border="1"> <thead> <tr> <th>Linguistic</th> <th>Notation</th> <th>Range</th> <th>function</th> <th>Actions</th> </tr> </thead> <tbody> <tr> <td>Low</td> <td>L</td> <td>[0.0,4.0]</td> <td>Triangular</td> <td>[Pencil, Trash]</td> </tr> <tr> <td>Medium</td> <td>M</td> <td>[3.0,8.0]</td> <td>Triangular</td> <td>[Pencil, Trash]</td> </tr> <tr> <td>High</td> <td>H</td> <td>[7.0,10.0]</td> <td>Triangular</td> <td>[Pencil, Trash]</td> </tr> </tbody> </table>	Linguistic	Notation	Range	function	Actions	Low	L	[0.0,4.0]	Triangular	[Pencil, Trash]	Medium	M	[3.0,8.0]	Triangular	[Pencil, Trash]	High	H	[7.0,10.0]	Triangular	[Pencil, Trash]	[+], [Pencil], [Document], [Trash]
Linguistic	Notation	Range	function	Actions																					
Low	L	[0.0,4.0]	Triangular	[Pencil, Trash]																					
Medium	M	[3.0,8.0]	Triangular	[Pencil, Trash]																					
High	H	[7.0,10.0]	Triangular	[Pencil, Trash]																					
25	Va	Input	[0.0,10.0]	<table border="1"> <thead> <tr> <th>Linguistic</th> <th>Notation</th> <th>Range</th> <th>function</th> <th>Actions</th> </tr> </thead> <tbody> <tr> <td>Low</td> <td>L</td> <td>[0.0,4.0]</td> <td>Triangular</td> <td>[Pencil, Trash]</td> </tr> <tr> <td>Medium</td> <td>M</td> <td>[3.0,8.0]</td> <td>Triangular</td> <td>[Pencil, Trash]</td> </tr> <tr> <td>High</td> <td>H</td> <td>[3.0,8.0]</td> <td>Triangular</td> <td>[Pencil, Trash]</td> </tr> </tbody> </table>	Linguistic	Notation	Range	function	Actions	Low	L	[0.0,4.0]	Triangular	[Pencil, Trash]	Medium	M	[3.0,8.0]	Triangular	[Pencil, Trash]	High	H	[3.0,8.0]	Triangular	[Pencil, Trash]	[+], [Pencil], [Document], [Trash]
Linguistic	Notation	Range	function	Actions																					
Low	L	[0.0,4.0]	Triangular	[Pencil, Trash]																					
Medium	M	[3.0,8.0]	Triangular	[Pencil, Trash]																					
High	H	[3.0,8.0]	Triangular	[Pencil, Trash]																					
24	Ic	Input	[0.0,10.0]	<table border="1"> <thead> <tr> <th>Linguistic</th> <th>Notation</th> <th>Range</th> <th>function</th> <th>Actions</th> </tr> </thead> <tbody> <tr> <td>Low</td> <td>L</td> <td>[0.0,4.0]</td> <td>to define</td> <td>[Pencil, Trash]</td> </tr> <tr> <td>Medium</td> <td>M</td> <td>[3.0,8.0]</td> <td>to define</td> <td>[Pencil, Trash]</td> </tr> <tr> <td>High</td> <td>H</td> <td>[7.0,10.0]</td> <td>to define</td> <td>[Pencil, Trash]</td> </tr> </tbody> </table>	Linguistic	Notation	Range	function	Actions	Low	L	[0.0,4.0]	to define	[Pencil, Trash]	Medium	M	[3.0,8.0]	to define	[Pencil, Trash]	High	H	[7.0,10.0]	to define	[Pencil, Trash]	[+], [Pencil], [Document], [Trash]
Linguistic	Notation	Range	function	Actions																					
Low	L	[0.0,4.0]	to define	[Pencil, Trash]																					
Medium	M	[3.0,8.0]	to define	[Pencil, Trash]																					
High	H	[7.0,10.0]	to define	[Pencil, Trash]																					

Showing 3 out of 29 entries

1 2 3 4 5 6 7 ... 9 10 Next

Figura 16 – Base de variáveis.

Os conjuntos *fuzzy* e as variáveis associadas são organizados de forma sistemática em uma base de dados dedicada, como ilustrado na Figura 16. Essa estrutura organizada não apenas simplifica o gerenciamento e a recuperação de informações, mas também torna a análise mais eficiente. Para complementar, a interface foi cuidadosamente projetada para proporcionar uma visualização clara e intuitiva dessas variáveis, integrando funcionalidade e acessibilidade.

Como ilustrado na Figura 17, os usuários podem visualizar individualmente cada variável *fuzzy*, juntamente com seus conjuntos associados, em gráficos detalhados. Essa visualização isolada é instrumental para compreender a distribuição e a interação dos conjuntos *fuzzy* dentro do modelo, permitindo aos especialistas identificar rapidamente áreas que podem necessitar de ajustes ou revisão.

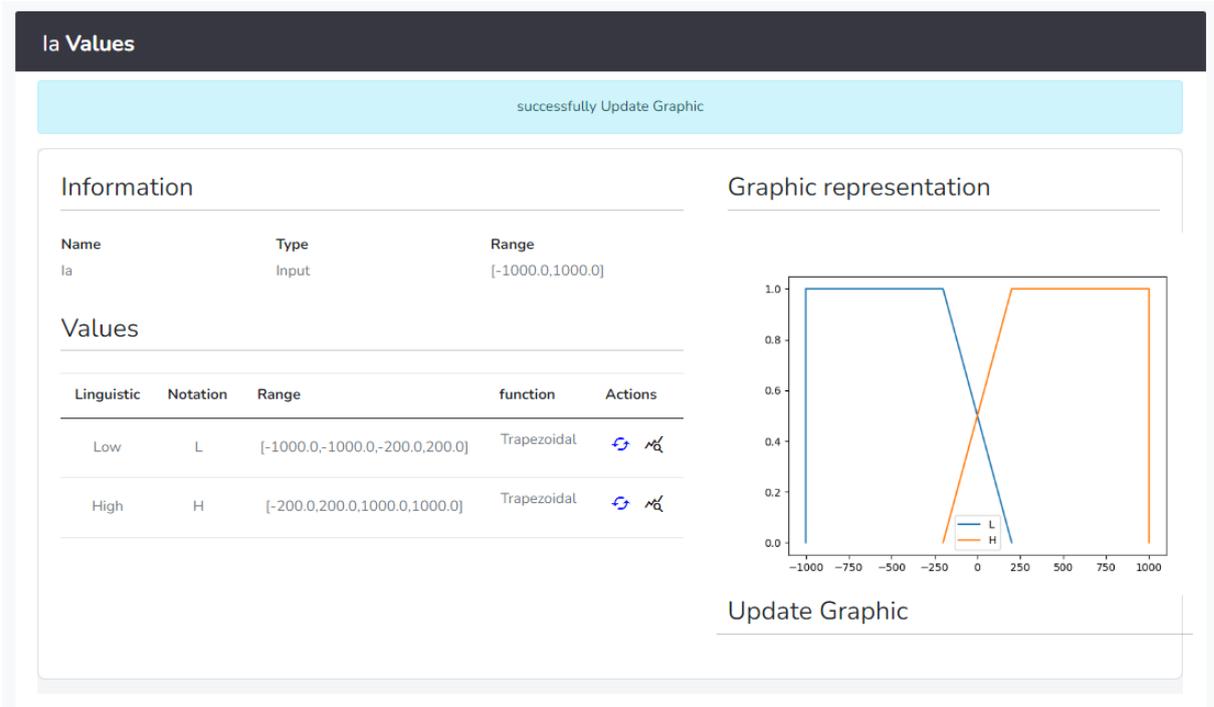


Figura 17 – Tela de visualização de gráficos da variável.

Ao combinar a geração automática e manual de conjuntos com ferramentas de manipulação e visualização, a metodologia assegura que os especialistas possam refinar seus modelos *fuzzy* de maneira eficaz, promovendo um equilíbrio ideal entre automação e controle especializado.

4.3.2 Submódulo de gerenciamento de regras

4.3.2.1 Regras geradas automaticamente

Após a conversão dos limiares da árvore de decisão treinada em conjuntos *fuzzy*, inicia-se um processo detalhado de iteração sobre o conjunto de regras geradas pela árvore. Nesta etapa, cada limiar, previamente identificado como um ponto de decisão crítico dentro da estrutura da árvore, é substituído pelo seu correspondente conjunto *fuzzy*, conforme ilustrado na Figura 18.

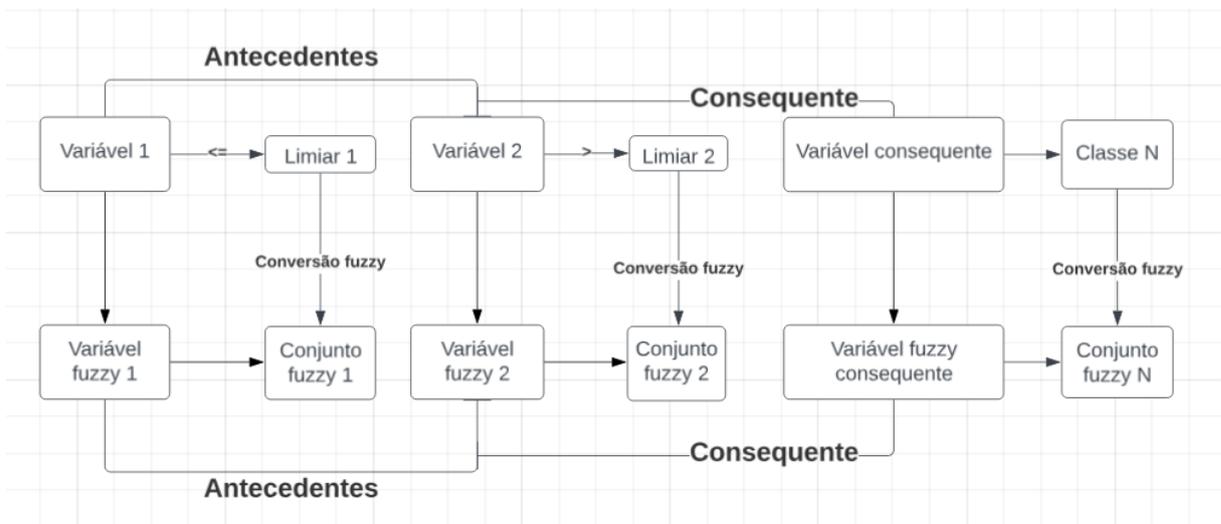


Figura 18 – Processo de conversão de regras *fuzzy*.

Este processo de substituição não se limita à alteração direta de valores, ele recontextualiza as condições de decisão sob a ótica *fuzzy*, permitindo capturar nuances e gradações de maneira mais fidedigna. Em vez de decisões estritamente delimitadas por limiares fixos, a aplicação dos conjuntos *fuzzy* reflete a incerteza e a variabilidade dos dados reais, oferecendo uma interpretação mais rica.

Dessa forma, cada regra é enriquecida, operando em um espectro mais amplo de cenários, melhorando a robustez e a precisão do modelo. A abordagem *fuzzy* permite que o sistema trate adequadamente casos que não atendem estritamente aos critérios binários originais, mas ainda são relevantes para a tomada de decisão.

A título de exemplo, se uma regra é gerada como:

1. Se $(Ia > -73.678) \wedge (Ia \leq 62.364) \wedge (Ib > -35.381) \wedge (Ib \leq 103.709) \wedge (Ic > -96.49) \wedge (Ic \leq 58.565) \wedge (Vb \leq -0.043) \wedge (Vb \leq 0.552)$ então classe: 0

Sua forma definitiva será:

1. Se $(Ia \text{ é Cf } 10) \wedge (Ib \text{ é Cf } 8) \wedge (Ic \text{ é Cf } 4) \wedge (Vb \text{ é Cf } 11)$ então classe: 0

Neste exemplo, quando uma mesma variável se repete mais de uma vez com operadores no mesmo sentido, apenas a condição mais restritiva é mantida na regra. Quando os operadores da mesma variável possuem sinais opostos, é possível criar um conjunto *fuzzy* que represente o intervalo considerado. Esse processo simplifica as regras, tornando-as mais gerenciáveis.

4.3.2.2 Regras geradas manualmente

A metodologia oferece um ambiente para criar, editar, pesquisar e excluir regras fuzzy. Os usuários podem definir regras específicas utilizando os conjuntos gerados pelo módulo classificador ou conjuntos criados manualmente, estabelecendo as relações lógicas entre antecedentes e consequentes.

A flexibilidade do submódulo destaca-se pela capacidade de editar e refinar regras, permitindo a adaptação a novos requisitos ou conhecimentos. Além disso, o módulo suporta operadores lógicos como “E” e “OU”, que facilitam a definição das relações entre antecedentes, representando com precisão as complexidades dos ambientes reais.

4.3.2.3 Exemplo de criação manual de regra

Uma base de regras, ilustrada na Figura 19, estabelece as relações lógicas entre as variáveis de entrada e saída, definindo o comportamento do sistema. Cada regra *fuzzy* é composta por uma condição (parte antecedente) e uma conclusão (parte consequente), essenciais para a tomada de decisões no esquema *fuzzy*.

Id	Name	Knowledge Base	Inputs	Outputs	Actions
33	Rule 4	Trasmission Line	IF(la is Medium) and (Vc is High)	THEN(Classification is Class 3)	
32	Rule 3	Trasmission Line	IF(la is Medium) and (lb is High) and (Va is Low) and (Vb is Medium)	THEN(Classification is Class 2)	
31	Rule 2	Trasmission Line	IF(la is High) and (lb is Medium) and (Va is High)	THEN(Classification is Class 3)	
30	Rule 1	Trasmission Line	IF(la is Low) and (lb is Medium) (la is Medium) and (lc is Medium)	THEN(Classification is Class 0)	
26	Controle de Tensão Regra3	Controle de Tensão	IF(Erro de Tensão (V) is Positivo) and (Mudança na Tensão (V/s) is Aumentando)	THEN(Variável de Saída is Diminuir)	
25	Controle de Tensão Regra2	Controle de Tensão	IF(Erro de Tensão (V) is Zero) and (Mudança na Tensão (V/s) is Estável)	THEN(Variável de Saída is Manter)	
24	Controle de Tensão Regra1	Controle de Tensão	IF(Erro de Tensão (V) is Negativo) and (Mudança na Tensão (V/s) is Diminuindo)	THEN(Variável de Saída is Aumentar)	

Showing 1 out of 24 entries 1 2 3 4 Next

Figura 19 – Visualização de base geral de regras.

Ao clicar em “Add New Rules”, ilustrado na Figura 19, o especialista navega entre opções

para configurar uma regra associando variáveis linguísticas às variáveis *fuzzy* e cria associação entre estas através de operadores lógicos.

A regra: “Se o “Ia” é “Medium” e a “Vc” é “High”, então “Classification” é “Classe 3”, pode ser dividida em duas partes já que possui dois antecedentes.

Na primeira parte, ilustrada na Figura 20, a variável linguística “Medium” é associada à variável *fuzzy* “Ia”.

The screenshot shows the 'Create Rule: Rule 4' interface. Under the 'Inputs' section, a 'Select Variable' dropdown menu is open, displaying a list of variables: Ia, Ib, Va, Vb, Vc, and Ic. The variable 'Ia' is highlighted. To the right of the dropdown is an 'Add' button. Below the inputs, there is a table for the 'Rule Body' with columns: Type, Variable, Value, Operator, and Actions.

(a) Escolha da primeira variável *fuzzy*.

The screenshot shows the 'Create Rule: Rule 4' interface. The 'Inputs' section now has 'Ia' selected in a dropdown. A 'Select Value' dropdown menu is open, showing 'Low', 'Medium', and 'High'. 'Medium' is highlighted. An 'Add' button is next to it. The 'Rule Name' field contains 'Rule 4'. The 'Rule Body' table is visible below.

(b) Variável linguística associada à primeira variável.

The screenshot shows the 'Create Rule: Rule 4' interface. The 'Inputs' section now has 'Ia' and 'Medium' selected in dropdowns. A 'Select Operator' dropdown menu is open, showing 'AND', 'OR', and 'None'. 'AND' is highlighted. An 'Add' button is next to it. The 'Rule Name' field contains 'Rule 4'. The 'Rule Body' table is visible below.

(c) Escolha do operador para relacionar duas variáveis *fuzzy* na regra.

Figura 20 – Primeira parte do antecedente da regra.

Na segunda parte, ilustrada na Figura 21, a variável linguística “High” é associada à variável fuzzy “Vc”.

Rule Name	Type	Variable	Value	Operator	Actions
Rule 4	Input	la	Medium	and	
	Output		Class 3	-	

(a) Variável linguística associada à segunda variável fuzzy.

Rule Name	Type	Variable	Value	Operator	Actions
Rule 4	Input	la	Medium	and	
	Output		Class 3	-	

(b) Conclusão da definição dos antecedentes.

Figura 21 – Segunda parte do antecedente da regra.

Por fim, como pode ser visto na Figura 22, o consequente da regra é criado associando a variável linguística “Classe 3” à variável fuzzy “Classification” que representa a classe de falha.

Create Rule: Rule 4 Delete Add New Rules

IF(la is Medium) and (lb is Low) and (Vc is High) THEN

successfully added

Inputs: Classification Select Value Add

Outputs

Rule Name Rule 4

Rule Body

Variable	Value	Operator	Actions
Input la	Medium	and	
Input lb	Low	and	
Input Vc	High	none	

(a) Variável linguística associada à variável fuzzy consequente.

Create Rule: Rule 4 Delete Add New Rules

IF(la is Medium) and (Vc is High) THEN(Classification is Class 3)

successfully Delete

Inputs: Select Variable Add

Outputs

Rule Name Rule 4

Rule Body

Type	Variable	Value	Operator	Actions
Input	la	Medium	and	
Input	Vc	High	none	
Output		Class 3	-	

(b) Conclusão da definição da regra.

Figura 22 – Consequente da regra.

Na Figura 23, é apresentada uma base de regras completa para uma tarefa específica. Após a finalização da base de regras, o especialista pode realizar as simulações que julgar mais adequadas.

Rules List		Select Task	Search	Add New Rules	
Id	Name	Knowledge Base	Inputs	Outputs	Actions
32	Rule 3	Trasmission Line	IF(Ia is Medium) and (Ib is High) and (Va is Low) and (Vb is Medium)	THEN(Classification is Class 2)	
31	Rule 2	Trasmission Line	IF(Ia is High) and (Ib is Medium) and (Va is High)	THEN(Classification is Class 3)	
30	Rule 1	Trasmission Line	IF(Ia is Low) and (Ib is Medium) (Ia is Medium) and (Ic is Medium)	THEN(Classification is Class 0)	

List

Figura 23 – Base de regras completa.

4.4 MÓDULO DE SISTEMAS *FUZZY*

O módulo de Sistemas *Fuzzy*, ilustrado na Figura 24, ressalta sua importância estratégica na construção de modelos inteligentes e na abordagem de problemas complexos. Facilitando a definição de tarefas específicas que representam diferentes modelos de decisão e associando variáveis *fuzzy* como antecedentes e consequentes, o módulo estabelece o alicerce para um sistema capaz de inferências e decisões adaptativas. A opção de escolha entre cinco métodos distintos de defuzzificação amplia a capacidade do módulo de se ajustar às especificidades de cada desafio enfrentado, possibilitando a simulação do sistema sob diferentes perspectivas e metodologias.

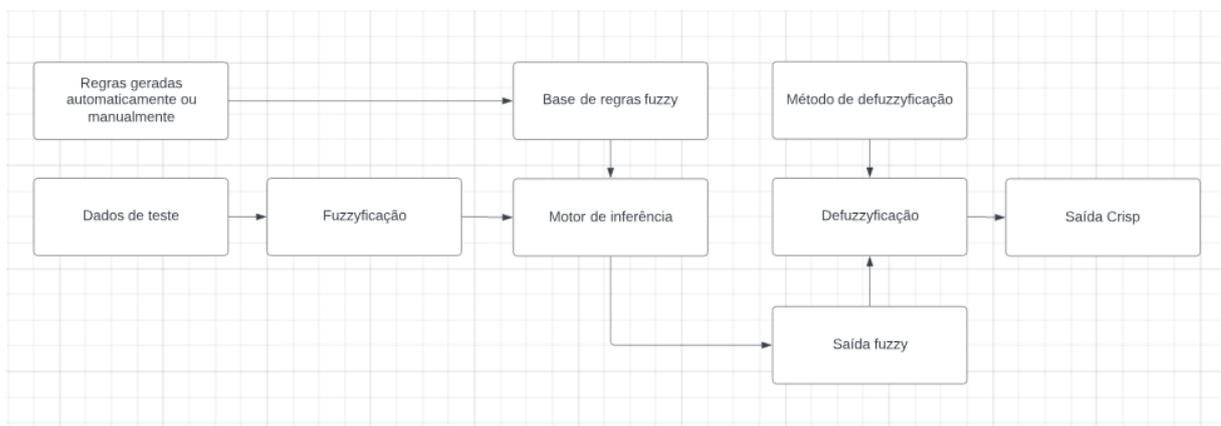
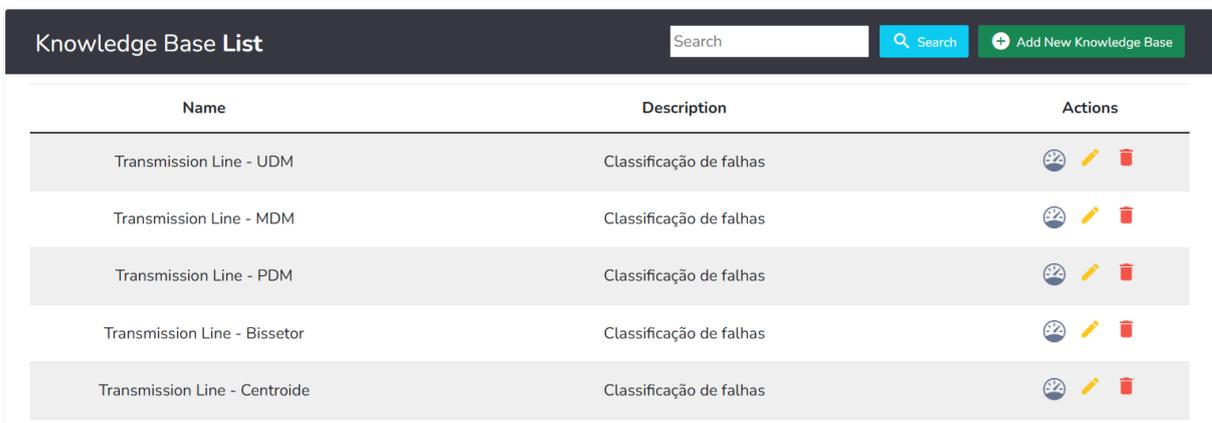


Figura 24 – Processo de inferência *fuzzy*.

Os conjuntos e regras gerados automaticamente pelo Módulo de Conversão formam a base de um sistema completo para simulação no contexto da lógica *fuzzy*. Entretanto, além

dessa capacidade inicial, o mesmo módulo oferece uma plataforma avançada que permite aos especialistas explorar variações desse sistema base, sem necessidade de alterações diretas no modelo original.

Esta flexibilidade é viabilizada através de uma base de sistemas *fuzzy*, a qual pode abrigar variações do modelo gerado automaticamente, permitindo ajustes nos conjuntos e regras *fuzzy* e a experimentação com diferentes métodos de defuzzificação, incluindo CEN, BA, PDM, MDM e UDM. Tal diversidade nos métodos de defuzzificação enriquece as possibilidades analíticas, aumentando a versatilidade e a precisão do sistema. Os modelos são armazenados em um base de modelos conforme ilustrado na Figura 25.



Name	Description	Actions
Transmission Line - UDM	Classificação de falhas	  
Transmission Line - MDM	Classificação de falhas	  
Transmission Line - PDM	Classificação de falhas	  
Transmission Line - Bissetor	Classificação de falhas	  
Transmission Line - Centroide	Classificação de falhas	  

Figura 25 – Visualização do módulo de Sistemas *Fuzzy*.

4.5 IMPLEMENTAÇÃO TÉCNICA

Nesta seção são abordados brevemente as ferramentas usadas para implementação desta metodologia, desde linguagens de programação, bibliotecas, frameworks, banco de dados, bem como padrões de arquitetura.

4.5.1 Ferramenta utilizadas na construção dos módulos

1. *Front End*: JavaScript

O JavaScript (EICH, 1995) foi escolhido para o *Front End* das telas devido à sua versatilidade e ampla utilização na construção de interfaces web interativas. Sua capacidade de manipulação dinâmica do *Document Object Model (DOM)* permite uma experiência do usuário fluida e responsiva, essencial para a interação eficiente com o sistema.

2. Back End: *Flask-MVC*

O Flask (RONACHER, 2010) é um microframework Python que, apesar de sua simplicidade, é bastante poderoso e flexível, permitindo a criação de aplicações web robustas e escaláveis. Quando combinado com a arquitetura MVC (Model-View-Controller) (SYROMIATNIKOV; WEYNS, 2014), o Flask oferece uma maneira organizada e eficiente de desenvolver aplicações web. A arquitetura MVC é um padrão de design que separa uma aplicação em três componentes principais: o Modelo (Model), responsável pela lógica de negócios e gestão de dados; a Visão (View), que cuida da apresentação dos dados e da interface do usuário; e o Controlador (Controller), que atua como intermediário, processando as solicitações do usuário, interagindo com o Modelo e retornando a resposta apropriada.

3. Biblioteca: Scikit-Learn

O “Scikit-learn” é uma biblioteca de aprendizado de máquina em Python amplamente utilizada para tarefas de classificação. Ela fornece uma interface simples e eficiente para implementar uma variedade de algoritmos de classificação. Com ferramentas robustas para avaliação de modelos, ajuste de hiperparâmetros e pré-processamento de dados, o “Scikit-learn” facilita a construção de modelos preditivos precisos e escaláveis.

4. Biblioteca: *Scikit-Fuzzy*

A biblioteca *Scikit-Fuzzy* (DEVELOPERS, 2022) foi escolhida para a construção do sistema *fuzzy* devido à sua robustez e eficiência na implementação de lógica difusa. Essa biblioteca oferece uma variedade de ferramentas para modelar sistemas *fuzzy*, permitindo a representação e análise de incertezas presentes nos sistemas de potência. A riqueza de funcionalidades do *Scikit-Fuzzy* facilita a construção de controladores *fuzzy* personalizados para otimizar o desempenho de SEP, proporcionando uma abordagem avançada para lidar com a sua complexidade.

5. Banco de Dados: *SQLite*

O *SQLite* (HIPPI, 2000) foi escolhido como o banco de dados para armazenamento de informações do sistema de potência devido à sua leveza, simplicidade e facilidade de implementação. Sua natureza sem servidor elimina a necessidade de configurações complexas, sendo ideal para aplicações de pequena a média escala. A integração com o *Flask* simplifica as operações de leitura e gravação de dados, garantindo eficiência e confiabilidade na gestão da informação necessária para a metodologia proposta.

5 EXPERIMENTOS E RESULTADOS

5.1 INTRODUÇÃO

Neste capítulo, serão apresentadas as análises e conclusões obtidas a partir do estudo de classificação de falhas com base na metodologia proposta. A avaliação dos resultados será realizada considerando métricas de desempenho como acurácia, precisão, sensibilidade e F1-Score. Essas métricas desempenham um papel fundamental na quantificação da eficácia da metodologia e na identificação de possíveis oportunidades de aprimoramento.

5.2 BASE DE DADOS UTILIZADA

Para o desenvolvimento da metodologia proposta, foi utilizada a base de dados do Kaggle intitulada “*Electrical Fault Detection and Classification*”¹, composta por variáveis elétricas, como correntes e tensões, registradas em diversas condições operacionais e cenários de falhas envolvendo curtos-circuitos. A qualidade e precisão desses dados são cruciais para o desempenho do sistema *fuzzy*, oferecendo uma base sólida para o desenvolvimento de modelos aplicáveis a cenários reais.

Além de atender diretamente aos objetivos da pesquisa, essa base de dados possibilita uma análise direcionada e relevante para a classificação de falhas elétricas. Um modelo bem-sucedido fundamentado nesses dados não apenas tem o potencial de estabelecer novos padrões na área, mas também de gerar *insights* valiosos para futuras pesquisas e aplicações práticas.

¹ <https://www.kaggle.com/datasets/esathyaprakash/electrical-fault-detection-and-classification>

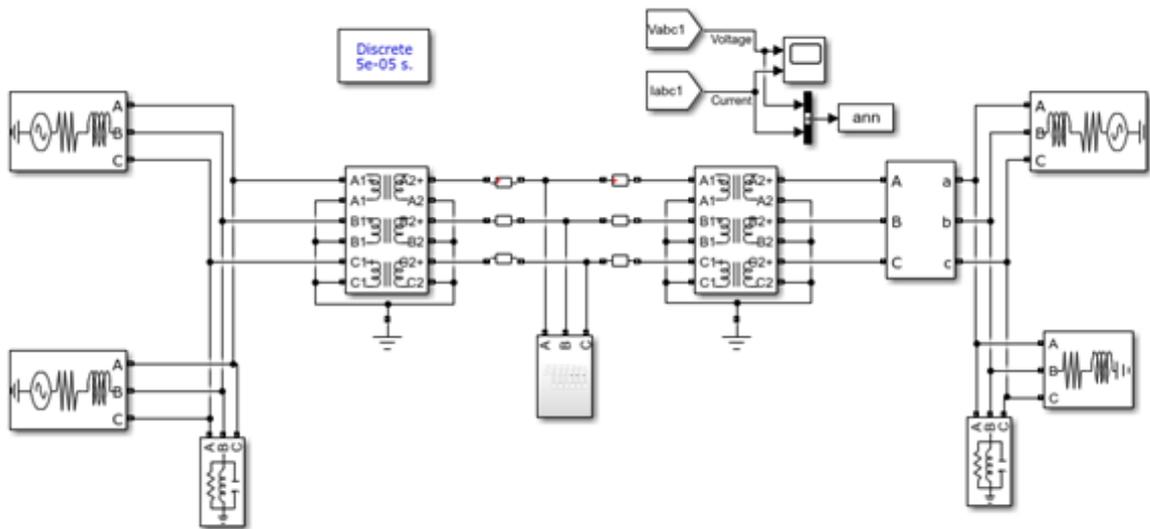


Figura 26 – Sistema simulado no MATLAB.

O sistema ilustrado na Figura 26 representa o conjunto de dados gerado a partir da simulação do sistema de energia no MATLAB (MathWorks Inc., 2010), especificamente projetado para estudar e analisar falhas em sistemas de transmissão de energia elétrica.

O sistema modelado simula uma linha de transmissão trifásica alimentada por geradores localizados em ambos os lados da linha. Esses geradores fornecem tensão e corrente trifásicas ao sistema, que são então transmitidas através de transformadores. Os transformadores, localizados entre os geradores e a linha de transmissão, têm a função de ajustar os níveis de tensão e corrente, seja elevando ou reduzindo, conforme necessário para a transmissão eficiente da energia. A linha de transmissão central conecta esses componentes, sendo o local onde ocorrem estudos de falhas, interrupções e variações de carga.

Nas extremidades da linha, há cargas elétricas simulando o consumo de energia, e elas podem ser ajustadas para permitir análises sob diferentes condições. Além disso, o sistema possui componentes de medição que capturam as correntes e tensões nos pontos de entrada e saída, fornecendo dados que podem ser posteriormente processados.

Durante a simulação, foram coletadas e armazenadas informações referentes às Tensões e Correntes de Linha no lado de saída do sistema de energia. No total, aproximadamente 12.000 pontos de dados foram coletados e posteriormente categorizados.

5.3 ANÁLISE DOS DADOS

Nesta seção, será explorado o conjunto de dados disponível, compreendendo suas características e preparando-o para a análise subsequente e desenvolvimento de modelos.

5.3.1 Visão geral dos dados

Tabela 4 – Amostra do conjunto de dados simulado.

G	C	B	A	Ia	Ib	Ic	Va	Vb	Vc
1	0	0	1	-151.291812	-9.677452	85.800162	0.400750	-0.132935	-0.267815
1	0	0	1	-336.186183	-76.283262	18.328897	0.312732	-0.123633	-0.189099
1	0	0	1	-502.891583	-174.648023	-80.924663	0.265728	-0.114301	-0.151428
1	0	0	1	-593.941905	-217.703359	-124.891924	0.235511	-0.104940	-0.130570
1	0	0	1	-643.663617	-224.159427	-132.282815	0.209537	-0.095554	-0.113983

O conjunto de dados contém medições de tensões e correntes de Fase em diferentes condições operacionais e de falha, como ilustrado na Tabela 4. Essas grandezas são medidas em ampères (A) para as correntes e volts (V) para as tensões. As variáveis principais e suas descrições são as seguintes:

1. **Ia**: Corrente na Fase A
2. **Ib**: Corrente na Fase B
3. **Ic**: Corrente na Fase C
4. **Va**: Tensão na Fase A
5. **Vb**: Tensão na Fase B
6. **Vc**: Tensão na Fase C

Cada classe de falha é identificada por uma sequência de quatro valores categóricos “0” e “1” que identificam se existe ou não falha em uma linha ou aterramento. A sequência é :[G,C,B,A] que indicam sequencialmente, Terra, Fase C, Fase B e Fase A, como ilustrado na Tabela 5.

Tabela 5 – Identificação das classes de falha com base na sequência de valores categóricos.

G	C	B	A	Descrição da Falha
0	0	0	0	Sem Falha
0	0	1	1	Falha LL (Entre a Fase A e a Fase B)
0	1	1	1	Falha LLL (Falha trifásica)
1	0	0	1	Falha LG (Entre a Fase A e o Terra)
1	0	1	1	Falha LLG (Entre as Fases A, B e o Terra)
1	1	1	1	Falha LLLG (Falha trifásica com Terra)

A partir disso, as classes categóricas de falhas foram codificadas em classes numéricas:

1. **Classe 0:** Sem Falha.
2. **Classe 1:** Falha LL (Entre a Fase A e a Fase B).
3. **Classe 2:** Falha LLL (Falha trifásica).
4. **Classe 3:** Falha LG (Entre a Fase A e o Terra).
5. **Classe 4:** Falha LLG (Entre as Fases A, B e o Terra).
6. **Classe 5:** Falha LLLG (Falha trifásica com Terra).

Assim é possível criar uma nova coluna para representar a classe correspondente de falha, como ilustrado na Tabela 6.

Tabela 6 – Adição da coluna de classes de falhas.

G	C	B	A	Ia	Ib	Ic	Va	Vb	Vc	Classe
1	0	0	1	-151.291812	-9.677452	85.800162	0.400750	-0.132935	-0.267815	3
1	0	0	1	-336.186183	-76.283262	18.328897	0.312732	-0.123633	-0.189099	3
1	0	0	1	-502.891583	-174.648023	-80.924663	0.265728	-0.114301	-0.151428	3
1	0	0	1	-593.941905	-217.703359	-124.891924	0.235511	-0.104940	-0.130570	3
1	0	0	1	-643.663617	-224.159427	-132.282815	0.209537	-0.095554	-0.113983	3

5.3.2 Estatística descritiva dos dados

É possível analisar estatisticamente os dados de corrente e tensão através da Tabela 7.

Tabela 7 – Estatísticas descritivas das variáveis.

	Ia	Ib	Ic	Va	Vb	Vc
count	7861.000000	7861.000000	7861.000000	7861.000000	7861.000000	7861.000000
mean	13.721194	-44.845268	34.392394	-0.007667	0.001152	0.006515
std	464.741671	439.269195	371.107412	0.289150	0.313437	0.307897
cv%	3387.04	979.52	1079.04	3771.32	27205.65	4725.98
min	-883.542316	-900.526951	-883.357762	-0.620748	-0.608016	-0.612709
25%	-119.802518	-271.845947	-61.034219	-0.130287	-0.159507	-0.215977
50%	2.042805	5.513317	-4.326711	-0.005290	0.001620	0.009281
75%	227.246377	91.194282	49.115141	0.111627	0.153507	0.239973
max	885.738571	889.868884	901.274261	0.595342	0.627875	0.600179

5.3.2.1 Correntes (**Ia**, **Ib**, **Ic**)

1. Os valores das correntes apresentam uma ampla variação, com desvio padrão elevado em comparação às suas médias, indicando dispersão significativa nos dados.
2. O desvio padrão é bastante grande para as três fases, sugerindo uma ampla gama de medições que podem ser devido à operação normal do sistema, bem como várias condições de falha.
3. Os valores mínimos e máximos mostram uma gama muito ampla, confirmando a presença de flutuações significativas nas medições de corrente, provavelmente devido a condições de falha.

5.3.2.2 Tensões (**Va**, **Vb**, **Vc**)

1. Os valores médios estão muito próximos de 0, indicando que, em média, as tensões se equilibram ao longo do tempo.
2. Os valores de tensões também apresentam dispersão, mas são muito menores em amplitude comparados às correntes.
3. A faixa de valores para as tensões, embora não tão extrema quanto para as correntes, ainda é substancial, destacando variações provavelmente devido a condições operacionais e de falha.

5.3.3 Visualização dos tipos de falha

A distribuição das classes de falhas no conjunto de dados é apresentada por meio de um gráfico de frequência, como ilustrado na Figura 27. Esse gráfico exibe a frequência de cada classe de falha, oferecendo uma compreensão sobre os cenários de falhas mais frequentes e mais raros no conjunto de dados.

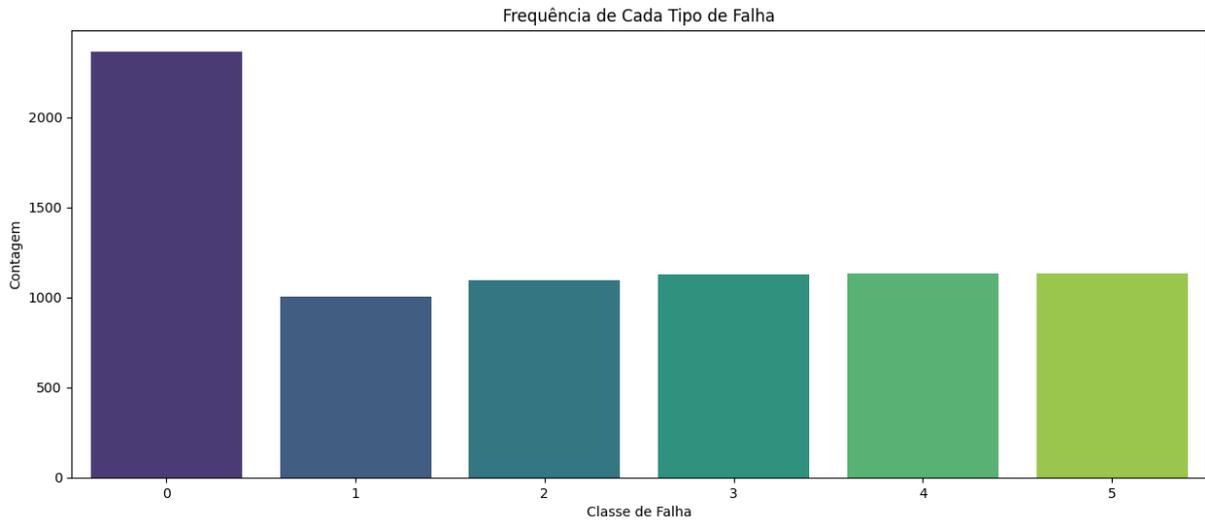


Figura 27 – Frequência das falhas.

A contagem de cada classe de falha no conjunto de dados é:

- Classe 0 (Sem falha): 2365 ocorrências
- Classe 1 (Entre a Fase A e a Fase B): 1004 ocorrências
- Classe 2 (Entre as três fases): 1096 ocorrências
- Classe 3 (Entre a Fase A e o Terra): 1129 ocorrências
- Classe 4 (Entre as Fases A, B e o Terra): 1134 ocorrências
- Classe 5 (Falha trifásica com Terra): 1133 ocorrências

5.3.4 Distribuição de variáveis por tipo de falha

Os *boxplots* das Figuras 28 e 29 exibem a distribuição das leituras de corrente e tensão por classe de falha.

5.3.4.1 Distribuição de Corrente por Classe de Falha

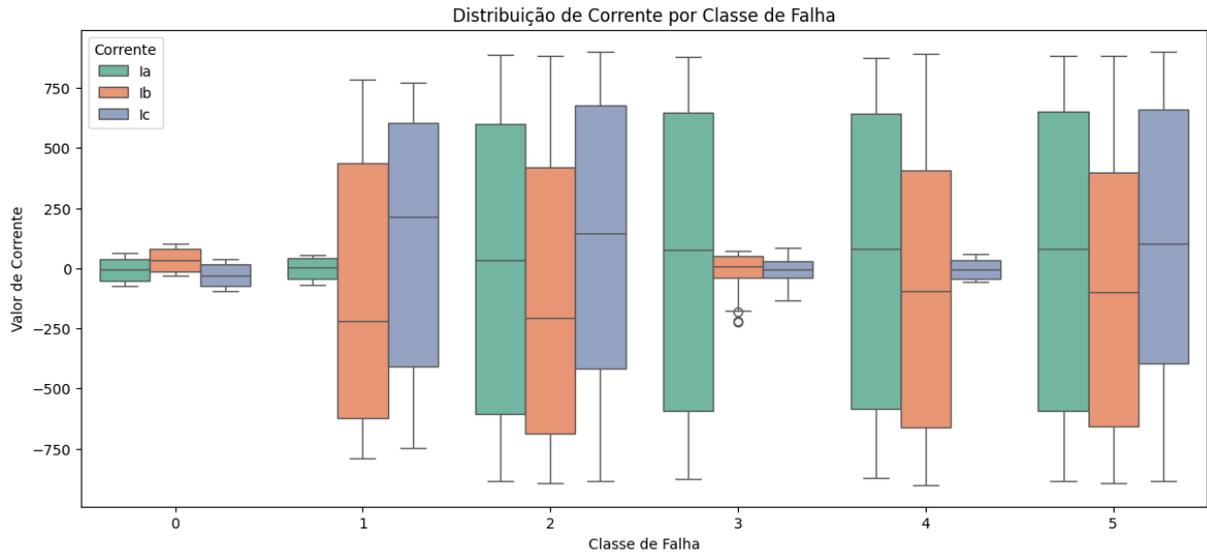


Figura 28 – Distribuição de corrente por classe de falha.

As leituras de corrente (I_a , I_b , I_c) mostram variações significativas entre as classes de falha. É evidente uma ampla dispersão nos valores de corrente, indicando a presença de outliers e a influência das condições de falha nas leituras de corrente.

5.3.4.2 Distribuição de Tensão por Classe de Falha

As leituras de tensão (V_a , V_b , V_c) são mais concentradas em torno de zero em comparação com as leituras de corrente, com variações menores entre as classes de falha. No entanto, ainda há uma certa dispersão, sugerindo que as condições de falha também afetam as leituras de tensão, mas de forma menos dramática do que as correntes.

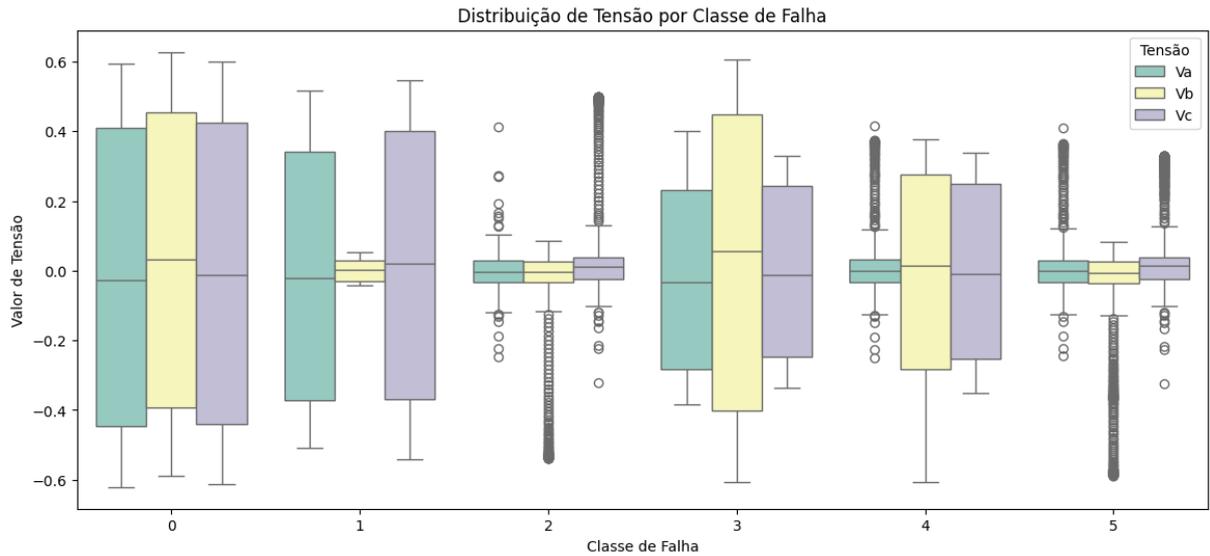


Figura 29 – Distribuição de tensão por classe de falha.

5.4 PROTOCOLO DOS EXPERIMENTOS

Para avaliar o estado atual do sistema, foi selecionada uma árvore de decisão (CHARBUTY; ABDULAZEEZ, 2021) como método primário, dada sua eficácia comprovada em acurácia e alta capacidade interpretativa (SAGI; ROKACH, 2021). A escolha da árvore de decisão é justificada por sua habilidade em dividir um conjunto de dados em subconjuntos menores, com base em critérios específicos, geralmente por meio de uma série de perguntas binárias “sim” ou “não”. Cada caminho da raiz até uma folha na árvore representa uma regra, que pode ser utilizada na formulação de regras *fuzzy* (HALL; LANDE, 1998), (BISWAL; DASH, 2012).

Enquanto as regras das árvores de decisão são tipicamente binárias e rígidas, as regras *fuzzy* permitem gradações e ambiguidades. Portanto, as regras extraídas das árvores de decisão podem ser transformadas em regras *fuzzy*, adaptando as condições binárias para funções de pertinência *fuzzy*, que atribuem graus de verdade variáveis, em vez de verdades absolutas.

Para uma comparação abrangente do desempenho do algoritmo escolhido para classificação com outros métodos, também foram incluídos classificadores baseados em técnicas avançadas de árvores, como XGBoost (CHEN et al., 2019), LightGBM (SABERI et al., 2022) e CatBoost (OGAR; HUSSAIN; GAMAGE, 2022). Esses métodos, apesar de lidarem com um maior número de árvores e condições mais complexas, permitem a extração de regras de uma forma semelhante à das árvores de decisão únicas (OBREGON; JUNG, 2023).

Na análise de Acurácia, Precisão, Sensibilidade e F1-Score, cada métrica desempenha um papel específico na avaliação do desempenho de um modelo de classificação (RAINIO; TEUHO; KLÉN, 2024). A acurácia mede a proporção de previsões corretas, indicando o quão bem o modelo classificou os exemplos em geral. A precisão reflete a exatidão das previsões positivas, mostrando a proporção de previsões positivas que são realmente corretas. Já a sensibilidade avalia a capacidade do modelo de identificar corretamente os casos positivos, indicando a proporção de verdadeiros positivos reconhecidos. O F1-Score combina precisão e sensibilidade em uma única métrica, fornecendo uma média harmônica dessas duas medidas, o que é particularmente útil em cenários com desequilíbrio entre as classes.

Para calcular essas métricas, utilizam-se os termos VP (verdadeiro positivo), VN (verdadeiro negativo), FP (falso positivo) e FN (falso negativo), que representam os diferentes tipos de resultados que um modelo de classificação pode gerar. Essas métricas são fundamentais para avaliar a eficácia do modelo sob diferentes perspectivas. Enquanto a acurácia oferece uma visão geral do desempenho, a precisão, a sensibilidade e o F1-Score fornecem insights mais detalhados sobre a capacidade do modelo de lidar com classes positivas, minimizando erros de classificação. Essas definições e suas importâncias são ilustradas na Tabela 8, onde valores mais altos indicam um desempenho superior do modelo em questão.

Tabela 8 – Métricas para avaliar a classificação.

Métrica	Equação
Acurácia	$\frac{VP+VN}{VP+VN+FP+FN}$
Precisão	$\frac{VP}{VP+FP}$
Sensibilidade	$\frac{VP}{VP+FN}$
<i>F1-Score</i>	$\frac{2 \times \text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}$

No contexto desta pesquisa, procedeu-se à segmentação da base de dados em dois grupos distintos: alocou-se 80% das instâncias para constituir o conjunto de treinamento, enquanto os remanescentes 20% foram reservados para o conjunto de teste. Esta divisão foi efetuada mediante um processo de seleção estratificada, garantindo que ambas as amostras, de treinamento e de teste, refletissem a mesma proporção de instâncias para cada classe representada na base de dados. Tal estratégia assegura a representatividade e a equidade entre os conjuntos.

Tabela 9 – Parâmetros utilizados pelos modelos da literatura avaliados nos experimentos.

Classificador	Hiperparâmetro	Valores
Árvore de Decisão	critério	gini e entropy
	profundidade máxima	2, 3, 4, 5, 6, 7, 8, 9 e 10
XGBoost	taxa de aprendizagem	0.1, 0.01 e 0.001
	profundidade máxima	2, 3, 4, 5, 6, 7, 8, 9 e 10
	quantidade de estimadores	2, 4, 8 e 10
LightGBM	taxa de aprendizagem	0.1 , 0.01 e 0.001
	profundidade máxima	2, 3, 4, 5, 6, 7, 8, 9 e 10
	quantidade de estimadores	2, 4, 8 e 10
CatBoost	taxa de aprendizagem	0.1 , 0.01 e 0.001
	profundidade máxima	2, 3, 4, 5, 6, 7, 8, 9 e 10
	quantidade de estimadores	2, 4, 8 e 10

Adentrando na fase de treinamento dos modelos, a determinação dos valores dos hiperparâmetros foi realizada com base na metodologia de *Grid-search*, conforme explicitado na Tabela 9. O principal propósito desta abordagem consistiu em maximizar a Acurácia média obtida. Para tal, empregou-se a técnica de validação cruzada, utilizando especificamente 5 *folds*. Esta técnica é utilizada para assegurar a generalização e a eficácia dos modelos desenvolvidos, além de proporcionar uma avaliação mais rigorosa e abrangente dos resultados.

5.5 RESULTADOS DO MÓDULO DE CLASSIFICAÇÃO

Conforme documentado na Tabela 10, foram analisados os resultados obtidos no conjunto de teste tanto pelo sistema proposto quanto por outros modelos de classificação descritos na literatura.

Tabela 10 – Resultados das métricas para os modelos em cada classe.

Modelo	Classe	Métricas		
		Precisão	Sensibilidade	F1-Score
Árvore de decisão	0	1.00	1.00	1.00
	1	1.00	0.99	0.99
	2	0.54	0.64	0.59
	3	0.98	1.00	0.99
	4	1.00	0.96	0.98
	5	0.56	0.47	0.51
Acurácia	0.88			
Tempo de Execução	13.87s			
XGBoost	0	0.97	1.00	0.98
	1	0.99	0.98	0.98
	2	0.46	0.57	0.51
	3	0.96	0.95	0.95
	4	0.97	0.95	0.96
	5	0.48	0.38	0.42
Acurácia	0.84			
Tempo de Execução	33.6s			
LightGBM	0	1.00	1.00	1.00
	1	0.99	1.00	1.00
	2	0.40	0.43	0.41
	3	0.97	1.00	0.98
	4	1.00	0.97	0.98
	5	0.42	0.39	0.40
Acurácia	0.84			
Tempo de Execução	17.7s			
CatBoost	0	0.96	1.00	0.98
	1	0.96	0.94	0.95
	2	0.45	0.55	0.50
	3	0.92	0.97	0.95
	4	0.89	0.93	0.91
	5	0.42	0.26	0.32
Acurácia	0.82			
Tempo de Execução	89.2s			

Para a Classe 0 (sem falhas), todos os modelos tiveram um desempenho quase perfeito ou perfeito. Tanto a árvore de decisão quanto o LightGBM se destacaram, classificando todas as instâncias dessa classe corretamente. O XGBoost e o CatBoost também tiveram um desem-

penho muito bom, embora ligeiramente inferior aos dois primeiros. No geral, árvore de decisão e LightGBM foram os melhores para a Classe 0, mostrando uma classificação impecável.

Na Classe 1 (falhas entre a Fase A e Fase B), o LightGBM foi o modelo mais eficaz, conseguindo identificar todas as instâncias corretamente. A árvore de decisão teve um desempenho muito próximo, com uma pequena margem de erro. O XGBoost também mostrou uma alta *precisão* e *sensibilidade*, embora um pouco abaixo dos outros dois. O CatBoost, embora eficaz, apresentou um desempenho um pouco mais baixo em comparação aos demais. Assim, o LightGBM se destacou como o melhor modelo para a Classe 1.

A Classe 2 (Falhas trifásica) foi a mais desafiadora para todos os modelos. A árvore de decisão se destacou um pouco mais do que os outros, conseguindo identificar essa classe com um grau moderado de sucesso. O XGBoost e o CatBoost tiveram um desempenho inferior, mostrando dificuldade em distinguir corretamente as instâncias da Classe 2. O LightGBM foi o modelo que mais teve problemas com essa classe. Portanto, a árvore de decisão foi o modelo que apresentou o melhor desempenho na Classe 2, embora todos os modelos tenham tido dificuldades significativas.

Para a Classe 3 (falhas entre a Fase A e G), tanto a árvore de decisão quanto o LightGBM apresentaram um desempenho excelente, quase perfeito em termos de *precisão* e *sensibilidade*. O XGBoost teve um desempenho ligeiramente inferior, mas ainda muito bom. O CatBoost também mostrou uma alta eficácia na classificação dessa classe, embora não tão alta quanto a árvore de decisão e o LightGBM. Dessa forma, árvore de decisão e LightGBM foram os modelos que se destacaram na Classe 3.

Na Classe 4 (falha entre as Fases A, B e o Terra), o LightGBM se destacou como o modelo mais eficaz, classificando a maioria das instâncias corretamente com uma *precisão* e *sensibilidade* superiores. A árvore de decisão também teve um desempenho muito bom, apenas ligeiramente inferior ao LightGBM. O XGBoost mostrou um bom desempenho, mas não tão bom quanto os dois primeiros. O CatBoost, por sua vez, teve a menor eficácia em classificar a Classe 4 entre os quatro modelos. Portanto, o LightGBM foi o mais eficaz para a Classe 4.

A Classe 5 (Falhas trifásicas com o Terra) foi a mais problemática para todos os modelos, com alto grau de dificuldade em distingui-la corretamente. A árvore de decisão se destacou ligeiramente em comparação aos outros, embora ainda com um desempenho apenas moderado. O LightGBM e o CatBoost apresentaram maiores dificuldades em classificar corretamente esta classe, com o CatBoost sendo o que teve o pior desempenho entre todos. Apesar das dificuldades em geral, a árvore de decisão foi o que apresentou a melhor eficácia para a Classe

5, mesmo que com resultados apenas moderados.

Em termos de Acurácia, a Árvore de decisão mostrou-se superior, superando significativamente o segundo colocado, LightGBM. Este resultado evidencia que esse modelo foi mais eficiente na classificação correta de um número maior de instâncias em comparação com os outros modelos da literatura.

Analisando o tempo de execução dos algoritmos, observa-se que a árvore de decisão apresenta o menor tempo computacional, com 13.87 segundos, demonstrando uma alta eficiência em termos de processamento. Em seguida, o LightGBM, com 17.70 segundos, também mostra um bom desempenho, sendo ligeiramente mais lento que a árvore de decisão, mas ainda mantendo um tempo competitivo. O XGBoost tem um tempo de 33.60 segundos, enquanto o CatBoost registra o maior tempo de execução, com 89.21 segundos. No geral, o tempo total de execução para todos os algoritmos foi de 154.38 segundos, com um tempo médio de 38.59 segundos por algoritmo.

As Figuras 30, 31, 32 e 33 exibem as matrizes de confusão para cada um dos classificadores avaliados. Nestas matrizes, o eixo X representa as classes previstas pelos modelos, enquanto o eixo Y detalha as classes reais das instâncias no conjunto de teste. A diagonal principal das matrizes destaca o número de instâncias corretamente classificadas por classe, sendo um indicativo direto da eficácia do modelo para cada categoria específica. As matrizes proporcionam uma visão clara sobre os erros de classificação, revelando potenciais semelhanças entre duas ou mais classes.

Uma análise detalhada dessas matrizes de confusão revela que todos os modelos apresentaram a mesma eficiência na classificação correta das instâncias da Classe 0. A árvore de decisão se destacou como a melhor para as Classes 3 e 5, além de apresentar um bom desempenho nas Classes 0 e 1. O LightGBM foi o mais eficiente para as Classes 1 e 4, e também mostrou ótimo desempenho nas Classes 0 e 3. O XGBoost teve um desempenho decente em todas as classes, porém, sem se sobressair em nenhuma delas. Já o CatBoost foi eficaz para as Classes 0 e 3, mas apresentou mais confusão nas Classes 1, 2 e 5.

Observa-se ainda, nas matrizes de confusão, que as Classes 2 e 5 foram as que mais sofreram com classificações incorretas pelos modelos. Notavelmente, na maioria dos casos, os modelos tendiam a prever a Classe 5 para instâncias que de fato pertenciam à Classe 2, e vice-versa. Este padrão sugere a necessidade de intervenção de um especialista para diferenciar situações de Falha trifásica e Falha trifásica com o Terra.

Com base na comparação entre os resultados apresentados na Tabela 10 e as matrizes

de confusão, fica evidente que a árvore de Decisão e o LightGBM foram os modelos com desempenho mais destacado em relação às métricas utilizadas. Contudo, é importante notar que para duas classes específicas, a Classe 2 e a Classe 5, esses modelos apenas alcançaram resultados satisfatórios.

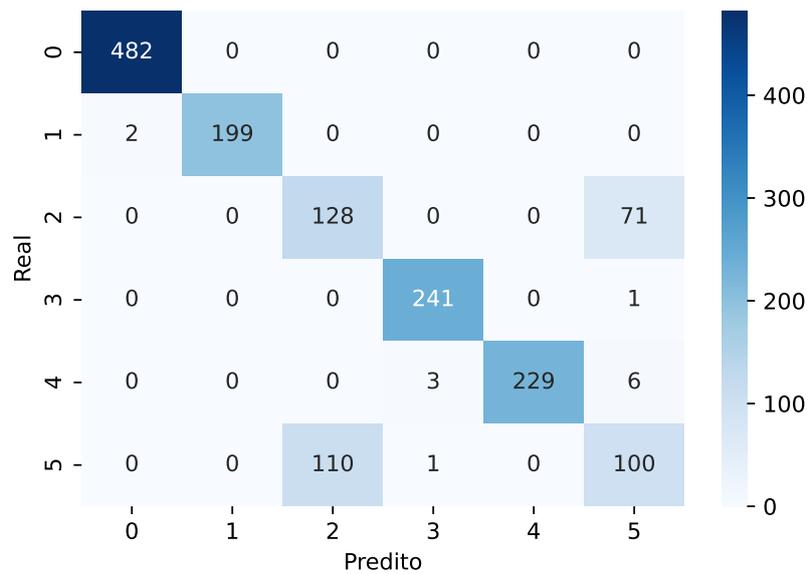


Figura 30 – Matriz de confusão obtida através das classificações da árvore de Decisão no conjunto de teste.

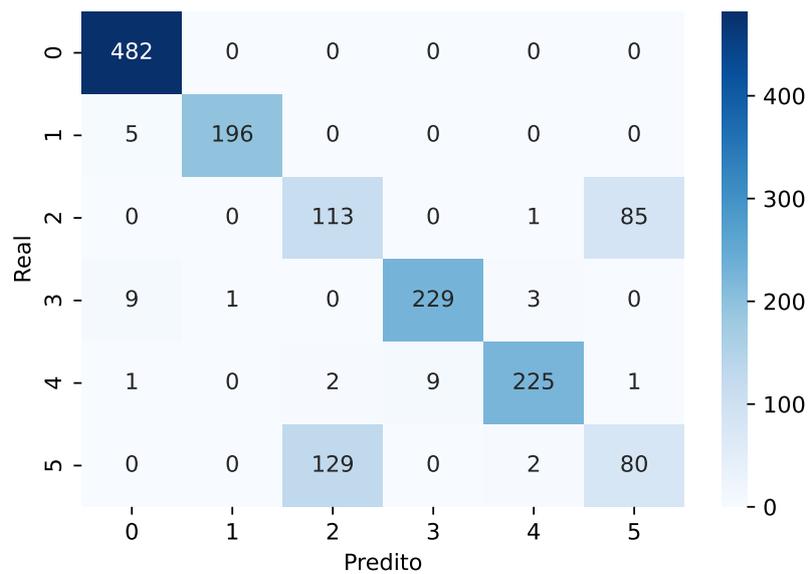


Figura 31 – Matriz de confusão obtida através das classificações do XGBoost no conjunto de teste.

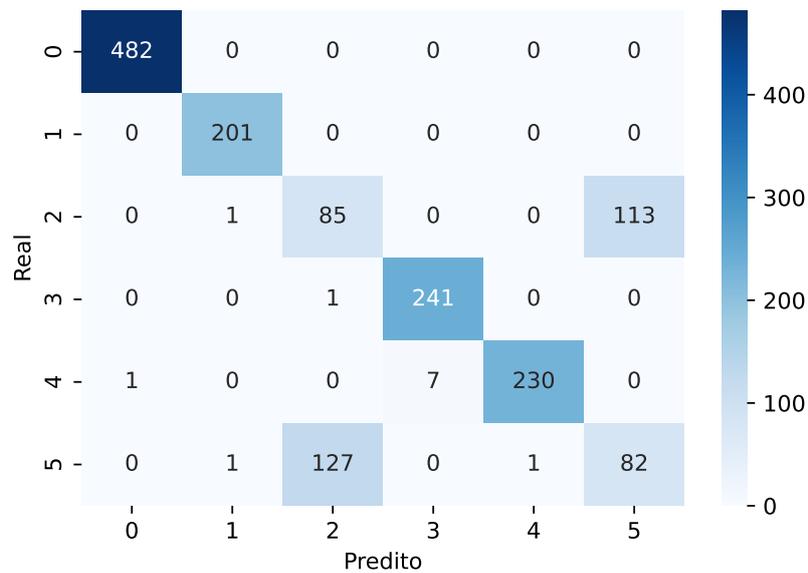


Figura 32 – Matriz de confusão obtida através das classificações do LightGBM no conjunto de teste.

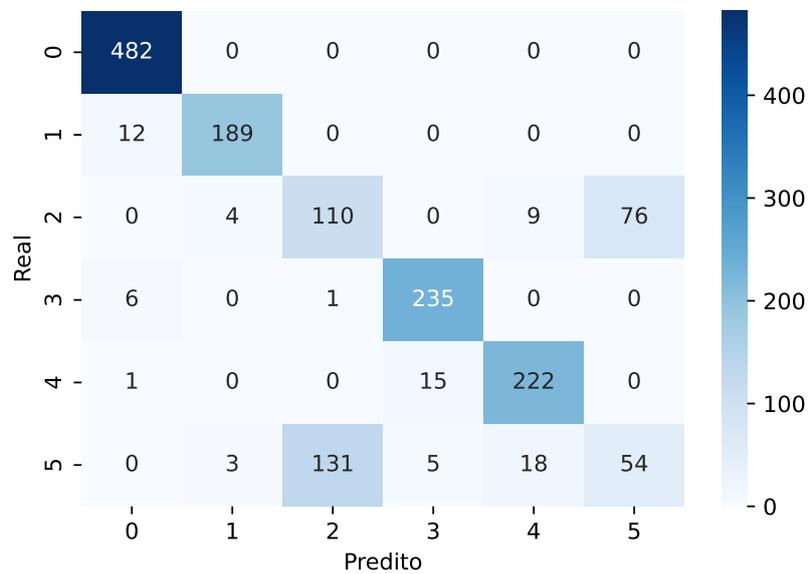


Figura 33 – Matriz de confusão obtida através das classificações do CatBoost no conjunto de teste.

5.5.1 Regras crisp extraídas

Após gerar o modelo de classificação é possível analisar o conjunto de regras geradas pelo classificador. A árvore de Decisão treinada apresenta 104 folhas que corresponde à quantidade de regras que podem ser extraídas dele. Esse conjunto de regras foi utilizado para criar as

regras de teste. Na Tabela 11 é possível visualizar a distribuição de regras por classe. É notório que as classes 2 e 5 demandaram um maior número de regras para o modelo.

Tabela 11 – Número de regras por classe.

Classe	Número de Regras
Classe 0	4
Classe 1	9
Classe 2	30
Classe 3	14
Classe 4	14
Classe 5	33

A utilização de árvores de decisão como uma ferramenta preliminar para a geração de regras *fuzzy* permite que os especialistas aproveitem a estrutura clara e os critérios de decisão das árvores para formular regras *fuzzy* mais eficazes e abrangentes. As regras geradas pela árvore de decisão servem como um guia inicial para identificar as variáveis mais relevantes e suas interações, facilitando a estruturação das regras *fuzzy*.

Este método é particularmente útil em situações onde a relação entre as variáveis de entrada e as saídas desejadas é complexa e não está claramente definida. A árvore de decisão pode revelar padrões e dependências nos dados que podem não ser imediatamente óbvios, fornecendo insights valiosos para a criação de um sistema de lógica *fuzzy* mais preciso e confiável.

A seguir são apresentadas 2 exemplos de regras geradas pela árvore para cada classe.

Classe 0

1. Se $Ia \leq 62.364$ e $Ib \leq 103.709$ e $Ic \leq 58.565$ e $Vb \leq -0.043$, então a classe é 0.
2. Se $Ia \leq 62.364$ e $Ib \leq 103.709$ e $Ic \leq 58.565$ e $Vb \leq 0.552$, então a classe é 0.

Classe 1

1. Se $Ia > -61.661$ e $Ib > -766.032$ e $Ic \leq 770.447$, então a classe é 1.
2. Se $Ic \leq -96.49$ e $Va > 0.043$ e $Vb > -0.012$, então a classe é 1.

Classe 2

1. Se $Ia \leq -61.661$ e $Ic \leq 883.758$ e $Va > -0.042$ e $Vc > -0.216$, então a classe é 2.
2. Se $Ia > -61.661$ e $Ib \leq -792.234$ e $Ic > 58.565$ e $Vc \leq 0.042$, então a classe é 2.

Classe 3

1. Se $Ia \leq -73.678$ e $Ib \leq 43.497$ e $Ic \leq 58.565$ e $Vc > -0.324$, então a classe é 3.
2. Se $Ia > 62.364$ e $Ib > -43.996$ e $Ic \leq 31.729$ e $Vb > -0.364$, então a classe é 3.

Classe 4

1. Se $Ia \leq -73.678$ e $Ib > 43.497$ e $Ic \leq 58.565$ e $Vb > 0.037$, então a classe é 4.
2. Se $Ia > 62.364$ e $Ib \leq -795.263$ e $Ic \leq 58.565$ e $Vc \leq 0.338$, então a classe é 4.

Classe 5

1. Se $Ia \leq 885.083$ e $Ic \leq -96.49$ e $Va \leq 0.042$ e $Vb > -0.042$, então a classe é 5.
2. Se $Ia \leq -72.002$ e $Ib \leq 883.198$ e $Ic \leq -96.49$ e $Va \leq 0.043$ e $Vc > -0.042$, então a classe é 5.

Essas regras são injetadas no módulo seguinte para sua devida conversão em regras *fuzzy*.

5.6 MÓDULO DE CONVERSÃO - MODELAGEM DAS VARIÁVEIS FUZZY E DAS REGRAS FUZZY

5.6.1 Variáveis *fuzzy*, Variáveis linguísticas e funções de pertinência

As três variáveis de Tensão e as três variáveis de Corrente nas linhas A, B e C foram modeladas como variáveis *fuzzy*, a partir dos limiares definidos pela árvore de decisão, bem como a variável de saída para as classes, para tanto foram extraídos da base de dados as informações básicas referentes ao universo do discurso a ser utilizado, como pode ser visto na Tabela 12.

A partir dos limiares ordenados fornecidos pelo módulo de classificação para cada variável,

Tabela 12 – Variáveis *fuzzy* e universo do discurso.

Variável <i>fuzzy</i>	Universo do Discurso	Referente	Natureza
Ia	-883.542316 885.738571	Corrente na fase A	Antecedente
Ib	-900.526951 889.868884	Corrente na fase B	Antecedente
Ic	-883.357762 901.274261	Corrente na fase C	Antecedente
Va	-0.620748 0.595342	Tensão na fase A	Antecedente
Vb	-0.608016 0.627875	Tensão na fase B	Antecedente
Vc	-0.612709 0.600179	Tensão na fase C	Antecedente
Classe	0 5	Tipo de falha	Consequente

são gerados conjuntos *fuzzy* correspondentes a cada limiar, com um conjunto à esquerda e outro à direita. Os limiares específicos para o conjunto de dados em análise estão apresentados na Tabela 13 . Antes de converter esses limiares em conjuntos *fuzzy*, é fundamental realizar uma análise criteriosa para garantir que eles sejam suficientemente espaçados. Limiares muito próximos podem resultar em conjuntos indistinguíveis, aumentando a complexidade do modelo sem ganho significativo de precisão. Nesse caso, pode-se optar por fundir limiares próximos em um único conjunto, utilizando a média entre eles.

Tabela 13 – Limiares por variável ordenados.

la	lb	lc	Va	Vb	Vc
-882.93	-893.38	-882.86	-0.07	-0.61	-0.33
-99.26	-795.79	-882.74	-0.04	-0.51	-0.19
-73.68	-793.99	-882.6	-0.03	-0.36	-0.04
-61.53	-792.23	-881.2	-0.01	-0.28	-0.02
-58.16	-775.18	-880.8	-0.0	-0.08	0.03
-55.68	-766.61	-880.25	0.04	-0.05	0.04
-47.66	-766.01	-98.41	0.18	-0.04	0.23
17.37	-752.45	-74.37	0.34	-0.0	0.31
62.36	-737.54	-61.1	0.38	0.03	0.33
744.0	-438.25	-60.18		0.04	0.34
793.6	-98.06	-21.12		0.36	
885.08	-47.13	-18.94		0.39	
	-44.0	22.7		0.55	
	-43.09	31.73			
	-35.38	41.95			
	36.65	59.79			
	43.5	63.74			
	103.71	63.82			
	446.22	91.37			
	690.65	119.19			
	707.62	749.8			
	723.9	770.45			
	800.25	899.41			
	883.2				
	883.44				

Os conjuntos gerados para cada limiar são ordenados por ordem de geração e transformados em funções de pertinência trapezoidais, como ilustrados nas Figuras 37 e 41. Seus pontos estão detalhados no apêndice A.

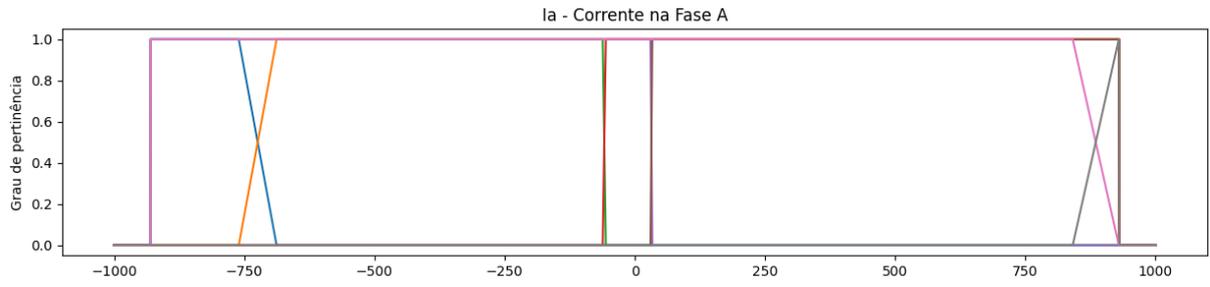


Figura 34 – Variável “Ia” modelada.

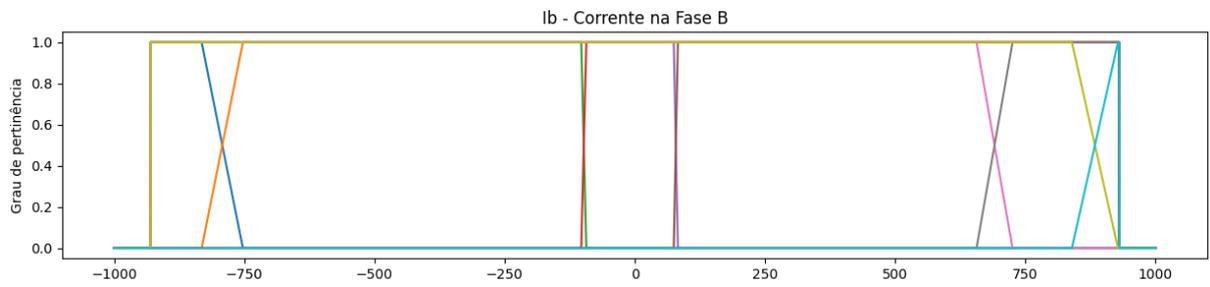


Figura 35 – Variável “Ib” modelada.

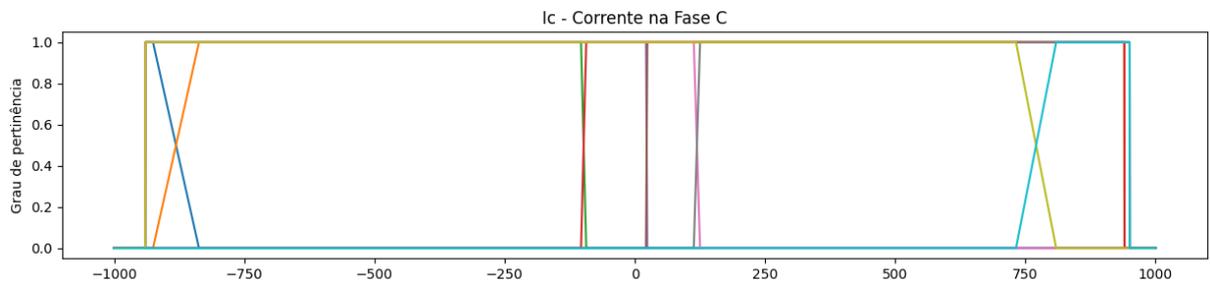


Figura 36 – Variável “Ic” modelada.

Figura 37 – Modelagem das variáveis de Corrente.

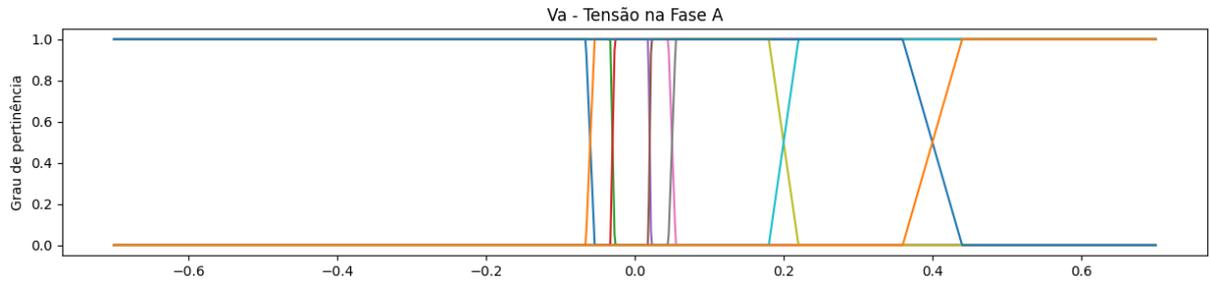


Figura 38 – Variável “Va” modelada.

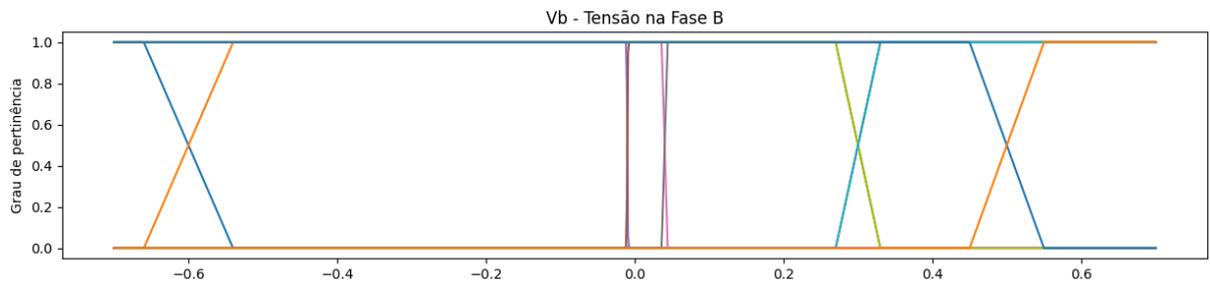


Figura 39 – Variável “Vb” modelada.

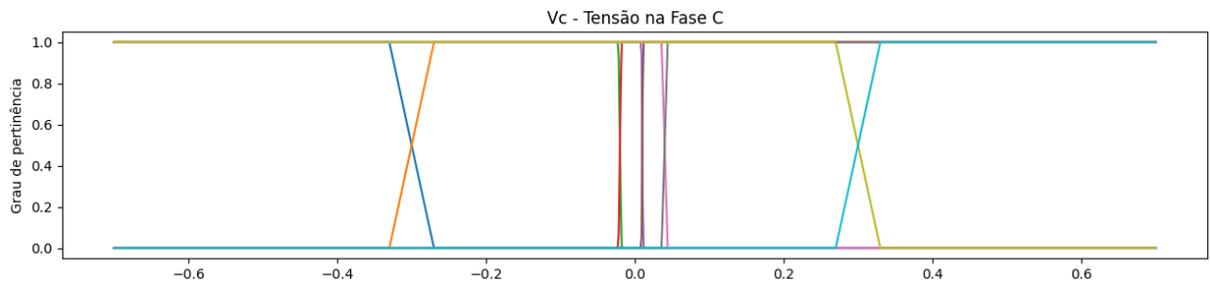


Figura 40 – Variável “Vc” modelada.

Figura 41 – Modelagem das variáveis de Tensão.

O consequente modelado é a variável de saída que representa as classes indicando o estado do sistema. Como o sistema apresenta uma classe para ausência de falha e cinco classes de falhas, foram modelados seis conjuntos *fuzzy*, cada um correspondendo a uma das seis classes da base de dados, conforme ilustrado na Figura 42.

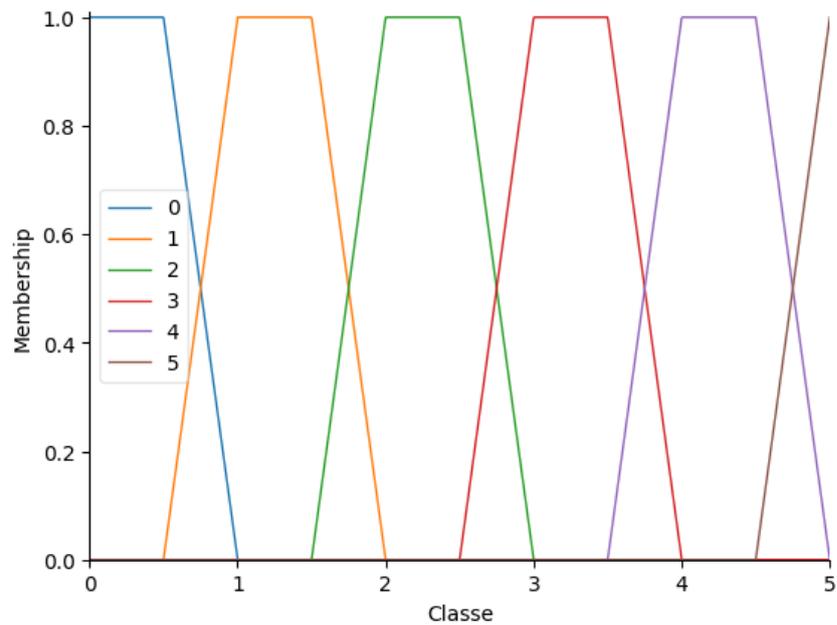


Figura 42 – Variável consequente “Classe” modelada.

5.6.2 Regras *fuzzy* modeladas

Após o processo de modelagem das variáveis *fuzzy* através do processo de conversão, as regras geradas pelas árvore de decisão foram convertidas em regras *fuzzy*.

A seguir um extrato de 6 regras enumeradas geradas pelo módulo de conversão:

1. Se $(Ia \text{ é } Cf\ 21) \wedge (Ib \text{ é } Cf\ 28) \wedge (Ic \text{ é } Cf\ 31) \wedge (Vb \text{ é } Cf\ 27)$ então classe: 0
2. Se $(Ia \text{ é } Cf\ 8) \wedge (Ib \text{ é } Cf\ 6) \wedge (Ic \text{ é } Cf\ 32)$ então classe: 1
3. Se $(Ia \text{ é } Cf\ 16) \wedge (Ic \text{ é } Cf\ 31) \wedge (Va \text{ é } Cf\ 15)$ então classe: 2
4. Se $(Ia \text{ é } Cf\ 8) \wedge (Ib \text{ é } Cf\ 5) \wedge (Ic \text{ é } Cf\ 32) \wedge (Va \text{ é } Cf\ 10) \wedge (Vb \text{ é } Cf\ 15) \wedge (Vc \text{ é } Cf\ 21)$ então classe: 3
5. Se $(Ia \text{ é } Cf\ 21) \wedge (Ib \text{ é } Cf\ 31) \wedge (Ic \text{ é } Cf\ 31) \wedge (Va \text{ é } Cf\ 17)$ então classe: 4
6. Se $(Ia \text{ é } Cf\ 8) \wedge (Ib \text{ é } Cf\ 6) \wedge (Ic \text{ é } Cf\ 32) \wedge (Va \text{ é } Cf\ 4) \wedge (Vc \text{ é } Cf\ 10)$ então classe: 5

O conjunto de regras estabelecido para a classificação de falhas demonstra um mapeamento eficaz e lógico entre as variáveis de entrada, representadas pelos estados de corrente e tensão, e as classes de falhas correspondentes.

Essa estrutura de regras é facilmente ajustável para novas condições ou refinamentos nos conjuntos *fuzzy*, sendo uma ferramenta versátil para diagnóstico e pesquisa em sistemas de transmissão elétrica. Em testes de classificação de falhas, essas regras devem discriminar eficazmente várias condições de falha, contribuindo para a operação segura e eficiente dos

sistemas de energia.

5.7 RESULTADO DO MÓDULO DE SISTEMAS *FUZZY*

Os resultados obtidos para os diversos métodos de defuzzificação presentes na Tabela 14 — CEN, BA, MDM, PDM, UDM — oferecem insights profundos sobre o desempenho do modelo em tarefas de classificação, permitindo uma avaliação criteriosa de cada abordagem. Estes métodos apresentam variações notáveis nas métricas de Acurácia, Precisão, Sensibilidade e *F1-Score*, refletindo suas respectivas eficácias.

Tabela 14 – Resultados dos Métodos de defuzzificação.

Método	Acurácia	Precisão	Sensibilidade	F1 Score
CEN	0.7711	0.7780	0.7711	0.7546
BA	0.8360	0.8347	0.8360	0.8207
MDM	0.8741	0.8772	0.8741	0.8742
PDM	0.7686	0.7654	0.7686	0.7581
UDM	0.7883	0.7842	0.7883	0.7851

5.7.1 Comparação de Desempenho entre Métodos

5.7.1.1 Desempenho Geral

O método MDM destaca-se com o melhor desempenho em todas as métricas, indicando que essa abordagem de defuzzificação é particularmente eficaz para o conjunto de dados em análise. Os resultados sugerem que a definição de decisão baseada nos valores máximos de pertinência é mais adequada para minimizar ambiguidades na classificação.

O método BA também apresenta um desempenho robusto, superando significativamente os métodos CEN e PDM em termos de Acurácia, Precisão e *F1-Score*. Isso pode ser atribuído à sua capacidade de equilibrar a área sob a curva de pertinência, oferecendo um critério de decisão equilibrado que se adapta bem a certas distribuições de dados.

Os métodos PDM e UDM apresentam desempenhos variados, com o UDM superando o PDM. Isso indica que, embora ambos priorizem valores extremos de pertinência, as especificidades de cada conjunto de dados podem favorecer ligeiramente diferentes abordagens de defuzzificação baseadas em máximo.

5.7.1.2 Método Centroide

Este método apresenta o menor desempenho entre os métodos analisados. A natureza do CEN, focada na distribuição geral da função de pertinência, pode não ser ideal para conjuntos de dados onde a decisão de classificação beneficia-se de uma abordagem mais focada nos valores extremos.

5.7.2 Sensibilidade e Precisão

A consistência na Sensibilidade entre os métodos reforça a capacidade do modelo de identificar corretamente as instâncias positivas. A Precisão, sendo geralmente mais alta do que a Sensibilidade para todos os métodos, indica uma eficiência na minimização de falsos positivos, com o método MDM mostrando a melhor balança entre essas métricas.

5.7.3 F1-Score

O *F1-Score* confirma a superioridade do método MDM sobre os demais, oferecendo um equilíbrio ótimo entre Precisão e Sensibilidade. Esse resultado reforça a eficácia de abordagens de defuzzificação que se concentram nos valores máximos de pertinência para a classificação.

5.7.4 Conclusão

Os resultados destacam o método MDM como a abordagem de defuzzificação mais eficaz para este modelo e conjunto de dados específicos, enfatizando a importância dos valores máximos de pertinência na decisão de classificação. A análise sublinha a necessidade de considerar as características específicas do conjunto de dados ao escolher um método de defuzzificação, pois isso pode impactar significativamente o desempenho do modelo. A escolha criteriosa do método de defuzzificação é, portanto, crucial para otimizar a precisão e a eficiência de modelos de classificação *fuzzy*.

6 CONCLUSÃO

6.1 RESUMO DO TRABALHO

No decorrer deste estudo, foi desenvolvido e implementado uma metodologia destinada ao diagnóstico de problemas em SEP. Ao longo da pesquisa, foi explorada a eficácia dessa metodologia na detecção e classificação de falhas em linhas de transmissão, apresentando resultados promissores em diferentes cenários de teste.

A construção da metodologia enfatizou a geração automática de conjuntos e regras, a conversão desses em conjuntos e regras *fuzzy*, bem como seu teste em um motor de inferência. O sistema demonstrou sua capacidade de lidar com a complexidade dos SEP, considerando variáveis inter-relacionadas e uma ampla gama de casos de falha.

6.2 QUESTÕES DA PESQUISA

Nesta seção são apresentadas as respostas para as questões de pesquisa com base nos resultados do capítulo anterior, levando em consideração os resultados e a base de dados utilizada neste trabalho.

6.2.1 Como a conversão de uma base de regras extraída de um árvore de decisão em uma base de regras *fuzzy* pode contribuir para a modelagem de conhecimento no diagnóstico de sistemas elétricos de potência?

A conversão de uma base de regras extraída de uma árvore de decisão em uma base de regras *fuzzy* permite incorporar a capacidade de lidar com incertezas e imprecisões inerentes aos SEP. Árvores de decisão fornecem regras claras e objetivas baseadas nos dados, porém muitas vezes não capturam adequadamente a natureza ambígua dos fenômenos em sistemas elétricos. A transformação dessas regras em regras *fuzzy* facilita a modelagem de conhecimento ao permitir que variáveis sejam representadas por conjuntos *fuzzy*, em vez de valores precisos, refletindo melhor a realidade operacional dos sistemas. Isso resulta em um diagnóstico mais robusto, capaz de lidar com situações complexas e variáveis contínuas de forma mais intuitiva e representativa.

6.2.2 De que forma a metodologia proposta contribui para o desenvolvimento de modelos precisos e regras representativas na construção de sistemas *fuzzy* voltados à detecção de falhas em sistemas elétricos de potência?

A metodologia combina regras extraídas de árvores de decisão com a lógica *fuzzy*, incorporando diferentes métodos de defuzzificação para gerar diferentes modelos de sistema *fuzzy*, permitindo ao especialista escolher aquele que melhor se adapta ao seu caso. Isso torna o sistema adaptável ao contexto específico do especialista, permitindo interpretar os resultados de forma mais adequada às particularidades do cenário. Assim, ela gera modelos mais representativos e precisos, melhorando a detecção de falhas nos sistemas elétricos de potência.

6.3 PRINCIPAIS CONTRIBUIÇÕES DA TESE

Os resultados obtidos pelo método proposto validam a proposição de que é viável empregar sistemas *fuzzy* para a classificação de falhas em SEP. As contribuições significativas desta pesquisa incluem:

1. Avaliação de diferentes algoritmos de *aprendizado de máquina* para seleção do mais adequado na geração de regras.
2. Desenvolvimento de uma metodologia para a conversão automática de conjuntos *crisps* em conjuntos *fuzzy*. Esta abordagem permite representar de forma mais abrangente e precisa o domínio das variáveis envolvidas, otimizando a classificação de falhas.
3. Criação de um processo automático para a geração de regras *fuzzy* que refletem com fidelidade o conjunto de dados analisado, promovendo uma classificação mais acurada e confiável de falhas.

Em resumo, a abordagem proposta fornece uma metodologia inovadora e eficaz para a geração de conjuntos e regras *fuzzy*, melhorando significativamente a aplicabilidade e desempenho em sistemas de controle e classificação *fuzzy*. Além disso, facilita a personalização da configuração gerada, permitindo ajustes precisos antes da implementação final, o que assegura uma aplicação mais eficiente e adaptada às necessidades específicas.

6.4 LIMITAÇÕES DA PESQUISA

Este estudo apresenta algumas limitações importantes que merecem ser destacadas. Primeiramente, o uso exclusivo de um único tipo de classificador para a geração de regras pode limitar a diversidade das configurações dos conjuntos *fuzzy* e das bases de regras obtidas. A incorporação de outros classificadores, além da árvore de decisão, poderia potencialmente resultar em conjuntos *fuzzy* com diferentes configurações.

Além disso, é importante ressaltar que a base de dados utilizada neste estudo pode não oferecer uma representação completa e abrangente do comportamento de uma rede de transmissão e seus componentes. Esta limitação pode influenciar a generalização dos resultados e sua aplicabilidade em contextos mais amplos.

6.5 TRABALHOS FUTUROS

Apesar dos avanços significativos alcançados nesta pesquisa, o campo de diagnóstico em SEP continua a oferecer oportunidades para aprimoramentos e expansões futuras. Algumas direções para pesquisas subsequentes incluem:

1. Testes com Diferentes Conjuntos de Dados: É essencial avaliar a capacidade da metodologia em lidar com diferentes bases de dados, abrangendo diversos tipos de casos e cenários, a fim de aprimorar sua robustez.
2. Exploração de Métodos Alternativos: A pesquisa futura pode explorar outros algoritmos de aprendizado de máquina na geração de regras para aprimorar ainda mais a capacidade de diagnóstico.
3. Design de sistemas *fuzzy* interpretáveis: Apesar da abordagem oferecer suporte à criação de variáveis, conjuntos, regras e métodos de defuzzificação variados, é possível explorar outras formas que garantam maior interpretabilidade, principalmente em relação a quantidade de termos linguísticos ligados às variáveis *fuzzy* e à quantidade de regras.
4. Testes em Ambientes Reais: A validação da metodologia em sistemas de potência reais é fundamental para avaliar sua eficácia em cenários práticos e sua viabilidade de implementação.

Este estudo representa um avanço importante no desenvolvimento de sistemas *fuzzy* para o diagnóstico de problemas em SEP. À medida que a demanda por energia elétrica continua a crescer, aprimorar as capacidades de diagnóstico desempenha um papel crítico na garantia

da confiabilidade e eficiência dos sistemas elétricos. As pesquisas futuras se concentrarão em abordar esses desafios e buscar soluções inovadoras para os problemas complexos enfrentados na indústria de energia.

REFERÊNCIAS

- ACKERMAN, W. J. Substation automation and the ems. In: IEEE. *Proceedings of the 20th Transmission and Distribution Conference*. New Orleans, 1999. p. 274–279.
- ADHIKARI, S.; SINHA, N.; DORENDRAJIT, T. *Fuzzy logic based on-line fault detection and classification in transmission line*. SpringerPlus. 2016.
- Agência Nacional de Energia Elétrica (ANEEL). *Glossário da Energia Elétrica, Resolução Normativa ANEEL n. 1.000*. 2021. Diário Oficial, de 20 dez. 2021, seção 1, p. 206. [Online; acessado em 10-Jan-2024]. Disponível em: <<https://www2.aneel.gov.br/cedoc/ren20211000.pdf>>.
- ALTHI, T. R.; KOLEY, E.; GHOSH, S. Fuzzy logic based fault detection and classification scheme for series faults in six phase transmission line. In: *2021 7ª Conferência Internacional sobre Sistemas de Energia Elétrica (ICEES)*. [S.l.: s.n.], 2021. p. 479–483.
- ANDRADE-BENAVIDES, D.; VALLEJO-HUANGA, D.; MORILLO, P. Fuzzy logic model for failure analysis in electric power distribution systems. *Procedia Computer Science*, v. 204, p. 497–504, 2022. ISSN 1877-0509. International Conference on Industry Sciences and Computer Science Innovation.
- AWALIN, L.; NAIDU, K.; SUYONO, H. Fault types classification using support vector machine (svm). In: . [S.l.: s.n.], 2019. v. 2129, p. 020132.
- BICHELS, A. *Sistemas elétricos de potência: métodos de análise e solução*. [S.l.]: EDUTFPR, 2018.
- BIH, J. Paradigm shift—an introduction to fuzzy logic. *IEEE potentials*, IEEE, v. 25, n. 1, p. 6–21, 2006.
- BISWAL, M.; DASH, P. K. Measurement and classification of simultaneous power signal patterns with an s-transform variant and fuzzy decision tree. *IEEE Transactions on Industrial Informatics*, IEEE, v. 9, n. 4, p. 1819–1827, 2012.
- BRANCO, H. M. G. C. *Uma estratégia para a detecção e classificação de transitórios em transformadores de potência pela utilização da transformada Wavelet e da lógica Fuzzy*. Tese (Doutorado) — Universidade de São Paulo, 2009.
- CARTER, J.; CHICLANA, F.; KHUMAN, A. S.; CHEN, T. *Fuzzy logic: recent applications and developments*. Springer Nature, 2021.
- CHARBUTY, B.; ABDULAZEEZ, A. Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, v. 2, n. 01, p. 20–28, 2021.
- CHEN, M.; LIU, Q.; CHEN, S.; LIU, Y.; ZHANG, C.-H.; LIU, R. Xgboost-based algorithm interpretation and application on post-fault transient stability status prediction of power system. *IEEE Access*, IEEE, v. 7, p. 13149–13158, 2019.
- CHOPDAR, S. M.; KOSHTI, A. Fault detection and classification in power system using artificial neural network. In: *2022 2nd International Conference on Intelligent Technologies (CONIT)*. [S.l.: s.n.], 2022. p. 1–6.

- DEVELOPERS, T. S.-F. *scikit-fuzzy: Fuzzy Logic Toolbox for Python*. 2022. [Online; acessado em 10-Jan-2023]. Disponível em: <<https://github.com/scikit-fuzzy/scikit-fuzzy>>.
- EICH, B. *JavaScript*. 1995. <<https://www.mozilla.org/>>. Linguagem de programação.
- FERREIRA, V.; ZANGHI, R.; FORTES, M.; SOTELO, G.; SILVA, R.; SOUZA, J.; GUIMARÃES, C.; GOMES, S. A survey on intelligent system application to fault diagnosis in electric power system transmission lines. *Electric Power Systems Research*, v. 136, p. 135–153, 2016.
- FRAZAO, R. J. A. *Proteção do sistema elétrico de potência*. Londrina: Editora e Distribuidora Educacional S.A., 2019. 200 p.
- GEDRA, R. L.; BARROS, B. F.; BORELLI, R. *Geração, Transmissão, Distribuição e Consumo de Energia Elétrica*. 1. ed. São Paulo: Érica, 2014.
- GIL, E.; SIVILLA, J.; GONZÁLEZ, A. et al. Fuzzy logic applied to the diagnosis of technical conditions of distribution transformers. *Journal of Engineering and Applied Science*, Springer, v. 70, p. 129, 2023.
- GUIMARAES, C. H. *Sistemas Elétricos de Potência e seus Principais Componentes 2ª Edição*. [S.l.: s.n.], 2021.
- HALL, L. O.; LANDE, P. Generation of fuzzy rules from decision trees. *J. Adv. Comput. Intell. Intell. Informatics*, v. 2, p. 128–133, 1998.
- HIPP, D. R. *SQLite*. 2000. <<https://www.sqlite.org/>>. Sistema de gerenciamento de banco de dados relacional.
- IBRAHIM, O.; BAKARE, M. S.; AMOSA, T. I.; OTUOZE, A. O.; OWONIKOKO, W. O.; ALI, E. M.; ADESINA, L. M.; OGUNBIYI, O. Development of fuzzy logic-based demand-side energy management system for hybrid energy sources. *Energy Conversion and Management: X*, v. 18, p. 100354, 2023. ISSN 2590-1745.
- JAMEHBOZORG, A.; SHAHRTASH, S. A decision tree-based method for fault classification in double-circuit transmission lines. *IEEE transactions on power delivery*, IEEE, v. 25, n. 4, p. 2184–2189, 2010.
- JAMIL, M.; SHARMA, S. K.; SINGH, R. Fault detection and classification in electrical power transmission system using artificial neural network. *SpringerPlus*, SpringerOpen, v. 4, n. 1, p. 1–13, 2015.
- JANARTHANAM, K.; KAMALESH, P.; BASIL, T. V.; KOVILPILLAI, A. K. J. Electrical Faults-Detection and Classification using Machine Learning. In: *2022 International Conference on Electronics and Renewable Systems (ICEARS)*. [S.l.: s.n.], 2022. p. 1289–1295.
- JANG, J.-S. R.; SUN, C.-T.; MIZUTANI, E. Neuro-fuzzy and soft computing-a computational approach to learning and machine intelligence [book review]. *IEEE Transactions on automatic control*, IEEE, v. 42, n. 10, p. 1482–1484, 1997.
- JR, G. C.; ROLIM, J. G.; ZÜRIN, H. H. Diagnóstico de faltas em sistemas de potência: definição do problema e abordagens via inteligência artificial. *Sba: Controle & Automação Sociedade Brasileira de Automática*, SciELO Brasil, v. 15, n. 2, 2004.

- KAGAN, N.; OLIVEIRA, C. C. B. de; ROBBA, E. J. *Introdução aos sistemas de distribuição de energia elétrica*. 2. ed. São Paulo: Edgard Blucher, 2010.
- KLIR, G. J.; YUAN, B. *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. [S.l.]: Prentice Hall, 1995.
- KONTOGIANNIS, D.; BARGIOTAS, D.; DASKALOPULU, A. Fuzzy control system for smart energy management in residential buildings based on environmental data. *Energies*, v. 14, p. 752, 02 2021.
- LIU, C.; RATHER, Z.; CHEN, Z.; BAK, C. An overview of decision tree applied to power systems. *International Journal of Smart Grid and Clean Energy*, p. 413–419, 01 2013.
- MAHANTY, R.; GUPTA, P. D. A fuzzy logic based fault classification approach using current samples only. *Electric Power Systems Research*, v. 77, n. 5, p. 501–507, 2007. ISSN 0378-7796.
- MAIA, W. U. L. d. A. *Sistema integrado de operação e diagnóstico de falhas para sistemas de energia elétrica - SODF*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Centro Tecnológico, 1998. Dissertação (Mestrado).
- MALLAT, S. *A wavelet tour of signal processing*. [S.l.]: Elsevier, 1999.
- MAMDANI, E. Application of fuzzy algorithms for control of simple dynamic plant. *Proceedings of the Institution of Electrical Engineers*, v. 121, n. 12, p. 1585–1588, 1974.
- MathWorks Inc. *MATLAB - software for numerical computing*. 2010. MathWorks Inc. Versão 7.10.0 (R2010a). Disponível em: <<https://www.mathworks.com/products/matlab.html>>.
- MEDEIROS, E. B. et al. Uma nova abordagem para diagnósticos de falta no sistema elétrico baseado em redes de petri coloridas. In: *XII ERIAC (Décimo Segundo Encontro Regional Ibero-americano do CIGRÉ)*. [S.l.: s.n.], 2007.
- NANDHINI, K.; PRAJITH, C. A. Review on fault detection and classification in transmission line using machine learning methods. In: *2023 International Conference on Control, Communication and Computing (ICCC)*. [S.l.: s.n.], 2023. p. 1–6.
- OBREGON, J.; JUNG, J.-Y. Rulecosi+: Rule extraction for interpreting classification tree ensembles. *Information Fusion*, v. 89, p. 355–381, 2023. ISSN 1566-2535.
- OGAR, V. N.; HUSSAIN, S.; GAMAGE, K. A. Transmission line fault classification of multi-dataset using catboost classifier. *Signals*, MDPI, v. 3, n. 3, p. 468–482, 2022.
- OGAR, V. N.; HUSSAIN, S.; GAMAGE, K. A. The use of artificial neural network for low latency of fault detection and localisation in transmission line. *Heliyon*, v. 9, n. 2, p. e13376, 2023. ISSN 2405-8440.
- PARADAVA, V. N.; SHIVANI, S. N.; CHAUDHARI, M. A. Islanding detection in distributed generation using fuzzy logic. *International Journal For Technological Research In Engineering*, GEC, Bhuj, Gujarat, India, v. 4, n. 8, p. 1471, April 2017.
- RAINIO, O.; TEUHO, J.; KLÉN, R. Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, Springer Nature, v. 14, n. 6086, 2024.

- RAMOT, D.; FRIEDMAN, M.; LANGHOLZ, G.; KANDEL, A. Complex fuzzy logic. *IEEE Transactions on Fuzzy Systems*, v. 11, n. 4, p. 450–461, 2003.
- RAZI, K.; HAGH, M. T.; AHRABIAN, G. High accurate fault classification of power transmission lines using fuzzy logic. In: *2007 International Power Engineering Conference (IPEC 2007)*. [S.l.: s.n.], 2007. p. 42–46.
- RONACHER, A. *Flask*. 2010. <<https://palletsprojects.com/p/flask/>>. Micro web framework for Python.
- ROSS, T. J. *Fuzzy Logic with Engineering Applications*. [S.l.]: John Wiley & Sons, 2004.
- SABERI, A. N.; BELAHCEN, A.; SOBRA, J.; VAIMANN, T. Lightgbm-based fault diagnosis of rotating machinery under changing working conditions using modified recursive feature elimination. *IEEE Access*, v. 10, p. 81910–81925, 2022.
- SAGI, O.; ROKACH, L. Approximating XGBoost with an interpretable decision tree. *Information Sciences*, Elsevier, v. 572, p. 522–542, 2021.
- SAHOO, S.; MOHANTY, S. K. A novel approach of svm for fault detection and classification in a series compensated line. In: IEEE. *2021 Innovations in Power and Advanced Computing Technologies (i-PACT)*. [S.l.], 2021. p. 1–5.
- SAMANTARAY, S. Decision tree-initialised fuzzy rule-based approach for power quality events classification. *Generation, Transmission Distribution, IET*, v. 4, p. 530 – 537, 05 2010.
- SAMANTARAY, S. R.; EL-ARROUDI, K.; JOÓŠ, G.; KAMWA, I. A fuzzy rule-based approach for islanding detection in distributed generation. *IEEE Transactions on Power Delivery*, v. 25, n. 3, p. 1427–1433, 2010.
- SILVA, R. S. d. *Sistemas Eléctricos de Potência I*. Londrina: Editora e Distribuidora Educacional S.A., 2019. 192 p. ISBN 978-85-522-1460-1.
- SUNDARARAMAN, B.; JAIN, P. Fault detection and classification in electrical power transmission system using wavelet transform. *Engineering Proceedings*, v. 59, n. 1, 2023.
- SWETAPADMA, A.; YADAV, A. Data-mining-based fault during power swing identification in power transmission system. *IET Science, Measurement & Technology*, Wiley Online Library, v. 10, n. 2, p. 130–139, 2016.
- SYROMIATNIKOV, A.; WEYNS, D. A journey through the land of model-view-design patterns. In: . [S.l.: s.n.], 2014. p. 21–30. ISBN 978-1-4799-3412-6.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, v. 15, n. 1, p. 116–132, 1985.
- USIDA, W. F. Controle fuzzy para melhoria do perfil de tensão em sistemas de distribuição de energia elétrica. *Diss.(Mestrado em Eng. Elétrica)-Univ. São Paulo-Esc. Eng. São Carlos, São Carlos, São Paulo*, 2007.
- VALSAN, S. P.; SWARUP, K. Wavelet transform based digital protection for transmission lines. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 31, n. 7-8, p. 379–388, 2009.

VASCONCELOS, F. M. d. *Geração, transmissão e distribuição de energia elétrica*. Londrina: Editora e Distribuidora Educacional S.A., 2017. 224 p. ISBN 978-85-522-0179-3.

VENKATA, P.; PANDYA, V.; VALA, K.; SANT, A. V. Support vector machine for fast fault detection and classification in modern power systems using quarter cycle data. *Energy Reports*, v. 8, p. 92–98, 2022.

XU, K. Fault diagnosis method of power system based on neural network. In: *2018 International Conference on Virtual Reality and Intelligent Systems (ICVRIS)*. [S.l.: s.n.], 2018. p. 172–175.

ZADEH, L. A. Fuzzy sets: information and control. *Elsevier*, v. 3, p. 235–354, 1965.

ZHAO, X.; ZHANG, X. Artificial intelligence applications in power system. In: . [s.n.], 2016. Disponível em: <<https://api.semanticscholar.org/CorpusID:64382590>>.

ZIMMERMANN, H.-J. Fuzzy set theory. *Wiley interdisciplinary reviews: computational statistics*, Wiley Online Library, v. 2, n. 3, p. 317–332, 2010.

APÊNDICE A – PARÂMETROS DAS FUNÇÕES TRAPEZOIDAIS PARA CADA VARIÁVEL

Variable	Limiar	Conjunto à esquerda	Conjunto à direita
Ia	-882.93	[-883.54, -883.54, -927.08, -838.78]	[-927.08, -838.78, 885.74, 885.74]
Ia	-99.26	[-883.54, -883.54, -104.22, -94.3]	[-104.22, -94.3, 885.74, 885.74]
Ia	-73.68	[-883.54, -883.54, -77.36, -70.0]	[-77.36, -70.0, 885.74, 885.74]
Ia	-61.53	[-883.54, -883.54, -64.61, -58.45]	[-64.61, -58.45, 885.74, 885.74]
Ia	-58.16	[-883.54, -883.54, -61.07, -55.25]	[-61.07, -55.25, 885.74, 885.74]
Ia	-55.68	[-883.54, -883.54, -58.46, -52.9]	[-58.46, -52.9, 885.74, 885.74]
Ia	-47.66	[-883.54, -883.54, -50.04, -45.28]	[-50.04, -45.28, 885.74, 885.74]
Ia	17.37	[-883.54, -883.54, 16.5, 18.24]	[16.5, 18.24, 885.74, 885.74]
Ia	62.36	[-883.54, -883.54, 59.24, 65.48]	[59.24, 65.48, 885.74, 885.74]
Ia	744	[-883.54, -883.54, 706.8, 781.2]	[706.8, 781.2, 885.74, 885.74]
Ia	793.6	[-883.54, -883.54, 753.92, 833.28]	[753.92, 833.28, 885.74, 885.74]
Ia	885.08	[-883.54, -883.54, 840.83, 929.33]	[840.83, 929.33, 885.74, 885.74]
Ib	-893.38	[-900.53, -900.53, -938.05, -848.71]	[-938.05, -848.71, 889.87, 889.87]
Ib	-795.79	[-900.53, -900.53, -835.58, -756.0]	[-835.58, -756.0, 889.87, 889.87]
Ib	-793.99	[-900.53, -900.53, -833.69, -754.29]	[-833.69, -754.29, 889.87, 889.87]
Ib	-792.23	[-900.53, -900.53, -831.84, -752.62]	[-831.84, -752.62, 889.87, 889.87]
Ib	-775.18	[-900.53, -900.53, -813.94, -736.42]	[-813.94, -736.42, 889.87, 889.87]
Ib	-766.61	[-900.53, -900.53, -804.94, -728.28]	[-804.94, -728.28, 889.87, 889.87]
Ib	-766.01	[-900.53, -900.53, -804.31, -727.71]	[-804.31, -727.71, 889.87, 889.87]
Ib	-752.45	[-900.53, -900.53, -790.07, -714.83]	[-790.07, -714.83, 889.87, 889.87]
Ib	-737.54	[-900.53, -900.53, -774.42, -700.66]	[-774.42, -700.66, 889.87, 889.87]
Ib	-438.25	[-900.53, -900.53, -460.16, -416.34]	[-460.16, -416.34, 889.87, 889.87]
Ib	-98.06	[-900.53, -900.53, -102.96, -93.16]	[-102.96, -93.16, 889.87, 889.87]
Ib	-47.13	[-900.53, -900.53, -49.49, -44.77]	[-49.49, -44.77, 889.87, 889.87]
Ib	-44	[-900.53, -900.53, -46.2, -41.8]	[-46.2, -41.8, 889.87, 889.87]
Ib	-43.09	[-900.53, -900.53, -45.24, -40.94]	[-45.24, -40.94, 889.87, 889.87]
Ib	-35.38	[-900.53, -900.53, -37.15, -33.61]	[-37.15, -33.61, 889.87, 889.87]
Ib	36.65	[-900.53, -900.53, 34.82, 38.48]	[34.82, 38.48, 889.87, 889.87]
Ib	43.5	[-900.53, -900.53, 41.32, 45.68]	[41.32, 45.68, 889.87, 889.87]
Ib	103.71	[-900.53, -900.53, 98.52, 108.9]	[98.52, 108.9, 889.87, 889.87]
Ib	446.22	[-900.53, -900.53, 423.91, 468.53]	[423.91, 468.53, 889.87, 889.87]
Ib	690.65	[-900.53, -900.53, 656.12, 725.18]	[656.12, 725.18, 889.87, 889.87]
Ib	707.62	[-900.53, -900.53, 672.24, 743.0]	[672.24, 743.0, 889.87, 889.87]
Ib	723.9	[-900.53, -900.53, 687.7, 760.1]	[687.7, 760.1, 889.87, 889.87]
Ib	800.25	[-900.53, -900.53, 760.24, 840.26]	[760.24, 840.26, 889.87, 889.87]
Ib	883.2	[-900.53, -900.53, 839.04, 927.36]	[839.04, 927.36, 889.87, 889.87]

Ib	883.44	[-900.53, -900.53, 839.27, 927.61]	[839.27, 927.61, 889.87, 889.87]
Ic	-882.86	[-883.36, -883.36, -927.0, -838.72]	[-927.0, -838.72, 901.27, 901.27]
Ic	-882.74	[-883.36, -883.36, -926.88, -838.6]	[-926.88, -838.6, 901.27, 901.27]
Ic	-882.6	[-883.36, -883.36, -926.73, -838.47]	[-926.73, -838.47, 901.27, 901.27]
Ic	-881.2	[-883.36, -883.36, -925.26, -837.14]	[-925.26, -837.14, 901.27, 901.27]
Ic	-880.8	[-883.36, -883.36, -924.84, -836.76]	[-924.84, -836.76, 901.27, 901.27]
Ic	-880.25	[-883.36, -883.36, -924.26, -836.24]	[-924.26, -836.24, 901.27, 901.27]
Ic	-98.41	[-883.36, -883.36, -103.33, -93.49]	[-103.33, -93.49, 901.27, 901.27]
Ic	-74.37	[-883.36, -883.36, -78.09, -70.65]	[-78.09, -70.65, 901.27, 901.27]
Ic	-61.1	[-883.36, -883.36, -64.16, -58.05]	[-64.16, -58.05, 901.27, 901.27]
Ic	-60.18	[-883.36, -883.36, -63.19, -57.17]	[-63.19, -57.17, 901.27, 901.27]
Ic	-21.12	[-883.36, -883.36, -22.18, -20.06]	[-22.18, -20.06, 901.27, 901.27]
Ic	-18.94	[-883.36, -883.36, -19.89, -17.99]	[-19.89, -17.99, 901.27, 901.27]
Ic	22.7	[-883.36, -883.36, 21.56, 23.84]	[21.56, 23.84, 901.27, 901.27]
Ic	31.73	[-883.36, -883.36, 30.14, 33.32]	[30.14, 33.32, 901.27, 901.27]
Ic	41.95	[-883.36, -883.36, 39.85, 44.05]	[39.85, 44.05, 901.27, 901.27]
Ic	59.79	[-883.36, -883.36, 56.8, 62.78]	[56.8, 62.78, 901.27, 901.27]
Ic	63.74	[-883.36, -883.36, 60.55, 66.93]	[60.55, 66.93, 901.27, 901.27]
Ic	63.82	[-883.36, -883.36, 60.63, 67.01]	[60.63, 67.01, 901.27, 901.27]
Ic	91.37	[-883.36, -883.36, 86.8, 95.94]	[86.8, 95.94, 901.27, 901.27]
Ic	119.19	[-883.36, -883.36, 113.23, 125.15]	[113.23, 125.15, 901.27, 901.27]
Ic	749.8	[-883.36, -883.36, 712.31, 787.29]	[712.31, 787.29, 901.27, 901.27]
Ic	770.45	[-883.36, -883.36, 731.93, 808.97]	[731.93, 808.97, 901.27, 901.27]
Ic	899.41	[-883.36, -883.36, 854.44, 944.38]	[854.44, 944.38, 901.27, 901.27]
Va	-0.07	[-0.62, -0.62, -0.07, -0.07]	[-0.07, -0.07, 0.6, 0.6]
Va	-0.04	[-0.62, -0.62, -0.04, -0.04]	[-0.04, -0.04, 0.6, 0.6]
Va	-0.03	[-0.62, -0.62, -0.03, -0.03]	[-0.03, -0.03, 0.6, 0.6]
Va	-0.01	[-0.62, -0.62, -0.01, -0.01]	[-0.01, -0.01, 0.6, 0.6]
Va	0	[-0.62, -0.62, -0.0, -0.0]	[-0.0, -0.0, 0.6, 0.6]
Va	0.04	[-0.62, -0.62, 0.04, 0.04]	[0.04, 0.04, 0.6, 0.6]
Va	0.18	[-0.62, -0.62, 0.17, 0.19]	[0.17, 0.19, 0.6, 0.6]
Va	0.34	[-0.62, -0.62, 0.32, 0.36]	[0.32, 0.36, 0.6, 0.6]
Va	0.38	[-0.62, -0.62, 0.36, 0.4]	[0.36, 0.4, 0.6, 0.6]
Vb	-0.61	[-0.61, -0.61, -0.64, -0.58]	[-0.64, -0.58, 0.63, 0.63]
Vb	-0.51	[-0.61, -0.61, -0.54, -0.48]	[-0.54, -0.48, 0.63, 0.63]
Vb	-0.36	[-0.61, -0.61, -0.38, -0.34]	[-0.38, -0.34, 0.63, 0.63]
Vb	-0.28	[-0.61, -0.61, -0.29, -0.27]	[-0.29, -0.27, 0.63, 0.63]
Vb	-0.08	[-0.61, -0.61, -0.08, -0.08]	[-0.08, -0.08, 0.63, 0.63]

Vb	-0.05	[-0.61, -0.61, -0.05, -0.05]	[-0.05, -0.05, 0.63, 0.63]
Vb	-0.04	[-0.61, -0.61, -0.04, -0.04]	[-0.04, -0.04, 0.63, 0.63]
Vb	0	[-0.61, -0.61, -0.0, -0.0]	[-0.0, -0.0, 0.63, 0.63]
Vb	0.03	[-0.61, -0.61, 0.03, 0.03]	[0.03, 0.03, 0.63, 0.63]
Vb	0.04	[-0.61, -0.61, 0.04, 0.04]	[0.04, 0.04, 0.63, 0.63]
Vb	0.36	[-0.61, -0.61, 0.34, 0.38]	[0.34, 0.38, 0.63, 0.63]
Vb	0.39	[-0.61, -0.61, 0.37, 0.41]	[0.37, 0.41, 0.63, 0.63]
Vb	0.55	[-0.61, -0.61, 0.52, 0.58]	[0.52, 0.58, 0.63, 0.63]
Vc	-0.33	[-0.61, -0.61, -0.35, -0.31]	[-0.35, -0.31, 0.6, 0.6]
Vc	-0.19	[-0.61, -0.61, -0.2, -0.18]	[-0.2, -0.18, 0.6, 0.6]
Vc	-0.04	[-0.61, -0.61, -0.04, -0.04]	[-0.04, -0.04, 0.6, 0.6]
Vc	-0.02	[-0.61, -0.61, -0.02, -0.02]	[-0.02, -0.02, 0.6, 0.6]
Vc	0.03	[-0.61, -0.61, 0.03, 0.03]	[0.03, 0.03, 0.6, 0.6]
Vc	0.04	[-0.61, -0.61, 0.04, 0.04]	[0.04, 0.04, 0.6, 0.6]
Vc	0.23	[-0.61, -0.61, 0.22, 0.24]	[0.22, 0.24, 0.6, 0.6]
Vc	0.31	[-0.61, -0.61, 0.29, 0.33]	[0.29, 0.33, 0.6, 0.6]
Vc	0.33	[-0.61, -0.61, 0.31, 0.35]	[0.31, 0.35, 0.6, 0.6]
Vc	0.34	[-0.61, -0.61, 0.32, 0.36]	[0.32, 0.36, 0.6, 0.6]