



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Vitor Fernando Couto

**Deteção de Falhas de Alta Impedância em Microrredes Considerando a
Influência de Geração Conectada via Conversores Estáticos**

Florianópolis
2023

Vitor Fernando Couto

**Detecção de Falhas de Alta Impedância em Microrredes Considerando a
Influência de Geração Conectada via Conversores Estáticos**

Tese submetida ao Programa de Pós-Graduação
em Engenharia Elétrica da Universidade Federal de
Santa Catarina para a obtenção do título de doutor
em Engenharia Elétrica.

Orientador: Prof. Miguel Moreto, Dr.

Florianópolis
2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Couto, Vitor Fernando

Detecção de Falhas de Alta Impedância em Microrredes
Considerando a Influência de Geração Conectada via
Conversores Estáticos / Vitor Fernando Couto ; orientador,
Miguel Moreto, 2023.

159 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Elétrica. 2. Falhas de Alta Impedância. 3.
Detecção de Falhas. 4. Microrredes. 5. Modelos de Simulação.
I. Moreto, Miguel. II. Universidade Federal de Santa
Catarina. Programa de Pós-Graduação em Engenharia Elétrica.
III. Título.

Vitor Fernando Couto

**Deteção de Falhas de Alta Impedância em Microrredes Considerando a
Influência de Geração Conectada via Conversores Estáticos**

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca
examinadora composta pelos seguintes membros:

Prof. André Eugênio Lazzaretti, Dr.
Universidade Tecnológica Federal do Paraná

Prof. Diego Issicaba, Phd.
Universidade Federal de Santa Catarina

Prof. Roberto Francisco Coelho, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi
julgado adequado para obtenção do título de doutor em Engenharia Elétrica.

Prof. Telles Brunelli Lazzarin, D.Sc.
Coordenação do Programa de
Pós-Graduação

Prof. Miguel Moreto, Dr.
Orientador

Florianópolis, 2023.

Este trabalho é dedicado à minha filha Maria Catharina,
minha esposa Débora e aos meus pais Maristela e Joel.

AGRADECIMENTOS

Primeiramente agradeço a Deus pelo dom da vida e durante o período de pós-graduação me dar força, sabedoria, perseverança, saúde, paz e proteção.

Aos meus pais Joel João Couto e Maristela de Souza Couto por me apoiarem nas minhas decisões e incentivar a ir em busca de meus objetivos. Em especial à minha amada esposa Débora Caroline Salomon, que sempre esteve ao meu lado durante os momentos mais difíceis. A sua parceria e nascimento da nossa filha, em plena pandemia, foram decisivos para a finalização do meu doutorado.

Ao meu orientador e professor, Miguel Moreto, pela parceria ao longo do doutorado que contribuiu decisivamente para a minha formação e realização desse trabalho. Agradeço especialmente pela liberdade que me concedeu para tomar decisões importantes ao longo do projeto. Sua confiança em minhas capacidades fortaleceu meu senso de responsabilidade e me incentivou a explorar novas abordagens, contribuindo assim para o enriquecimento do trabalho.

Gostaria de expressar minha sincera gratidão aos incríveis colegas de laboratório e companheiros de pós-graduação que compartilharam comigo esta jornada acadêmica desafiadora. O nosso laboratório foi mais do que um espaço de pesquisa; tornou-se uma comunidade onde cada desafio foi enfrentado com colaboração e determinação. Agradeço a cada um de vocês pelo constante apoio técnico e pela maneira como nos unimos para superar obstáculos, criando um ambiente propício ao crescimento acadêmico e pessoal. Como não conseguirei contar as várias experiências e histórias vividas, agradeço-os nominalmente: Amanda Cristine Rodrigues, Ana Carolina Carvalho, Angélica Benetti Cezimbra, Cristiana da Silva Alexandre, Dalton Felipe Casamali, Dante Edson Sifuentes Quiroz, Fernanda Fernandes, Franciele Cicconet, Franciele Nornberg, Gisllane Oliveira, João Carlos Yokoyama Meneses, Joelma Nascimento, Jonas Roberto Pesente, José Octávio Cesário, Juliana Luisa Pereira, Jyvago Castello Branco Soares Terceiro, Larah Brüning Ascari, Luis Otavio Grillo, Palloma Graziely Santos Araújo, Manoel Moisés Bessa, Kauna Palma Silva, Taiane Pereira Dos Reis, Vitor Antunes e Victor Freitas.

À Universidade Federal de Santa Catarina, por oferecer um curso de Engenharia Elétrica com docentes qualificados. E pelo apoio financeiro fornecido pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - código de financiamento 001.

"A persistência é o caminho do êxito.."
(Calvin Coolidge, 1925)

RESUMO

As Faltas de Alta Impedância (FAI) em Sistema de Distribuição de Energia Elétrica (SDE) são perigosas e difíceis de detectar com relés de sobrecorrente convencionais ou fusíveis devido à baixa corrente. A proteção contra esse tipo de falta utiliza as distorções que ela causa nos sinais de corrente e tensão para sua detecção. Portanto, é fundamental que a modelagem da falta e do sistema elétrico seja suficientemente precisa na construção de métodos efetivos de detecção. Sendo assim, esta tese apresenta uma avaliação dos impactos dos modelos de simulação na detecção de FAI em Microrrede (MR) com Geração Distribuída (GD) com interface por dispositivos de eletrônica de potência do tipo *Voltage Source Converter* (VSC) além da proposição de um novo classificador. Os modelos de simulação detalhados de VSC utilizados consideram a comutação de alta frequência da eletrônica de potência e, conseqüentemente, as distorções harmônicas associadas. Assim, para sistemas com maior degradação da forma de onda senoidal da corrente, as características FAI como não-linearidade, assimetria e aleatoriedade podem permanecer ocultas, comprometendo o desempenho de algumas técnicas de detecção existentes. Tais modelos não são comumente usados ou discutidos na literatura para detecção da FAI. Para avaliar o impacto da complexidade do modelo de simulação, uma Redes Neurais Convolucionais (RNC) pré-treinada no banco de dados da *ImageNet* é adaptada para classificar a forma de onda da corrente com base em uma imagem de representação de tempo-frequência. O método proposto é projetado e testado utilizando um modelo MR baseado no *benchmark* europeu de rede de distribuição de média tensão proposto pelo Conselho Internacional de Grandes Sistemas Elétricos (CIGRE). O conjunto de dados da simulação considera a MR operando de forma ilhada e conectada, topologia radial e em anel, com transitórios diversos e em diferentes locais da MR. Foram realizados uma série de testes utilizando-se índices para avaliação de desempenho do método. Também foi realizada uma análise comparativa com um método no estado da arte treinado e testado para a mesma base de dados. Os resultados indicam que os métodos de detecção de FAI para MR com geradores do tipo VSC precisam ser projetados usando modelos de simulação detalhados para obter melhor precisão, e o classificador proposto apresentou uma índices de desempenho superiores ao método de comparação.

Palavras-chave: Faltas de Alta Impedância, Microrredes, Modelos de Simulação, Aprendizagem por Transferência, Detecção de Faltas.

ABSTRACT

High Impedance Faults (HIF) in Electricity Distribution Systems are dangerous and difficult to detect with conventional overcurrent relays or fuses due to the low fault current. Protection against this type of fault uses the distortions it causes in the current and voltage signals to detect it. As a result, precise modeling of the fault and the electrical system is required to develop efficient detection systems. Therefore, this thesis presents an evaluation of the impact of simulation models on the detection of faults in a microgrid with distributed generation interfaced with Voltage Source Converter (VSC) power electronics devices, as well as proposing a new classifier. The detailed VSC simulation models used take into account the high-frequency switching of the power electronics and, consequently, the associated harmonic distortions. Thus, for systems with greater degradation of the current sine waveform, HIF characteristics such as non-linearity, asymmetry and randomness can remain hidden, compromising the performance of some existing detection techniques. Such models are not commonly used or discussed in the literature for HIF detection. To assess the impact of simulation model complexity, a Convolutional Neural Networks pre-trained on the ImageNet database is adapted to classify the current waveform based on a time-frequency representation image. The proposed method is designed and tested using an MR model based on the European medium-voltage distribution network benchmark proposed by the International Council on Large Electricity Systems. The simulation data set considers the MR operating in islanded and connected form, radial and ring topology, with different transients and at different locations in the MR. A series of tests were carried out using indices to evaluate the method's performance. A comparative analysis was also carried out with a state-of-the-art method trained and tested on the same database. The results indicate that HIF detection methods for microgrid with VSC-type generators need to be designed using detailed simulation models to obtain better accuracy, and the proposed classifier showed a higher performance index than the comparison method.

Keywords: High Impedance Fault, Microgrid, Simulation Models, Transfer Learning, Fault Detection.

LISTA DE FIGURAS

Figura 1 – Microrrede e sistema formado por microrredes interligadas.	18
Figura 2 – Causas possíveis de FAI: (a) rompimento do cabo (b) contato de vegetação.	26
Figura 3 – Oscilografia típicas de FAI: (a) tensão e (b) corrente.	30
Figura 4 – Conjunto das 16 impedâncias não lineares para tensões entre 5 kV e 10,5 kV.	32
Figura 5 – Circuito equivalente do modelo de FAI R_f e L_f	33
Figura 6 – Circuito equivalente do modelo de FAI com diodos em antiparalelo.	34
Figura 7 – Harmônicas da corrente versus ângulo de fase e tensão; (a) 2ª da corrente; (b) 3ª da corrente.	35
Figura 8 – Modelo de FAI com diodos e resistores variáveis.	36
Figura 9 – (a) Modelo de FAI com diodos e fontes variáveis, (b) forma de onda de corrente em pu.	36
Figura 10 – (a) Modelo de FAI com diodos, fontes, resistores e indutores não variáveis, (b) forma de onda da corrente.	37
Figura 11 – Circuito equivalente do modelo de FAI com resistências variáveis em série.	38
Figura 12 – Curva VxI característica para FAI.	39
Figura 13 – Estrutura da técnica de detecção de FAI.	40
Figura 14 – Classificação dos métodos de detecção de FAI.	41
Figura 15 – Fluxograma da técnica de detecção de FAI com base em <i>Digital Signal Processing</i> (DSP).	48
Figura 16 – Algoritmo de Árvore de Decisão (AD) para detecção de FAI.	49
Figura 17 – Fluxograma de um algoritmo genético.	51
Figura 18 – Classificação linear com <i>Support Vector Machine</i> (SVM).	53
Figura 19 – Classificação da altura pela lógica convencional (esq.) e da lógica <i>Fuzzy</i> (dir.).	56
Figura 20 – Fluxo de dados em Redes Neurais Artificiais (RNA) com Técnicas de Reconhecimento de Padrão (TRP).	59
Figura 21 – Arquitetura de uma RNC unidimensional com filtros de diferentes resoluções.	62
Figura 22 – Projeção da Capacidade instalada no Sistema Interligado Nacional.	68
Figura 23 – MRs apoiadas pelo Departamento de Energia e Defesa Norte Americano.	72
Figura 24 – Gráfico que aponta tamanho, velocidade e precisão de algumas RNC treinadas com ImageNet.	85
Figura 25 – Método de detecção desenvolvido.	86

Figura 26 – Exemplos de escalogramas: as 3 imagens na parte superior da figura correspondem a FAI enquanto as na parte inferior são obtidas a partir de outros eventos.	86
Figura 27 – Método de detecção proposto utilizando a RNC SqueezeNet.	87
Figura 28 – Modelo de referência de SDE europeu.	89
Figura 29 – MR baseada na <i>European MV distribution network benchmark</i>	91
Figura 30 – Topologia das linhas de distribuição.	92
Figura 31 – Modelo do Gerador Fotovoltaico.	95
Figura 32 – Modelo detalhado de gerador eólico.	96
Figura 33 – Modelo de simulação de carga não linear com dois retificadores distintos alimentando cargas indutivas.	98
Figura 34 – Circuito elétrico do Modelo 1 de FAI.	99
Figura 35 – Formas de ondas típicas de tensão e corrente para a FAI modelo 1.	100
Figura 36 – Fomas de ondas para FAI do modelo 1 simuladas: (a) tensão e corrente, (b) curva característica VxI	100
Figura 37 – Circuito do Modelo de FAI com 6 arcos.	101
Figura 38 – FAI modelo 2 do tipo 1 (a) Foma de onda de tensão e corrente, (b) curva característica VxI	101
Figura 39 – Fomas de ondas para FAI do modelo 2 simuladas: (a) tensão e corrente, (b) curva característica VxI	102
Figura 40 – Fomas de ondas para FAI do modelo 3 para um sistema de 4,16 kV: (a) tensão acima e corrente abaixo, (b) curva característica VxI	103
Figura 41 – Fomas de ondas para FAI do modelo 3 para um sistema de 25 kV: (a) tensão acima e corrente abaixo, (b) curva característica VxI	103
Figura 42 – Circuito de FAI utilizado nas simulações.	104
Figura 43 – Fomas de ondas para FAI do modelo 3 simuladas: (a) tensão e corrente, (b) curva característica VxI	105
Figura 44 – Organização da base de dados para treinamento e teste.	107
Figura 45 – Base de dados para treinamento e teste utilizada no teste com a base de dados completa.	113
Figura 46 – Índices de desempenho para o teste com a base de dados completa.	114
Figura 47 – Base de dados para treinamento e teste utilizada no teste da FAI modelo 2:(a) teste 1 (b) teste 2.	115
Figura 48 – Índices de desempenho para o teste 1 da FAI modelo 2.	116
Figura 49 – Base de dados para treinamento e teste utilizada no teste da FAI modelo 3:(a) teste 1 (b) teste 2.	117
Figura 50 – Índices de desempenho para o teste 1 da FAI modelo 3.	117
Figura 51 – Base de dados para treinamento e teste utilizada no teste para carga não linear.	118

Figura 52 – Índices de desempenho para o teste da carga não linear.	119
Figura 53 – Base de dados para treinamento e teste utilizada no teste de chaveamento das linhas da MR.	119
Figura 54 – Índices de desempenho para o teste de chaveamento das linhas da MR.	120
Figura 55 – Base de dados para treinamento e teste utilizada no teste sem transitório.	121
Figura 56 – Índices de desempenho para o teste sem transitório.	121
Figura 57 – Índices de desempenho do modelo detalhado para resiliência a ruído.	122
Figura 58 – Índices de desempenho do modelo simplificado para resiliência a ruído.	123
Figura 59 – Avaliação de características no teste com a base de dados completa.	155
Figura 60 – Avaliação de características no teste 1 com FAI Modelo 2.	156
Figura 61 – Avaliação de características no teste 2 com FAI Modelo 2.	156
Figura 62 – Avaliação de características no teste 1 com FAI Modelo 3.	157
Figura 63 – Avaliação de características no teste 2 com FAI Modelo 3.	157
Figura 64 – Avaliação de características no teste com carga não linear.	158
Figura 65 – Avaliação de características no teste de chaveamento de linhas.	158
Figura 66 – Avaliação de características no teste para simulações sem transitórios.	159

LISTA DE TABELAS

Tabela 1 – Correntes FAI para diferentes superfícies de contato, SDE 12,5 kV.	27
Tabela 2 – Características da FAI.	29
Tabela 3 – Comparação entre Técnicas de Inteligência Artificial (GURURAJA-PATHY <i>et al.</i> , 2017).	65
Tabela 4 – Parâmetros de algumas RNC treinadas com Imagenet.	84
Tabela 5 – Parâmetros dos condutores das linhas de distribuição aéreas.	92
Tabela 6 – Parâmetros dos transformadores da MR.	93
Tabela 7 – Parâmetros do sistema equivalente da rede alta tensão.	93
Tabela 8 – Parâmetros de carga da MR utilizada nas simulações.	94
Tabela 9 – Quantidade de simulações realizadas que formam a base de dados.	107
Tabela 10 – Avaliação comparativa com os índices de desempenho.	123
Tabela 11 – Informação das base de dados.	124

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulado
AD	Árvore de Decisão
AG	Algoritmo Genético
AIE	Agência Internacional de Energia
ANEEL	Agência Nacional de Energia Elétrica
AP	Aprendizagem Profunda
AT	Aprendizagem por Transferência
ATP	<i>Alternative Transients Program</i>
CA	Corrente Alternada
CC	Corrente Contínua
CIGRE	Conselho Internacional de Grandes Sistemas Elétricos
DFIG	<i>Doubly-Fed Induction Generator</i>
DOE	<i>Department of Energy</i>
DSP	<i>Digital Signal Processing</i>
EPRI	<i>Electric Power Research Institute</i>
FAI	Faltas de Alta Impedância
FFT	<i>Fast Fourier Transform</i>
GD	Geração Distribuída
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IGBT	<i>Insulated Gate Bipolar Transistor</i>
LF	Lógica Fuzzy
LSC	<i>Line Side Converter</i>
LSTM	<i>Long short-term memory</i>
MPPT	<i>Maximum Power Point Tracking</i>
MR	Microrrede
PCA	<i>Principal Components Analysis</i>
PCC	<i>Point of Common Coupling</i>
PCH	Pequena Central Hidrelétrica
PES	<i>Power and Energy Society</i>
PMU	<i>Phasor Measurement Units</i>
PRODIST	Regras e Procedimentos de Distribuição
PSCAD	<i>Power Systems Computer-Aided Design</i>
PSRCC	<i>Power System Relaying and Control Committee</i>
RGB	<i>Red, Green and Blue</i>
RMS	<i>Root Mean Square</i>
RNA	Redes Neurais Artificiais

RNC	Redes Neurais Convolucionais
RNP	Redes Neurais Profundas
RNR	Redes Neurais Recorrentes
RSC	<i>Rotor Side Converter</i>
SDE	Sistema de Distribuição de Energia Elétrica
SEP	Sistema Elétrico de Potência
SNR	<i>Signal-to-noise ratio</i>
SVM	<i>Support Vector Machine</i>
TACS	<i>Transient Analysis of Control Systems</i>
TAMU	<i>Texas A & M University</i>
THD	<i>Total Harmonic Distortion</i>
TRP	Técnicas de Reconhecimento de Padrão
TW	Transformada Wavelet
VMD	<i>Variational Mode Decomposition</i>
VSC	<i>Voltage Source Converter</i>
XLPE	<i>Cross-linked polyethylene</i>

SUMÁRIO

1	INTRODUÇÃO	17
1.1	DIFICULDADE NA DETECÇÃO DE FAI	20
1.2	APRIMORAMENTO DA SEGURANÇA DE REDES ELÉTRICAS	20
1.3	TÉCNICAS RECONHECIMENTO DE PADRÕES	21
1.4	OBJETIVOS	22
1.5	PRINCIPAIS CONTRIBUIÇÕES	22
1.6	PUBLICAÇÃO EM REVISTA	23
1.7	ESTRUTURA DO DOCUMENTO	23
2	FALTAS DE ALTA IMPEDÂNCIA	25
2.1	CARACTERÍSTICAS E REPRESENTAÇÃO DE FAI	25
2.1.1	Aspectos Físicos e Elétricos do Fenômeno	27
2.1.2	Modelagem para Simulação da Falta	31
2.2	DETECÇÃO DE FALTAS DE ALTA IMPEDÂNCIA	39
2.2.1	Medições e Extração de Características	42
2.3	TÉCNICAS DE CLASSIFICAÇÃO	44
2.3.1	Árvore de Decisão (AD)	48
2.3.2	Algoritmo Genético (AG)	50
2.3.3	Support Vector Machine (SVM)	52
2.3.4	Lógica Fuzzy (LF)	56
2.3.5	Redes Neurais Artificiais (RNA)	59
2.3.6	Aprendizagem Profunda (AP)	61
2.3.7	Análise Comparativa entre as Técnicas de Reconhecimento de Padrões.	65
3	MICRORREDES	67
3.1	DESENVOLVIMENTO E PERSPECTIVAS FUTURAS	70
3.2	SISTEMAS DE PROTEÇÃO EM MIICRORREDES (MR)	74
3.3	DETECÇÃO DE FAI EM MR	77
3.3.1	Discussão	80
4	METODOLOGIA E SISTEMA TESTE	82
4.1	MÉTODO DE DETECÇÃO DE FAI PROPOSTO	82
4.1.1	Detecção utilizando imagens	85
4.2	SISTEMA TESTE	87
4.2.1	Microrrede	90
4.2.2	Geradores Distribuídos	94
4.3	MODELOS DE FAI UTILIZADOS	97
4.3.1	FAI modelo 1 (LAI <i>et al.</i>, 2005)	98
4.3.2	FAI modelo 2 (SEDIGHI, A. R.; HAGHIFAM, 2010)	99

4.3.3	FAI modelo 3 (GAUTAM; BRAHMA, 2013)	102
4.4	SIMULAÇÕES E BASE DE DADOS	105
4.5	AVALIAÇÃO DE DESEMPENHO	108
4.5.1	Índices de Desempenho	108
4.5.2	Teste de resistência a ruído	109
4.5.3	Método para comparação	110
5	TESTES E ANÁLISE DE RESULTADOS	112
5.1	TESTE COM A BASE DE DADOS COMPLETA	113
5.2	TESTE PARA A FAI MODELO 2	114
5.3	TESTE PARA A FAI MODELO 3	116
5.4	CARGA NÃO LINEAR	118
5.5	CHAVEAMENTO DE LINHAS DE DISTRIBUIÇÃO	119
5.6	SIMULAÇÕES SEM TRANSITÓRIOS	120
5.7	SIMULAÇÕES COM ADIÇÃO DE RUÍDO NAS MEDIDAS	122
5.8	AVALIAÇÃO COMPARATIVA DE DESEMPENHO	123
6	CONCLUSÕES E TRABALHOS FUTUROS	125
6.1	PROPOSTA PARA TRABALHOS FUTUROS	126
	REFERÊNCIAS	127
	APÊNDICE A – TESTES PARA SINAIS DE ENTRADA DO CLAS- SIFICADOR	154

1 INTRODUÇÃO

A organização de um Sistema Elétrico de Potência (SEP) é tradicionalmente formado pelo tripé: geração, transmissão e distribuição, por meio do qual a energia flui da fonte geradora até o consumidor final. No Brasil as grandes centrais hidrelétricas ficam distantes dos centros consumidores, e a sua produção é escoada através do sistema de transmissão que minimiza as perdas elétricas elevando o nível de tensão da energia gerada. O sistema de distribuição é responsável por diminuir para um nível seguro a tensão, tornando a rede mais compacta e compatível com os centros urbanos e, ao final, entregando a energia ao consumidor (CHOWDHURY, S. *et al.*, 2009).

Para suprir o crescimento contínuo da demanda por energia elétrica, este sistema está passando por um aprimoramento de forma a comportar a inclusão de fontes de geração distribuída GD, que fazem o aproveitamento energético de fontes renováveis, tais como solar e eólica. Isto vem ao encontro do anseio da sociedade por uma matriz energética menos dependente de combustíveis fósseis causadores de efeito estufa (FAHIMI *et al.*, 2011). Além disso, grandes usinas hidrelétricas causam sérios impactos ambientais e sociais, devido aos alagamentos causados pelas barragens e sistema de transmissão associado. Evidenciando que o potencial hídrico de grande escala restante no nosso país encontra-se na região norte (MORETTO *et al.*, 2012).

No Brasil, o plano decenal da expansão de 2028 aponta para um futuro com elevada participação de fontes renováveis na matriz elétrica brasileira. Aqui o papel dessas fontes é prioritariamente na expansão, o que difere de países Europeus, China e Estados Unidos onde estas fontes de baixa emissão de carbono e desenvolvimento sustentável visam substituir combustíveis fósseis e a geração nuclear (EPE, 2021).

A introdução de fontes de GD no nível da distribuição, que é regida a mais de 10 anos pela Resolução Normativa ANEEL nº 482/2012, foi recentemente alterada para atender a Lei nº 14.300/2022 e o art. 1º da Lei nº 14.120/2021. Essa nova legislação trouxe comandos que diferem da norma da ANEEL em vigor e precisam ser regulamentados, além de outros dispositivos que dependem de regulamentação da ANEEL para se tornarem efetivos. Existe também o projeto de Lei n. 2.703/2022, que acrescenta prazo para o acesso de GD ao Sistemas de Distribuição de Energia Elétrica SDE com subsídios. Dessa forma, vislumbra-se um incremento desse tipo de inserção, trazendo desafios como a adequação do sistema de proteção (NETO *et al.*, 2014), considerando inversão nos fluxos de potência, aumento do nível de curto-circuito e aumento de componentes harmônicos na rede (RODRIGUES; DE CONTI, 2016; VAISH *et al.*, 2021).

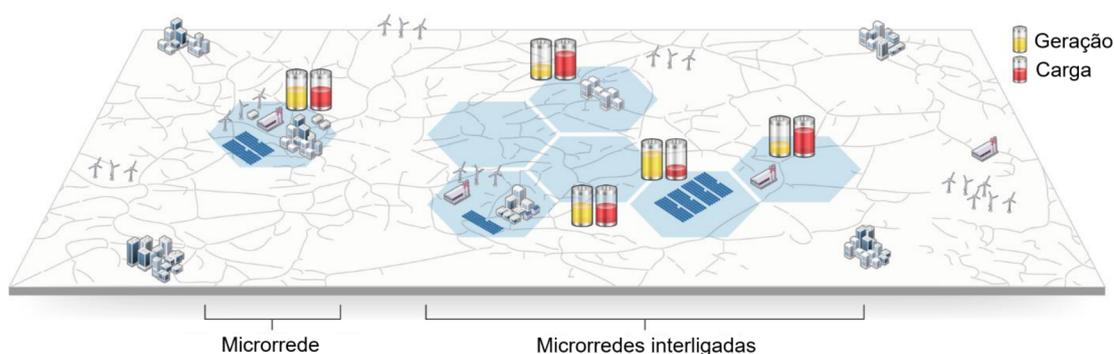
A Resolução Normativa ANEEL nº 956/2021 estabelece as Regras e Procedimentos de Distribuição (PRODIST) (ANEEL, 2022c). No seu módulo 1, separa GD nas categorias microgeração distribuída e minigeração distribuída. A principal diferença

está na potência instalada, em que a microgeração distribuída possui uma potência igual ou inferior a 75 kW em corrente alternada, enquanto a minigeração distribuída tem uma potência superior a 75 kW, com limites específicos baseados no tipo de fonte de energia utilizada (ANEEL, 2022a).

No processo de evolução nos SDE, além da GD, se destaca a introdução de Microrredes (MR). Adicionalmente ao que foi descrito acima, a MR se refere à integração dessas fontes distribuídas ao sistema elétrico com a possibilidade de compartimentalização, de forma que um grande sistema interligado pode dar lugar a vários sistemas menores conectados entre si.

O PRODIST define MR como "sistema elétrico de pequeno porte com cargas e Recursos Energéticos Distribuídos com capacidade de operar ilhado ou conectado à rede de distribuição (ANEEL, 2022a). Já o *Department of Energy* (DOE) dos Estados Unidos define MR como um grupo de cargas interligadas e de recursos energéticos distribuídos, com fronteiras elétricas claramente definidas, que atua como uma entidade única controlável em relação à rede e que pode ligar-se e desligar-se da rede para poder funcionar tanto em modo de ligação à rede como em modo de ilha (TON; SMITH, M. A., 2012). O conceito do DOE é mais detalhado e também é amplamente encontrado na literatura acadêmica (CHOWDHURY, S. *et al.*, 2009). A previsão do DOE é que as MRs deixarão de ser unidades individuais para se tornarem os blocos fundamentais de formação do SDE (POC *et al.*, 2021), como na Figura 1.

Figura 1 – Microrrede e sistema formado por microrredes interligadas.



Fonte: Adaptado (POC *et al.*, 2021)

O SDE tradicional está sujeito à ocorrência de faltas e as mesmas podem ser ocasionadas por situações diversas. As faltas em um sistema elétrico de distribuição podem ser originadas por condições climáticas, contatos de árvores nas linhas de distribuição, acidentes de trânsito, falhas em equipamentos, etc. A detecção dessas faltas consiste em identificar e classificar a ocorrência acionando os dispositivos necessários para que esta seja isolada. O sistema de proteção também é utilizado na transmissão e distribuição para determinar a origem e provável localização de uma falta, diminuindo

o tempo para o restabelecimento do sistema. Além disso, a proteção tem que distinguir eventos normais que causam algum tipo de transitório elétrico, como chaveamento de cargas e capacitores quando a atuação da proteção não é necessária, de situações de falta na qual o circuito sob falta deve ser isolado (ZAMANI *et al.*, 2011).

Existe um tipo específico de falta, que os SDEs estão expostos, que é incapaz de sensibilizar as funções de proteção convencionais. Essa falta ocorre devido a um curto-circuito à terra envolvendo superfícies de contato com alta resistência elétrica, resultando em correntes de falta inferiores aos ajustes dos sistemas tradicionais de proteção. Esse tipo de falta é conhecido como Falta de Alta Impedância (FAI) (HAMANAHA *et al.*, 2023). Normalmente o condutor se rompe e cai ao solo ou entra em contato com a vegetação próxima a rede fornecendo um caminho elétrico para a circulação de corrente. Portanto, uma FAI representa um perigo real para as pessoas, pois um condutor energizado fica ao nível do solo expondo-as a risco de um choque possivelmente fatal. Este tipo de condição insegura é motivo de preocupação para as concessionárias, pois também podem causar danos materiais a terceiros, bem como animais. Incluindo incêndios a locais públicos e privados, além de vegetação e florestas (GASHTERO-ODKHANI *et al.*, 2021). Estes danos podem resultar em reparação financeira por parte das distribuidoras ou proprietários de MR, por isto, depender apenas de notificações e avisos dos usuários para detectar este tipo de falta, não é uma prática recomendável e eficiente.

As formas de onda de corrente e tensão resultantes de uma FAI são frequentemente caracterizadas por não linearidade, assimetria nas formas de onda, intermitência, aleatoriedade entre outras distorções que serão aprofundadas ao longo do texto (GHADERI, Amin *et al.*, 2017). Assim, a maioria dos métodos de detecção busca rastrear padrões de distorção na tensões e correntes medidas. As abordagens mais recentes nesse campo fazem uso de alguma técnicas de processamento digital de sinais associadas com algoritmos para reconhecimento de padrões.

Em (MISHRA; PANIGRAHI, 2019) vários artigos que tratam do problema da FAI são apresentados desde os anos 1960 até 2017, o que mostra a popularidade deste campo de pesquisa. Do total de trabalhos analisados 15% tratam da modelagem do fenômeno, 10% tratam das experiências dos autores nesse campo (concebendo, implementando e testando métodos de detecção) e por fim 75% tratam de métodos de detecção de FAI.

Neste contexto a proposta deste trabalho é o desenvolvimento de um método eficiente de detecção automática de FAI em MR, podendo contribuir para confiabilidade e continuidade do serviço de fornecimento de energia elétrica. Bem como proteger vidas humanas expostas ao contato com estes condutores caídos ao solo ainda energizados.

1.1 DIFICULDADE NA DETECÇÃO DE FAI

As FAI são reconhecidas por serem difíceis de detectar. Diferente de outras faltas, elas não causam correntes elevadas em comparação à carga nominal, o que dificulta sua detecção por relés de sobrecorrentes convencionais (EMANUEL *et al.*, 1990). Algumas características adicionais que influenciam em sua detecção são as condições meteorológicas, distância entre a falta e os pontos de medição, capacidade de curto circuito do sistema, tipo de condutor, superfície de contato e o nível de monitoramento do SDE.

As técnicas de detecção de FAI devem apenas atuar na ocorrência deste distúrbio, permanecendo inativadas na presença de quaisquer outros eventos no sistema elétrico e isto é chamado de critério de segurança. Por isso, novas técnicas são submetidas a testes nos quais essa segurança é verificada (GHADERI, Amin *et al.*, 2017). Para um SDE formado apenas cargas lineares, a FAI é facilmente identificada, pois os componentes harmônicos da FAI são mais evidentes, o que não ocorre na presença de cargas não lineares (ZHENG *et al.*, 2021).

Atualmente, a grande quantidade de conteúdo harmônico nas redes de distribuição contribui significativamente para confusão nos relés de proteção. Entretanto a maioria dos métodos convencionais para detecção de FAI consideram o SDE um ambiente livre de harmônicas (SOHEILI *et al.*, 2018).

Em um ambiente de MR com a presença de GD, baseada em fontes com interface de conversores de frequência (VSC - *Voltage Sourced Converters*), esse conteúdo harmônico será ainda maior especialmente em operação ilhada. Desta forma, é muito importante levar em conta este fator para a formulação de técnicas de detecção de FAI mais eficientes (MEMON; KAUHANIEMI, 2015), pois o desempenho testado apenas em ambiente de simulação, sem considerar condições realísticas, pode inviabilizar a implementação prática do método de detecção.

1.2 APRIMORAMENTO DA SEGURANÇA DE REDES ELÉTRICAS

As FAIs podem causar incêndios quando ventos fortes derrubam linhas ou condutores de energia ou quando animais, árvores, ou outras vegetações fazem contato com as linhas elétricas. Em (KOUSKY *et al.*, 2018) são tratados os riscos e custos desses incêndios florestais no estado da Califórnia. Este assunto é especialmente sensível lá, pois no final de 2017 aconteceram incêndios mais mortais nos condados de Mendocino e Napa causados pelo SDE. Como resultado, 15 pessoas morreram, houve a queima de um total de aproximadamente 88.000 acres e a destruição de quase 1.200 estruturas.

No Brasil, e mais especificamente Santa Catarina, eventos climáticos relativamente frequentes também causam impacto nos SDEs. Em junho de 2020, um ciclone

deixou 1,5 milhão de unidades consumidoras sem energia elétrica e causou prejuízos de R\$ 60 milhões no sistema de geração e distribuição de energia elétrica de Santa Catarina (VASQUEZ-ARROYOA *et al.*, s.d.). Nestes casos, os ventos estão associados com chuvas, tornando incêndios florestais menos prováveis, mas podem facilitar o contato da vegetação ou mesmo o rompimento dos cabos das linhas de distribuição.

Existem diversos estudos que colocam as questões de segurança que envolvam não apenas danos materiais ao SDE, mas também incêndios causados por FAI como motivador principal (GOMES, D. P. *et al.*, 2019; GASHTEROODKHANI *et al.*, 2021; GOMES, Douglas Pinto Sampaio; OZANSOY, 2022; LEÃO *et al.*, 2020; GOMES, Douglas P. S. *et al.*, 2018, 2017).

Verifica-se dentro de um SDE a existência de um sistema de proteção que é baseado em relés de sobrecorrentes, elos fusíveis e religadores. Este tipo de tecnologia não é eficaz em um ambiente de MR, que necessita da adaptabilidade para os modos de operação ilhado e conectado, bem como da previsão de reversão de fluxos de potência, bidirecionalidade da corrente de falta, redução da capacidade de corrente de falta e adaptação da sensibilidade da proteção. Isto torna a tarefa de proteção de uma MR muito mais complexa de que um SDE radial (PARHIZI, Sina *et al.*, 2015).

Assim sendo, assume-se que nas MRs vão existir mais pontos de medição de tensão e corrente ao longo da rede. Essas medidas terão um grau de resolução melhor que as atuais, com uma taxa de amostragem muito maior que irão circular por uma rede de dados dedicada a tarefa de gerenciamento do sistema. Adicionalmente, medidas podem ter uma base de tempo comum, proporcionados por unidades de medição fasorial conhecidas como *Phasor Measurement Units* (PMU) (DE LA REE *et al.*, 2010). A hipótese levantada sugere que a quantidade significativa de dados provenientes dessas medidas é crucial para o desenvolvimento da estratégia proposta.

Toda essa nova massa de dados disponível permite um aprimoramento no monitoramento e nas técnicas de controle e proteção do sistema. Dessa forma, faz sentido utilizar-se dessas informações mais precisas e detalhadas no aprimoramento da tomada de decisões para eventos complexos, como é o caso de FAI (GHADERI, Amin *et al.*, 2017). Somando-se a isso, destaca-se o contínuo incremento da capacidade de processamento e conectividade dos dispositivos utilizados nos SDE e certamente em MR (SIROJAN *et al.*, 2022; FARHOUMANDI *et al.*, 2021).

Hipótese: A disponibilidade dessa quantidade significativa de dados é essencial para o desenvolvimento e eficácia da estratégia proposta.

1.3 TÉCNICAS RECONHECIMENTO DE PADRÕES

O avanço tecnológico no campo da informática vem melhorando a capacidade de processamento de informação bem como ferramentas para construção de algoritmos cada vez mais capazes. Isso tem sido um dos motivos para o aprimoramento da

proteção em sistemas elétricos (RAO, 2005).

Os microprocessadores de alta velocidade pavimentam o caminho em direção a relés digitais rápidos e confiáveis. Com este elevado poder computacional, é possível implementar técnicas de detecção FAI com maior complexidade. Portanto, é possível avançar para domínios de análise e classificadores mais complexos (HASSAN *et al.*, 2014; KAVOUSI-FARD *et al.*, 2021).

A complexidade de MR associada a vários fatores de incerteza são difíceis de abordar utilizando técnicas convencionais e para um melhor desempenho a aplicação de uma técnica baseada no conhecimento para a detecção de faltas. De uma forma geral, esses métodos requerem informações sobre a topologia da rede, o estado de chaves e disjuntores, medições disponíveis e até condições atmosféricas (PARHIZI, Sina *et al.*, 2015).

O uso de técnicas de análise e processamento de sinais no domínio tempo-frequência, possibilitando o enfrentamento de diferentes problemas na rede elétrica, tornou-se bastante comum nos últimos anos (MISHRA; PANIGRAHI, 2019). As características obtidas com essas técnicas também impulsionam o desenvolvimento de abordagens avançadas de classificação de eventos (VAISH *et al.*, 2021). Estas informações podem ser analisadas usando métodos de inteligência artificial como RNA, SVM, Lógica Fuzzy (LF) e abordagem coincidente (GURURAJAPATHY *et al.*, 2017; VAISH *et al.*, 2021).

1.4 OBJETIVOS

O objetivo principal deste trabalho é propor um método de detecção de FAI que leve em conta a evolução dos SDE. Para tanto, destacam-se os seguintes objetivos específicos:

- Desenvolver um modelo de simulação que reproduza o mais fielmente possível uma MR, levando-se em conta as distorções causadas por fontes VSC.
- Desenvolvimento de uma nova metodologia para detecção de FAI em MR levando-se em conta a operação ilhada e conectada da MR, e a presença de conteúdo harmônico devido à geração distribuída baseada em VSC.
- Utilização de algoritmo de reconhecimento de padrões, capaz de ser ajustado para detectar as FAIs levando-se em conta as múltiplas características obtidas por meio do processamento dos sinais medidos.

1.5 PRINCIPAIS CONTRIBUIÇÕES

As principais contribuições dessa pesquisa estão relacionadas à detecção de FAI. Na literatura existem trabalhos relacionados, mas nenhum deles examina o im-

pacto que modelos de simulação detalhados para GD tem no desempenho destes. Dentre as contribuições relevantes pode-se mencionar:

- Desenvolvimento de uma metodologia para detectar FAI usando transformada Wavelet e aprendizagem profunda. A RNC utilizada é chamada SqueezeNet e possui arquitetura compatível para o processamento em dispositivos do tipo *edge devices*.
- O método proposto considera a operação da MR ilhada e conectada, as topologia em anel e radial, utilizando apenas um ponto de medição de corrente.
- Testes dos classificadores treinados com dados de simulação contendo GD com modelagem detalhada e simplificada. Possibilitando analisar se a frequência de comutação e as características dinâmicas de geradores do tipo VSC impactam no desempenho desses classificadores.
- Os testes realizados também incluem três modelos distintos de FAIs, permitindo avaliar o desempenho dos Classificadores para uma FAI para a qual não foram treinados.

1.6 PUBLICAÇÃO EM REVISTA

Os principais resultados obtidos neste trabalho, com a utilização de técnicas de aprendizagem por transferência e classificação de imagens, foram publicados na revista *IEEE Access*:

1. *High Impedance Fault Detection on Microgrids Considering the Impact of VSC Based Generation* (COUTO; MORETO, 2023).

1.7 ESTRUTURA DO DOCUMENTO

Este documento é organizado em 6 capítulos, incluindo este de introdução. Os demais são organizados da seguinte forma:

O Capítulo 2 trata das FAIs, inicialmente apresentando 5 conceitos errôneos existentes em empresas concessionárias de distribuição. Na seção 2.1 são apresentados os aspectos físicos e elétricos desse fenômeno como magnitude da corrente de FAI de acordo com a superfície de contato, bem como características de distorções nas formas de onda de tensão e corrente. São apresentados também alguns dos modelos de simulações mais populares de simulação. Na seção 2.2, primeiramente são apresentadas as medidas, a escolha do domínio de análise para extração de características pertinentes e o tipo de classificadores para detecção da falta. Posteriormente, na seção 2.3, divide-se os métodos de detecção de FAI em abordagem clássica e em

técnicas de reconhecimento de padrões. Essas técnicas são explicadas de maneira sucinta com alguns trabalhos que as utilizam.

No Capítulo 3 estão os conceitos e desenvolvimento de MR, e características de sua proteção. Na seção 3.3 são relacionados e descritos alguns artigos que tratam do mesmo problema de detecção de FAI em ambiente de MR ou SDE com a inserção de GD.

No Capítulo 4 é apresentado o método de detecção proposto e as ferramentas utilizadas no seu desenvolvimento. Na seção 4.1 é apresentada a técnica de classificação utilizando imagens e o método desenvolvido. Os modelos de simulação da MR e dos GD utilizados são apresentados na seção 4.2, e os três modelos de FAI utilizado estão na seção 4.3. Na seção 4.4, é apresentada a base de dados e as simulações utilizadas na sua construção. Por último, na seção 4.5 são apresentados critérios para classificação de desempenho, o teste de resistência a ruído e o método para comparação.

Os testes realizados e sua análise são apresentados no Capítulo 5. São sete testes ao todo que possibilitam avaliar o desempenho do método proposto com cinco diferentes índices de desempenho. Além disso, é feita uma análise comparativa com alguns métodos no estado da arte selecionados da literatura.

No Capítulo 6 estão as principais conclusões e resultados sobre o trabalho realizado. São descritas algumas sugestões para trabalhos futuros que possam vir a aprimorar o desenvolvimento e melhoria de métodos de detecção de FAIs considerando um SDE com a presença de GD baseada em VSC.

Foram incluídos no Apêndice A os testes realizados na determinação do parâmetro de detecção utilizado no método desenvolvido.

2 FALTAS DE ALTA IMPEDÂNCIA

Há muito tempo pesquisadores e engenheiros estão interessados e preocupados com os curto-circuitos nos SDE. Os sistemas de proteção têm evoluído ao longo do tempo, incluindo novos aparelhos e tecnologia. A confiabilidade na distribuição de energia elétrica aumentou consideravelmente como resultado deste progresso. Mas ainda há questões relacionadas à proteção que ainda não foram resolvidas, isto inclui a FAI.

Este problema torna-se ainda mais desafiador se considerarmos que este tipo de ocorrência normalmente não é detectada pela magnitude de corrente, mas pelas distorções que causa nas formas de onda de corrente e tensão. A tendência futura é um SDE convivendo com muitas outras fontes desse tipo de distorção, como cargas não lineares e GD com interface de VSC.

Para tratar sobre esse assunto, este capítulo apresenta a FAI com suas características físicas e elétricas, com como os modelos de simulação que permitem reproduzi-la. Posteriormente, são apresentadas as medidas e seu atributos, algumas técnicas para classificação deste tipo de falta com métricas para avaliação de desempenho. Por último, são apresentadas algumas iniciativas de pesquisa e implementação de MR, e trabalhos relevante para detecção de FAI em MR ou SDE com a presença de GD.

2.1 CARACTERÍSTICAS E REPRESENTAÇÃO DE FAI

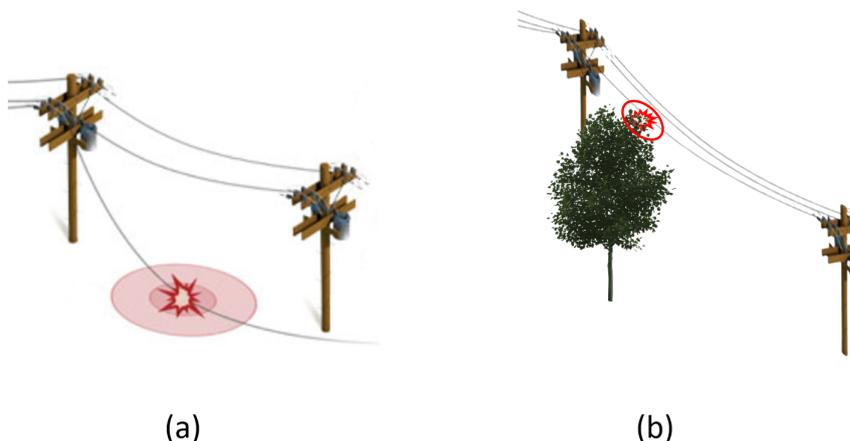
Os SDE são projetados para operar em regime permanente. Entretanto estão sujeitos a uma grande variedade de transitórios eletromagnéticos que podem resultar em sobretensões e/ou sobrecorrentes (DE ARAÚJO; NEVES, 2005). Então, para evitar que esses fenômenos transitórios se tornem um problema para segurança da operação, os SDE contam com um sistema de proteção que é capaz de identificar e sanar a maioria destes eventos antes que causem maiores prejuízos.

A proteção é responsável por isolar a parte defeituosa do resto do sistema, de modo que o mínimo de consumidores sejam afetados. Mas esse sistema de proteção não é infalível e capaz de proteger o SDE contra qualquer tipo de falta, porque isso o tornaria extremamente caro. Assim, por uma questão de filosofia e economicidade, sistemas de distribuição têm basicamente proteção contra curto-circuitos e sobrecargas por meio de religadores, disjuntores e fusíveis.

Esse sistema de proteção é adequado para proteger contra faltas de baixa impedância e sobrecargas, porém, não é adequado para um tipo diferente de falta que pode ocorrer, são as chamadas FAI. Estas faltas se caracterizam por ter um nível baixo de corrente elétrica, similar ao de uma carga do sistema, sendo assim muito difícil a sua detecção pelo esquema de proteção convencional.

As FAI se devem ao contato de um condutor energizado com uma superfície de impedância elevada (TENGDIN *et al.*, 1996). Este contato acidental pode ser causado por falha no isolamento ou por fatores como: relâmpagos, animais, galhos de árvores, condições climáticas adversas ou a ruptura do cabo e conseqüente queda ao solo como na Figura 2.

Figura 2 – Causas possíveis de FAI: (a) rompimento do cabo (b) contato de vegetação.



Como as FAI têm uma pequena magnitude de corrente elétrica, ela pode ser interpretada como sendo uma perturbação do tipo acréscimo de carga, chaveamento de banco de capacitores ou reconexão de ramais. Por isso, diminuir os limites de corrente nos ajustes da proteção não é um procedimento recomendável, pois irá resultar em uma maior sensibilidade na proteção e prováveis atuações indevidas.

Além disso, um condutor caído ao solo representa um grande risco à segurança de pessoas e animais, pois não é necessário o contato direto para causar um choque elétrico. Isto porque a área no entorno do condutor caído ficará energizada com um nível de tensão potencialmente fatal. O condutor também pode entrar em contato com árvores, edificações, meios de transportes e outros objetos, que estejam próximos a rede, mascarando a situação de risco (AUCOIN, Mike, 1985).

Em (THERON *et al.*, 2018) os autores desmistificam alguns conceitos errôneos que existem nas empresas concessionárias de distribuição a respeito de proteção contra as FAI. Os seus argumentos estão enumerados a seguir:

1. Por melhor que seja o ajuste da proteção de sobrecorrente ela não será capaz de detectar todas as FAI. Isto porque a corrente de FAI é muito reduzida (1 - 100 amperes) e muitas vezes é inferior às cargas conectadas ao sistema; (AUCOIN, M. *et al.*, 1985b)
2. A proteção de sobrecorrente temporizada de terra (51G) é utilizada para detecção de baixas correntes que circulam pelo circuito de aterramento. Entretanto, em

sistemas com cargas desequilibradas, esta proteção não pode ser muito sensível. Além disso, um condutor caído ao solo pode levar a uma carga mais equilibrada, reduzindo a corrente de neutro, o que não acionará a proteção 51G;

3. A corrente das FAI não necessariamente aumentará ao longo do tempo levando à operação da proteção. O que normalmente ocorre é a diminuição da corrente de falta conforme o condutor queima, a umidade evapora, a areia se funde, etc;
4. A equipe de engenharia acredita que a taxa de ocorrência das FAI é baixa. Entretanto, equipes de campo relatam muitos casos em que os condutores ainda estão energizados, quando vão atender aos chamados por condutores rompidos;
5. As tecnologias disponíveis para a detecção de FAI são capazes de detectar a maior parte dos eventos, mas não existe a garantia de 100% de proteção.

2.1.1 Aspectos Físicos e Elétricos do Fenômeno

De acordo com a definição, as FAI são um tipo de falta cuja corrente não é capaz de sensibilizar os relés de sobrecorrente normalmente empregados na proteção de SDE com tensões de 4 kV até 34,5 kV (DAQING HOU, 2007). Esta falta se deve ao contato do condutor energizado com um objeto semi-isolado, podendo ser: árvore, estrutura ou equipamento, que toca a superfície da terra, como asfalto, concreto, grama, relva e areia. Estas superfícies impõem uma impedância muito alta que limitam as correntes de falta a valores muito pequenos entre 0 e 75 amperes, conforme apresentado na Tabela 1.

Tabela 1 – Correntes FAI para diferentes superfícies de contato, SDE 12,5 kV.

Superfície	Corrente de falta (A)
Asfalto seco	0
Concreto (não reforçado)	0
Areia seca	0
Areia molhada	15
Grama seca	20
Pasto seco	25
Grama molhada	40
Pasto molhado	50
Concreto (reforçado)	75

Fonte: Adaptado de (AUCOIN, B. M.; JONES, 1996)

Quando se inicia uma FAI o ar ao redor do condutor fica altamente ionizado podendo evoluir para um arco elétrico. Se a falta acontecer perto de algum tipo de material inflamável pode resultar em incêndio e/ou explosão. Além destes riscos, existe a possibilidade de que um membro da equipe da concessionária, ou de qualquer

indivíduo que estiver naquele momento nas proximidades da FAI, possa a vir a ser atingido de forma não intencional pelo condutor (ou outra estrutura, como por exemplo uma árvore) exposto e energizado (CARPENTER *et al.*, 2005).

Infelizmente não há índices estatísticos absolutos a respeito das FAI, pois apenas são registradas faltas que resultam em alarmes ou disparos de proteção. No entanto, estima-se que entre 5% e 10% das falhas de distribuição são FAI. Segundo mostram Amin Ghaderi *et al.* (2017) há estudos relatando que 25% ou 32% (dependendo da fonte) dos condutores partidos em contato com o solo não são detectados pelos relés de sobrecorrente.

Um grupo de trabalho organizado pelo comitê *Power System Relaying and Control Committee* (PSRCC) da sociedade *Power and Energy Society* (PES) do *Institute of Electrical and Electronic Engineers* (IEEE), que debateu e apresentou um relatório sobre tecnologia de detecção de FAI (TENGDIN *et al.*, 1996), teceu considerações sobre a frequência de eventos de FAI. Neste relatório é apresentada a contradição entre a percepção dos engenheiros de proteção e equipes de campo em relação a quantidade de FAI. Isto ocorre porque segundo as equipes de manutenção, quando eles chegam a um local de FAI, o condutor ainda permanece energizado devido à não atuação da proteção. Assim, os engenheiros de proteção têm uma percepção errônea, pois muitas FAI não aparecem nas estatísticas e relatórios de atuação da proteção. Este relatório cita também um estudo de 11 anos realizado por pesquisadores da *Texas A & M University* (TAMU), no qual foram aplicadas 200 FAI em cinco concessionárias e em dez alimentadores de distribuição. Destas 200, apenas 35 foram detectadas e isoladas pela proteção convencional.

Desta forma, se torna imperativo adotar ações no sentido de detectar as FAI de maneira automática e rápida. Isto vai ao encontro do aperfeiçoamento da segurança dos SDE, tanto para quem passa próximo à rede, quanto do ponto de vista da continuidade do fornecimento ao consumidor e assim diminuindo o tempo de indisponibilidade. A Agência Nacional de Energia Elétrica (ANEEL) regulamenta as concessionárias que prestam o serviço de distribuição de energia elétrica por meio do PRODIST (ANEEL, 2022c). Nesse regulamento, os ajustes tarifários anuais são calculados com base em índices que mensuram a frequência e duração de interrupções no suprimento (ANEEL, 2022b). Assim, têm-se um incentivo econômico para incorporar ferramentas que detectem FAI. Existem meios para a detecção de uma maior porcentagem dessas FAI que são negligenciadas pelas funções de proteção convencionais como sobrecorrente instantânea (50), sobrecorrente temporizada (51), sobrecorrente de terra (50SG) ou fusíveis.

Uma vez que a magnitude de corrente da FAI não pode ser utilizada como parâmetro de detecção como no caso de falta de baixa impedância, outros parâmetros devem ser utilizados. As técnicas e algoritmos de detecção se baseiam no rastrea-

mento das pequenas distorções causadas aos sinais de tensão e corrente durante o evento. As características físicas e elétricas principais da FAI são apresentadas na Tabela 2.

Tabela 2 – Características da FAI.

Característica	Descrição
Intermitência do Arco Elétrico	O arco não gera corrente em um padrão estável, em vez disso gera alguns ciclos de condução seguidos por vários ciclos de não condução (JEERINGS; LINDERS, 1989).
Assimetria na Forma de Onda de Corrente	Os valores de tensão de ruptura dielétrica são diferentes para tensão positiva e negativa, resultando numa diferença entre o valor do pico e a forma dos semiciclos positivo e negativo da corrente na FAI (EMANUEL <i>et al.</i> , 1990).
Corrente não Estacionária	O espectro de frequência da corrente varia com tempo.
Aleatoriedade	Tanto a magnitude da corrente quanto os intervalos de condução e não condução são valores aleatórios (KAUFMANN; PAGE, 1960).
Não Linearidade	A característica tensão-corrente do FAI não é linear devido à existência do arco.
Componentes de Baixa Frequência de Corrente e Tensão	Devido à não linearidade da FAI, as formas de onda contêm harmônicos de até 600 Hz para a corrente e até 300 Hz para tensão.
Componentes de Alta Frequência na Corrente	O arco elétrico resulta em componentes de alta frequência na forma de onda da corrente.

Fonte: Adaptado de (GHADERI, Amin *et al.*, 2017)

A Tabela 2 mostra como as características das FAI estão intimamente relacionadas a formação de um arco elétrico no ponto de contato entre o condutor e a superfície de alta impedância. O arco ocorre quando o valor da tensão excede o valor de ruptura dielétrica e se extingue quando a tensão está abaixo deste limiar. Este limiar de ruptura é diferente para o semi-ciclo positivo e negativo. Esta propriedade resulta que a cada ciclo de tensão existem duas ignições de arco elétrico e duas extinções (GHADERI, Amin *et al.*, 2017).

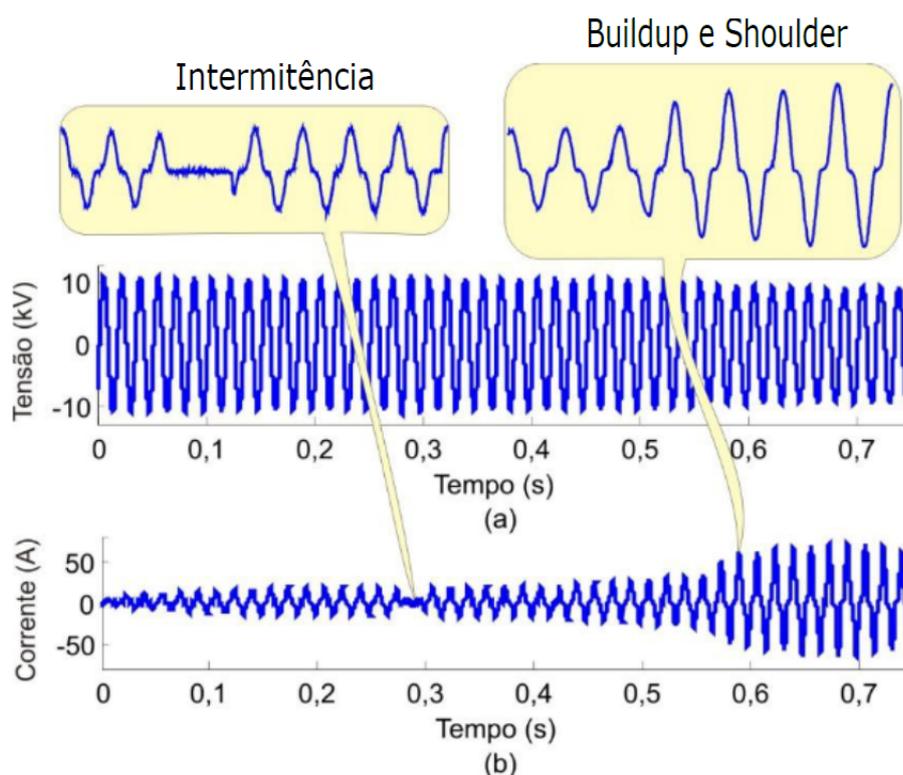
A maioria das FAI é monofásica-terra mas é possível haver casos bifásicos, quando por exemplo um galho de árvore entra em contato com dois condutores. Devido a sua natureza aleatória, cada tipo de FAI é único em termos de magnitude de corrente de falta, natureza, característica e em formas de onda (THERON *et al.*, 2018). Esses parâmetros são diferentes a depender da superfície de contato, da umidade no local,

da quantidade de arcos elétricos formados durante a falta e do tipo de aterramento do sistema.

Um estudo realizado pelos pesquisadores coreanos Nam *et al.* (2001), com o objetivo de reproduzir por meio de simulações o comportamento das FAI traz mais duas características na corrente de falta. A primeira característica, nomeada *buildup*, se refere ao comportamento de crescimento da corrente elétrica de falta ao longo do tempo, que atinge seu máximo valor em aproximadamente dez ciclos. Fisicamente este crescimento gradativo da corrente se explica pelo tempo de acomodação do condutor energizado no solo. Durante o crescimento da envoltória da corrente de falta existem períodos em que sua amplitude se torna constante antes de voltar a crescer, o que foi chamado de *shoulder*.

Na Figura 3 são apresentadas as formas de onda de tensão e de corrente obtidas por intermédio de testes de campos realizados em um alimentador de 13,8 kV no estado da Paraíba. As características de *shoulder* e *buildup* na corrente podem ser observadas.

Figura 3 – Oscilografia típicas de FAI: (a) tensão e (b) corrente.



Fonte: Adaptado de (SANTOS, 2011).

Estas características apresentadas, decorrente das FAI, se traduzem em uma assinatura contida nas medidas aferidas do sistema, de tal forma que se rastreadas possibilitam fazer a sua detecção. Esta assinatura também depende de fatores como

a superfície de contato e umidade do ar. Desse modo, para projetar um método de detecção eficiente, é preciso desenvolvê-lo utilizando um modelo de FAI que reproduza de maneira suficiente essas características.

2.1.2 Modelagem para Simulação da Falta

A utilização de modelos de FAI é uma prática comum devido à dificuldade de detecção e conseqüente baixa disponibilidade de registros oscilográficos desses eventos. A seguir serão apresentados os principais modelos encontrados na literatura, cujo papel é emular as características das FAI em um ambiente de simulação, bem como o modelo utilizado neste trabalho.

Os modelos podem ser categorizados em três grupos: cálculo de resistência do arco por equações empíricas, equações diferenciais e representação por circuitos elétricos equivalentes.

A primeira categoria usa dados empíricos para calcular a resistência equivalente do arco, em função de vários parâmetros, como comprimento e corrente do arco. São métodos de relativamente simples implementação, mas negligenciam a natureza aleatória da FAI. No segundo grupo, equações diferenciais são utilizadas para calcular a condutância equivalente do arco elétrico. Apesar de modelar a natureza aleatória das FAI, a suposição de comprimento constante do arco elétrico é falsa para condutores caídos ao solo.

O terceiro é a combinação de elementos de circuitos elétricos emulando as características aleatórias e assimétricas da FAI, mas é necessário adequar seu parâmetros empiricamente para diferentes tipos de FAI (GHADERI, Amin *et al.*, 2017).

A seguir estão listados alguns dos principais modelos de FAI disponíveis na literatura:

- **Modelo com Resistência Fixa:**

Este modelo faz parte do grupo que utiliza circuitos elétricos equivalentes. Trata-se de uma representação bastante simplificada das FAI e consiste numa resistência elevada com valor fixo entre o ponto de falta e a terra. Assim, apenas o nível de corrente do curto-circuito é reduzido sem reproduzir os efeitos do arco elétrico, tais como assimetrias e distorções harmônicas.

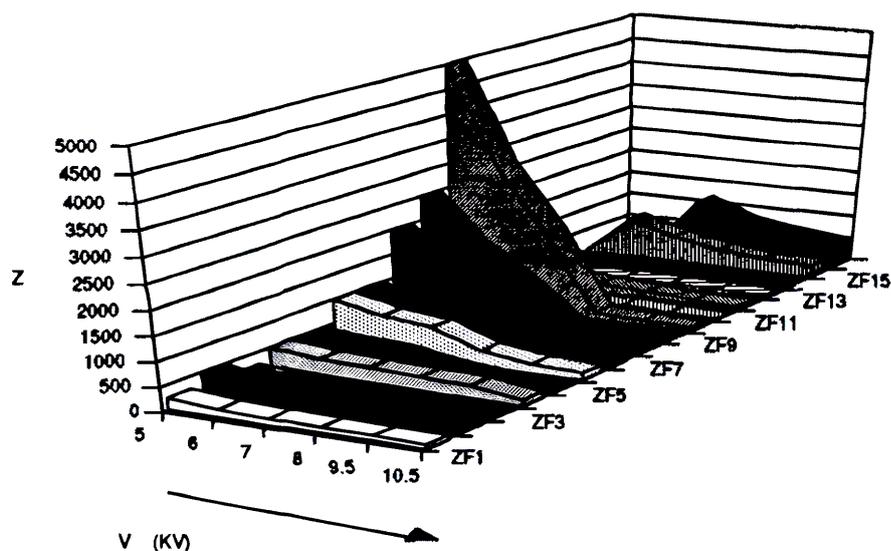
Este modelo não é apropriado para simulações com a finalidade de detecção de FAI, uma vez que algoritmos baseados em transitórios eletromagnéticos causados por esse modelo não serão capazes de distingui-lo do chaveamento de cargas monofásicas. Por isso, esse modelo é pouco utilizado pelos pesquisadores, uma vez que as características relevantes que se pretende usar para a detecção de FAI não são reproduzidas.

- **Modelo que combina impedâncias não lineares, apresentada em (YU; KHAN, 1994):**

O modelo leva em conta que a impedância das FAI é não linear e varia a cada ciclo. Para isso ocorrer, quando a tensão aumenta durante o semiciclo positivo, a impedância diminui. Da mesma forma, no semiciclo negativo, conforme a tensão chega próxima ao seu valor mínimo, a impedância também diminui.

A Figura 4 foi apresentada no estudo (YU; KHAN, 1994) e traz 16 impedâncias não lineares de faltas diferentes, sendo que estas impedâncias assumem valores diferentes conforme o nível de tensão. Apesar da baixa qualidade no artigo original, é possível observar que entre as impedâncias Z_7 e Z_{11} existe o maior de variação de acordo com o nível de tensão, e que o arco elétrico ocorre para tensões entre 5 kV e 10,5 kV.

Figura 4 – Conjunto das 16 impedâncias não lineares para tensões entre 5 kV e 10,5 kV.



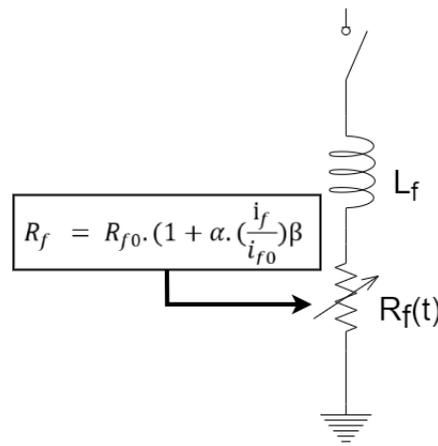
Fonte: (YU; KHAN, 1994).

A implementação desse modelo não é trivial, pois como o estudo sugere, é necessário que sejam escolhidas e combinadas as impedâncias não lineares até que as características das FAI sejam adequadamente reproduzidas. Esta escolha demanda um processo de tentativa e erro para modelar as não linearidades das impedâncias e combiná-las. Portanto, devido a sua natureza empírica e complexidade de configuração, este modelo não será considerado no estudo aqui proposto.

- **Modelo R_f variável com L_f fixo, proposto por (SHARAF; WANG, G., 2003):**

O modelo leva em conta a presença de arco elétrico durante a falta e consiste em uma resistência de falta variável R_f com uma reatância indutiva fixa L_f , mostrado na Figura 5. Este modelo é muito empregado, principalmente em conjunto com técnicas de inteligência computacional segundo Nakagomi (2006).

Figura 5 – Circuito equivalente do modelo de FAI R_f e L_f .



Fonte: (SHARAF; WANG, G., 2003).

Os valores de R_f variam conforme a variação da corrente de falta e R_{f0} é resistência de falta inicial de 20 Ω . Para calcular esses valores da resistência é utilizada a seguinte equação:

$$R_f = R_{f0} \cdot \left(1 + \alpha \cdot \left(\frac{i_f}{i_{f0}}\right)^\beta\right), \quad (1)$$

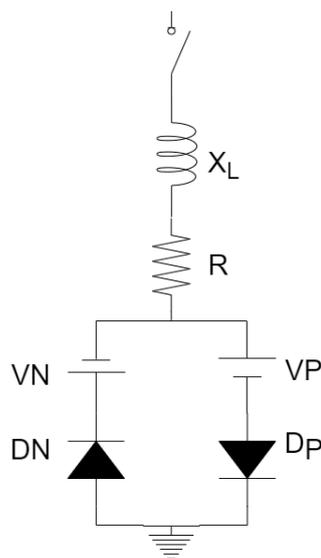
em que α e β são valores de escolha; i_f é a corrente de falta atual e i_{f0} a corrente inicial da falta.

Este modelo reproduz as não linearidades e assimetria na corrente de falta, porém, negligencia o crescimento do módulo da corrente (*buildup*) e sua intermitência.

- **Modelo com diodos, fontes de Corrente Contínua (CC) e impedância, proposto por (EMANUEL *et al.*, 1990):**

Este modelo é baseado em experimentos de laboratório, medições de campo e cálculos teóricos. Ele é composto por dois ramos de diodo conectados em série com fonte CC, sendo que ramos têm polaridade invertida um em relação ao outro. Também é adicionada uma impedância, composta de resistor e indutância, conectada em série entre as fontes CC e o ponto da falta, como apresentado na Figura 6.

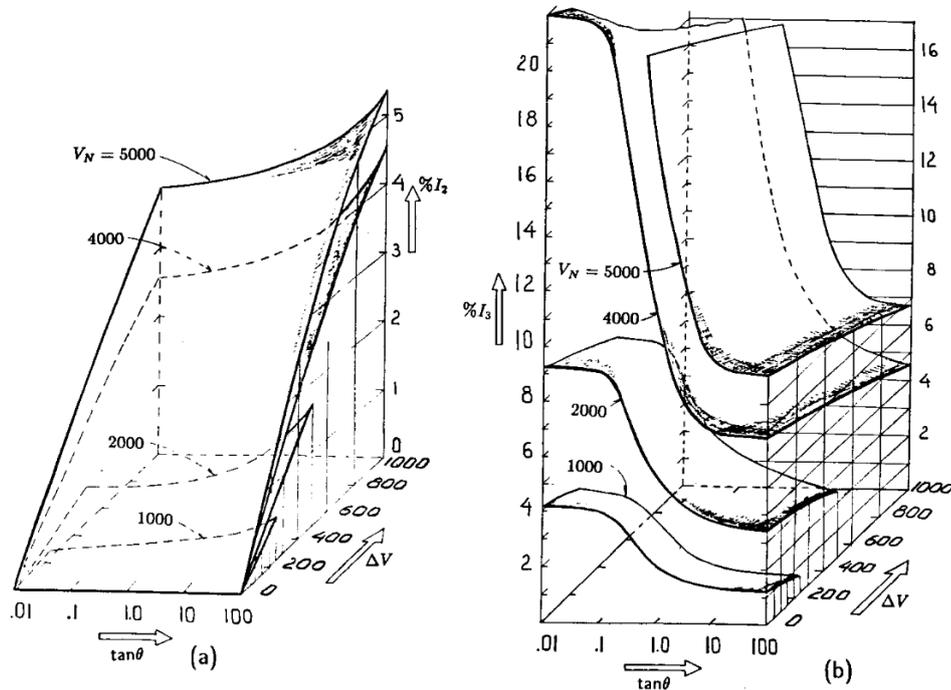
Figura 6 – Circuito equivalente do modelo de FAI com diodos em antiparalelo.



Fonte: Adaptado de (EMANUEL *et al.*, 1990)

O circuito se comporta da seguinte forma: a corrente de falta circula por meio de V_P durante o semiciclo positivo e, durante o semiciclo negativo, por meio de V_N . Como a corrente de falta é maior no semiciclo positivo, normalmente utiliza-se $V_N > V_P$. Essa diferença ($\Delta V = V_N - V_P$) e a relação R com X_L ($\tan\theta = X_L/R$) são os parâmetros de ajuste do conteúdo harmônico na corrente, apresentados na Figura 7.

Figura 7 – Harmônicas da corrente versus ângulo de fase e tensão; (a) 2ª da corrente; (b) 3ª da corrente.

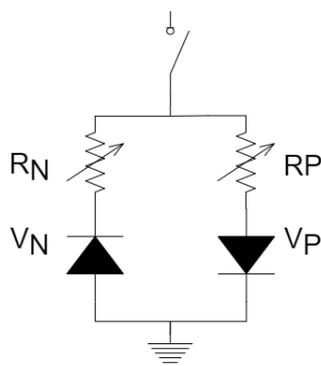


Fonte: Adaptado de (EMANUEL *et al.*, 1990)

Desde então, uma série de outros artigos tem proposto refinar e adaptar este modelo para melhor representar este fenômeno físico (MISHRA; PANIGRAHI, 2019). Existem modificações desse modelo clássico, mantendo a topologia dos diodos em antiparalelo mas com variações em relação aos outros elementos do circuito.

Em (SHARAT *et al.*, 1993), a falta foi modelada pelo circuito mostrado na Figura 8, com dois resistores não lineares e sem as fontes de corrente contínua. Este modelo foi utilizado para implementação de um método de detecção de FAI baseado em redes neurais multicamadas *feed forward* em sistemas radiais de distribuição de energia.

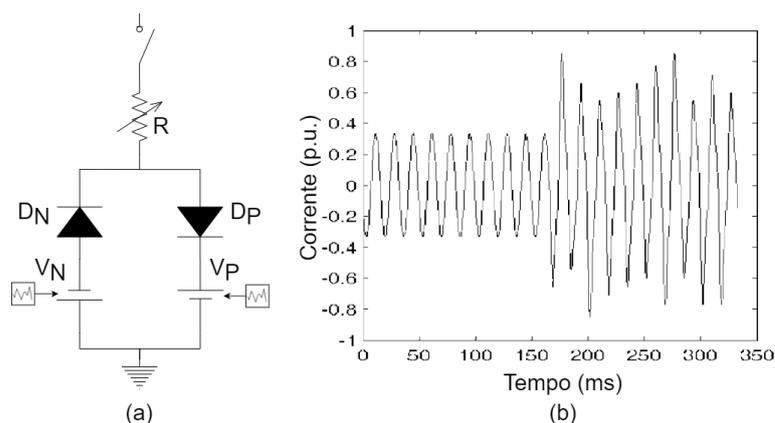
Figura 8 – Modelo de FAI com diodos e resistores variáveis.



Fonte: Adaptado de (SHARAT *et al.*, 1993)

Posteriormente, em (SHENG; ROVNYAK, 2004), os autores apresentam um modelo com dois diodos, um diodo não linear e duas fontes de tensão operando em corrente contínua que variam de amplitude de forma aleatória a cada semiciclo, como pode ser visto na Figura 9(a). Os autores alegam que a corrente obtida com o modelo, mostrada na Figura 9(b), é compatível com as formas de onda de correntes reais de falta quando adequadamente condicionadas e filtradas das altas frequências. Esta configuração reproduz de maneira simplificada a dinâmica aleatória das FAI sobre diferentes superfícies, como asfalto, areia, grama ou terra.

Figura 9 – (a) Modelo de FAI com diodos e fontes variáveis, (b) forma de onda de corrente em pu.

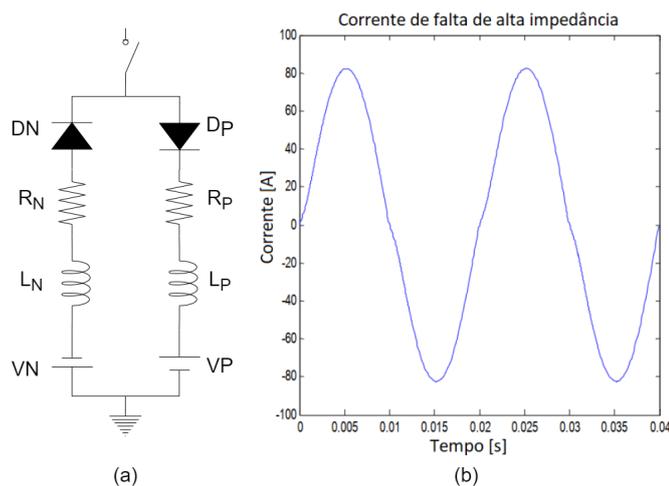


Fonte: Adaptado de (SHENG; ROVNYAK, 2004)

No modelo apresentado por Naser Zamanan e Sykulski (2006), não existem elementos do circuito elétrico que tenham valores variáveis no tempo. Como os arcos elétricos são mais frequentes em circuitos altamente indutivos, foram

adicionadas duas indutâncias L_P e L_N . Estes elementos também acentuam a não linearidade na curva característica $V \times I$ e a uma assimetria necessária na corrente da FAI. Na Figura 10(a) é apresentado o circuito do modelo e Figura 10 (b) traz a forma de onda da corrente produzida por ele.

Figura 10 – (a) Modelo de FAI com diodos, fontes, resistores e indutores não variáveis, (b) forma de onda da corrente.



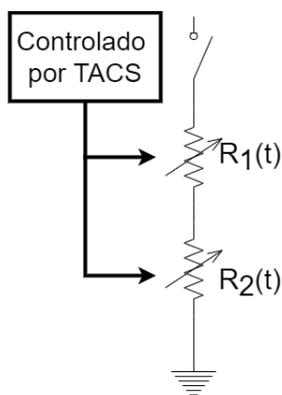
Fonte: Adaptado de (ZAMANAN, Naser; SYKULSKI, 2006)

Este tipo de modelo com diodos é de fácil implementação reproduzindo as características de não linearidade e assimetria decorrentes do arco elétrico em ambiente de simulação. No entanto, os valores dos elementos do circuito elétrico não são triviais de se encontrar na literatura e dependem de uma série de fatores como superfície de contato e umidade do ar. Além disso, as características de *buildup*, *shoulder* e intermitência não são consideradas.

- **Modelo com Resistências Variáveis proposto por Nam *et al.* (2001) :**

Um modelo de FAI usando duas resistências não lineares em séries como mostrado na Figura 11 foi apresentado em 2001. O modelo pode ser implementado utilizando-se o *software Alternative Transients Program (ATP)* com a rotina *Transient Analysis of Control Systems (TACS)* para controlar as duas resistências que são variantes no tempo.

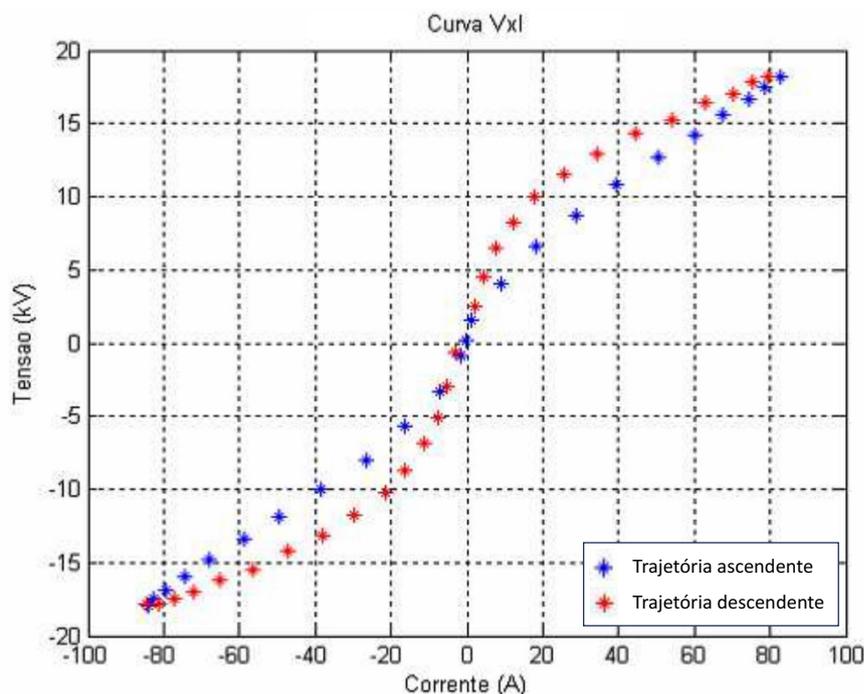
Figura 11 – Circuito equivalente do modelo de FAI com resistências variáveis em série.



Fonte: Adaptado de (NAM *et al.*, 2001)

Neste modelo o resistor $R_1(t)$ simula as características de não linearidade e assimetria da FAI, atuando nos regimes transitório e permanente. Já o resistor $R_2(t)$ reproduz os fenômenos de *buildup* e *shoulder*.

Deste modelo podem ser destacadas as seguintes características na corrente de falta: distorção na forma de onda, assimetria entre os semiciclos, intermitência, descontinuidade, *buildup* e *shoulder*. Na Figura 12 é apresentada a curva tensão por corrente ($V \times I$) característica deste modelo, em vermelho a trajetória ascendente da tensão e em azul a descendente.

Figura 12 – Curva $V \times I$ característica para FAI.

Fonte: Adaptado de (NAKAGOMI, 2006)

Este modelo não reproduz os componentes de alta frequência pois desconsidera a característica de intermitência da corrente de falta. Além disso, uma limitação prática deste modelo é a necessidade de dados reais de tensão e corrente de arco, que geralmente não estão disponíveis, tornando-o pouco viável.

Os modelos apresentados são os mais comumente utilizados para FAI encontrados na literatura técnica. Existem modelos mais atuais que utilizam como base os modelos expostos em busca de melhorias. O tipo de modelo de falta para simulação deve ser escolhido de acordo com aplicação e as informações disponíveis.

Considerando o propósito e condições deste trabalho, um modelo de interesse deve reproduzir o mais fielmente as FAI, mas sem a necessidade de medidas reais de tensão e de corrente. Modelos que os autores não apresentam os valores dos parâmetros foram descartados. Assim como aqueles que necessitam de muitos ajustes, com método tentativa e erro, para obtenção da forma de onda de corrente que se assemelhe às disponíveis na literatura. Os modelos selecionados são apresentados de forma detalhada na seção 4.3

2.2 DETECÇÃO DE FALTAS DE ALTA IMPEDÂNCIA

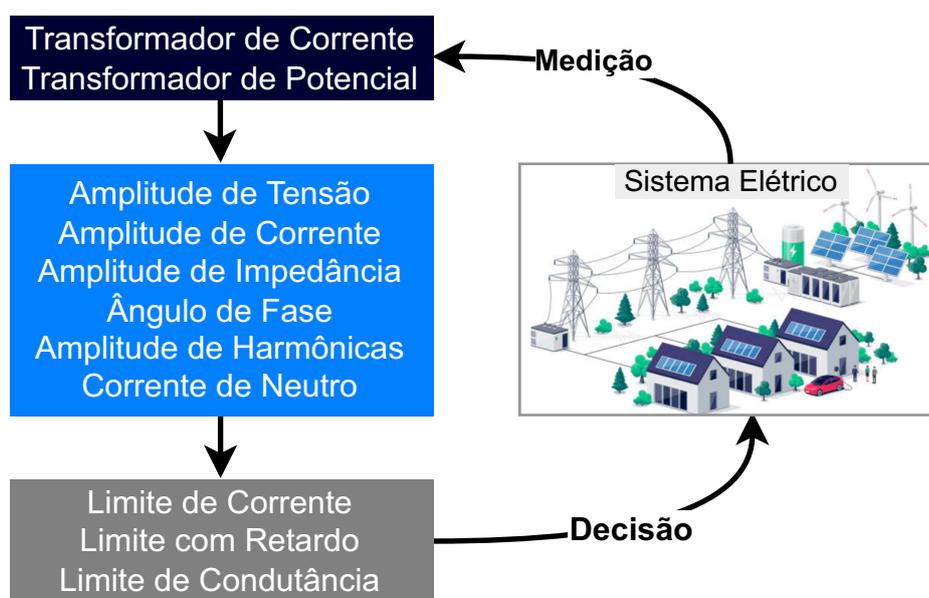
Os algoritmos desenvolvidos para a detecção de FAI tem como tarefa a classificação de padrões, distinguindo a partir de informações disponíveis se um evento no

sistema elétrico é uma falta ou qualquer outro transitório elétrico. Esta tarefa pode ser dividida em duas etapas: caracterizar as FAI e procurar a presença de parâmetros que as diferenciem de eventos similares.

Uma função de proteção que utiliza a detecção de faltas por classificação de padrões é vantajosa, pois permite que as tarefas sejam segregadas em blocos essenciais para assim, abordá-las separadamente. Além disso, a classificação de padrões tem critérios quantitativos de avaliação que permitem comparar e categorizar as técnicas de detecção de acordo com o seu desempenho frente a diferentes situações de emprego (GHADERI, Amin *et al.*, 2017).

O processo de classificação aplicado a um SDE, apresentado na Figura 13, tem três etapas: medição, extração de características e classificação que leva a tomada de uma ação sobre o SDE ou não. As medidas obtidas devem se adequar ao algoritmo se, por exemplo, as características de alta frequência são importantes, a taxa de amostragem deve ser grande o bastante para fornecer esta informação. Para extração das características deve-se levar em conta capacidade de processamento dos equipamentos, o tempo para que essa informação seja obtida e a quantidade e qualidade de medidas disponíveis. O processo de classificação normalmente utiliza limites para estabelecer qual evento elétrico está ocorrendo. A partir desta classificação, o sistema de proteção decide se o transitório detectado requer a sua atuação.

Figura 13 – Estrutura da técnica de detecção de FAI.



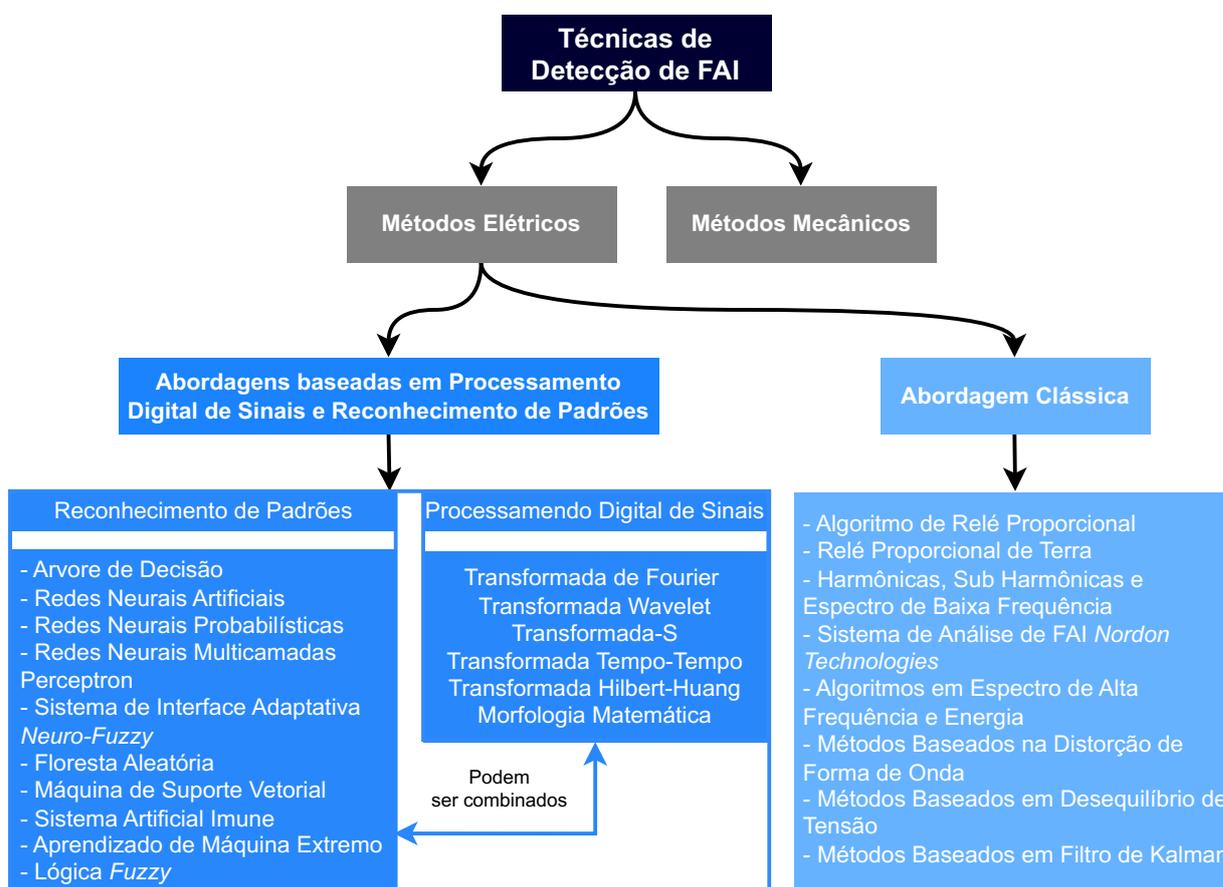
Fonte: Adaptado de (GHADERI, Amin *et al.*, 2017).

Em um caso hipotético de detecção de FAI, estes passos, mostrados na Figura 13, seriam os seguintes: 1º medir a corrente e ou tensão de linha utilizando

transformadores de corrente e potencial, 2º extrair características significativas que representem a ocorrência da falta, 3º determinar se a característica analisada atingiu o limiar que separa um estado de operação normal ou de falta.

A detecção de FAI em SDE é um problema não trivial, pois o espectro de frequência envolvido neste fenômeno é semelhante a outros fenômenos transitórios como o chaveamento de bancos de capacitores e chaveamento de cargas. Além disso, a preocupação com a ocorrência desse fenômeno não é nova, em (SEDIGHIZADEH *et al.*, 2010) é apresentada uma linha cronológica dos métodos de detecção de FAI que se inicia em 1960. Neste trabalho a classificação e apresentação dos métodos de detecção de FAI seguiram a taxonomia apresentada por (MISHRA; PANIGRAHI, 2019), mostrada na Figura 14.

Figura 14 – Classificação dos métodos de detecção de FAI.



Fonte: Adaptado de (MISHRA; PANIGRAHI, 2019)

Os métodos mecânicos consistem na instalação de dispositivos que fornecem um caminho de baixa impedância para a corrente quando ocorrem rompimento dos condutores, assim, a proteção de sobrecorrente é sensibilizada. Este tipo de solução pode ser aplicado próximo a escolas, hospitais e locais de grande circulação de

peças, mas tem um alto custo de manutenção e instalação (MISHRA; PANIGRAHI, 2019).

O métodos elétricos foram divididos entre métodos clássicos e métodos que utilizam o processamento digital de sinal associado a técnicas de reconhecimento de padrões, sendo este último o foco deste trabalho. Nas seções seguintes serão detalhadas as tarefas realizadas no processos de classificação de faltas, especificamente na detecção de FAI como apresentados na Figura 14.

2.2.1 Medições e Extração de Características

- **Medição de Corrente:** na FAI a forma de onda da corrente é não estacionária e com características não lineares, resultando em componentes de alta e baixa frequência, que são utilizados na sua detecção. No entanto, as linhas de distribuição e os transformadores de corrente atuam como um filtro passa-baixas, assim, parte da informação sobre FAI contida na corrente é perdida antes do seu processamento. Por isso, a medição de corrente é recomendada para sistemas fortes, pois essa atenuação de sinal é menor, ou a utilização de mais pontos de medição (HONG; HUANG, W.-S., 2015). A utilização de esquemas de proteção diferencial também podem ser utilizados contra FAI como mostrado em (SAMANTARAY, S. R. *et al.*, 2012; KHANDARE; DEOKAR, 2015; KAR; SAMANTARAY, Subhransu Rajan, 2014).
- **Medição de Tensão:** este tipo de medida é mais indicado para SDE mais fracas, devido a atenuação do sinal de tensão ao longo das linhas de distribuição. Isto porque apenas nesses sistemas há uma queda de tensão suficiente do ponto de localização da falta até o relé onde são feitas as medidas de tensão (BAKAR *et al.*, 2014; MORETO; KURSANCEW KHAIRALLA, 2018; THOMAS *et al.*, 2016; MORETO; KURSANCEW KHAIRALLA, 2018).
- **Medição de Tensão e Corrente:** o uso das medições de tensão e corrente, de forma simultânea, aumenta a confiabilidade da técnica de detecção. Essa associação de grandezas elétricas já foi utilizada em técnicas de detecção e localização de FAI usando ondas viajantes (MILIOUDIS *et al.*, 2012a, 2012b). Adicionalmente, sincrofasores de tensão e corrente, obtidos a partir de PMUs, também foram utilizados por conter uma boa taxa de amostragem e medidas na mesma base de tempo. Esse tipo de esquema de medição aumenta a confiabilidade do método de detecção, mas acarreta alto custo de implementação (ZANJANI *et al.*, 2012).

A segunda etapa consiste na extração de características ocultas nas medidas, transformando o domínio das grandezas elétricas cujas variações mais significativas são observadas. Em técnicas de detecção com abordagens diferentes das clássicas a

extração de características se dá com DSP, quadro vermelho ao centro da Figura 13. Os domínios com melhor representação para detecção de FAI são o domínio do tempo, domínio da frequência, domínio de escala de tempo e domínio de tempo-frequência. Estes domínios são descritos a seguir:

- **Domínio do Tempo:** neste domínio é possível extrair as deformações no tempo das formas de onda senoidais de tensão e corrente na ocorrência de uma FAI. Porém, os índices simples como magnitude, valor *Root Mean Square* (RMS), valor de pico ou médio nem sempre são parâmetros eficientes para denunciar distorções causadas pelas FAI. Algumas técnicas de domínio do tempo utilizam-se de outros índices, tais como a magnitude da componente de sequência zero, as funções caóticas (que buscam a variação dos estados de linearidade do sistema), geometria fractal (que aponta o nível de aleatoriedade nas formas de onda) e morfologia matemática (revela irregularidades nas formas de onda) (GHADERI, Amin *et al.*, 2017).
- **Domínio da Frequência:** as técnicas que utilizam o domínio da frequência buscam as componentes de baixa e alta frequência resultantes do arco elétrico durante uma FAI, conforme já apresentado na Tabela 2. As técnicas baseadas em baixa frequência aproveitam que a não linearidade resulta em harmônicos de baixa ordem, a 3^o harmônica geralmente é utilizada. Outras frequências harmônicas pares, ímpares e inter-harmônicas de baixa frequência, também podem ser utilizadas como parâmetro de detecção. As técnicas baseadas em alta frequência aproveitam a variação aleatória e brusca da corrente durante as FAI. Com a *Fast Fourier Transform* (FFT) é possível extrair as componentes harmônicas, porém, a corrente de FAI é não estacionária com as componentes harmônicas variando no tempo. Assim várias técnicas utilizam a filtragem de Kalman, para estimar as componentes de frequência da corrente FAI (GHADERI, Amin *et al.*, 2017).
- **Domínio em Escala de Tempo:** este domínio de análise, que também é conhecido como Transformada Wavelet (TW), coleta as informações de frequência e o instante em que esses componentes de frequência ocorrem. Está é um importante vantagem na detecção de FAI pois a sua corrente tem espectro de frequência variável no tempo. Mas este domínio implica que as medidas tenham frequência de amostragem adequada, FAI têm componentes de 10 kHz, assim é preciso de pelo menos 20 kHz de taxa de amostragem. Além disso, é preciso fazer a escolha da wavelet mãe que melhor se adéque a detecção. Segundo (GHADERI, Amin *et al.*, 2017) cerca de 40% de todas as técnicas de detecção de FAI foram baseadas em TW.

- **Domínio do Tempo-Frequência:** este domínio consegue manter a localização tempo-frequência da TW, estimando a energia do sinal em cada ponto de coordenadas de tempo e frequência. Técnicas neste domínio utilizam a transformada-S e apresentam uma confiabilidade superior as que utilizam TW. No entanto, requerem alta capacidade computacional em comparação com os outros domínios (GHADERI, Amin *et al.*, 2017).

2.3 TÉCNICAS DE CLASSIFICAÇÃO

A terceira etapa das técnicas de detecção de faltas é encontrar o limite que separa um estado defeituoso de um saudável. Para a detecção de FAI, vários classificadores com diferentes níveis de complexidade foram desenvolvidos. Abaixo tem-se os detalhes listados.

- **Limitador Simples:** este classificador funciona de maneira análoga ao de relés de sobrecorrente, com um valor limiar para um determinado atributo separando a condição normal da condição de falta. Várias técnicas utilizam esse tipo de classificador que simplifica bastante a metodologia de detecção. Entretanto este classificador não é recomendado para tratar as FAI, pois sua natureza simples diminuiria a confiabilidade do método de detecção. Artigos que usam esse classificador são (SIADATAN *et al.*, 2010; GONZÁLEZ *et al.*, 2014) usando análise no domínio do tempo, (TORRES *et al.*, 2014; SARLAK, Mostafa *et al.*, 2010) no domínio da frequência e (ALI *et al.*, 2014; CHEN *et al.*, 2014) com o domínio de escala do tempo.
- **Limitador e Contador:** a adição de um contador aumenta a confiabilidade dos classificadores com limitador simples. Este contador acumula as detecções de FAI consecutivas e o classificador decide se ocorreu uma falta. Esta técnica é lenta, necessita de mais memória para processamento e não é capaz de detectar FAI permanentes. Alguns trabalhos que usam esse classificador são (HOU; FISCHER, 2006; GAUTAM; BRAHMA, 2013) que aplicam análise no domínio do tempo, em (HEN-GEUL YEH *et al.*, 2014; ABOUL-ZAHAB *et al.*, 2008) no domínio da frequência e (BAKAR *et al.*, 2014; LAZKANO, Andoni *et al.*, 2004) com o domínio de escala do tempo.
- **Redes Neurais:** trata-se de uma técnica de inteligência computacional com grande precisão para o reconhecimento de padrões e generalização, rápida resposta, habilidade de filtrar ruídos além de capacidade de predição. Se trata de uma técnica muito utilizada para detecção de FAI, constando que pelo menos 23% contenham alguma topologia de redes neurais (GHADERI, Amin *et al.*, 2017). Porém essa técnica aumenta bastante a complexidade do algoritmo, sendo de-

pendente da qualidade das informações utilizadas para o seu treinamento. Adicionalmente, o número de neurônios em cada camada da rede é um processo de tentativa e erro. Nas próximas subseções serão apresentados trabalhos com essa técnica de classificação.

- **Outras Técnicas:** Lógica FuzzyLF e *Support Vector Machine* SVM são mais atrativas do que classificadores que utilizam árvore de decisão, algoritmo genético entre outros (GHADERI, Amin *et al.*, 2017). Embora menos estudados e utilizados, é possível obter um alto nível de eficiência na detecção de FAI se associados de medições e domínio de análise apropriados. Detalhes dessas técnicas, bem como artigos pertinentes serão apresentados nas subseções a seguir.

Esta terceira etapa completa o ciclo de tarefa para classificação de padrões na detecção de FAI. Em seguida são apresentados os principais métodos de detecção conforme a taxonomia apresentada na Figura 13. As técnicas clássicas de detecção de FAI são listadas e explicadas, junto com alguns trabalhos relevantes que as utilizam:

- **Relé Proporcional e Relé Proporcional de Terra:** o algoritmo de relé proporcional combina duas medidas de corrente para criar um parâmetro de detecção em sistemas de distribuição multi-aterrados. Esta técnica isola a corrente de falta a partir da soma ponderada das correntes de sequência negativa e de neutro ($I_F = k_1 I_0 + K_2 I_N$) (CARR, 1981). No esquema de relé proporcional de terra, o índice de detecção de falta é obtido a partir da relação entre a corrente residual ($3I_0$) e um dentre os 4 parâmetros: (1) diferença de corrente de sequência equilibrada, (2) corrente de sequência positiva, (3) soma das correntes a e b e (4) soma das correntes a,b e c (CALHOUN *et al.*, 1982). Estes métodos foram desenvolvidos para relés eletromecânicos, datam do início da década de 80 e tem uma implementação relativamente simples. Porém, o ajuste dos limites não é uma tarefa trivial e sua confiabilidade não é garantida (MISHRA; PANIGRAHI, 2019).
- **Espectro Harmônico e Baixa Frequência:** há na literatura uma boa quantidade de técnicas de detecção de FAI com análise do conteúdo harmônico e o espectro de baixa frequência presente na corrente, publicados principalmente dos anos 80 até início dos anos 2000. Em (YU; KHAN, 1994) é apresentada uma técnica adaptativa de detecção que utiliza uma combinação de características da corrente sendo a magnitude da componente fundamental, 3ª e 5ª harmônicas. Sharaf *et al.* (1996) apresentam um esquema para detecção de FAI em SDE com topologia radial baseado no conceito de frequências harmônicas quase-estática, sub e super harmônicas. Estas componentes são encontradas na corrente elétrica de baixa magnitude e com presença de arco elétrico resultante de FAI. A magnitude

de harmônicas ímpares e pares presente na corrente elétrica foram utilizadas como índice de detecção de FAI. Este método utilizou registros oscilográficos de condutores rompidos no SDE da Espanha (LAZKANO, A. *et al.*, 2000). Em (LIMA *et al.*, 2019) foi utilizada a transformada de Stockwell para obter o ângulo da 3ª harmônica da corrente, que associada ao desvio padrão, são utilizadas para detecção de FAI

- **Espectro de Alta Frequência e Energia:** o sinal de corrente elétrica durante FAI tem uma notável parcela de alta frequência, devido a presença do arco elétrico, distinta de outras condições sem falta. Em eventos de chaveamento e comutação também existem essas componentes de alta frequência, mas com duração reduzida. Com isso, é possível determinar a presença de FAI no sistema quando componentes de alta frequência no sinal de corrente são detectados por mais tempo que o evento de chaveamento. Essa foi a estratégia de detecção utilizada por (AUCOIN, B. M.; RUSSELL, B. D., 1982). Neste trabalho, os sinais de corrente de alta frequência com a banda de de 2-10 kHz foram examinados, e o cálculo da energia (duração do sinal) foi feito com a FFT. Em 1985, o mesmo autor usou esta mesma técnica para correntes harmônicas de baixa frequência e não harmônicas (AUCOIN, M. *et al.*, 1985a, 1985b). M. Aucoin *et al.* (1985b) propuseram um indicador de baixo custo de FAI para o sistema de iluminação em baixa tensão na cidade de Seattle, com o algoritmo de B. M. Aucoin e B. D. Russell (1982). Mas é preciso ter em mente que a corrente de FAI é um sinal não estacionário, resultando em um espectro de frequência variável.
- **Distorção na Forma de Onda:** existem dois trabalhos na literatura técnica que apresentam abordagens de detecção com uso da distorção na onda senóide causada pelas FAI como parâmetro de detecção. O mais recente propõem um novo parâmetro chamado fator de crista modificado (*revised crest factor*), que é calculado pela multiplicação do fator de crista pelo fator de forma (KIM; RUSSELL, B., 1995). O fator de crista é a relação entre os valores de pico e RMS da onda, já o fator de forma é a relação entre o valor RMS e o valor médio de cada semi ciclo. No segundo trabalho, (SULTAN, A. F. *et al.*, 1994), são utilizados o cálculo de *flicker* e assimetria na corrente elétrica. O *flicker* é calculado comparando os picos máximo e mínimo da corrente em um ciclo com os valores do próximo ciclo. Já na assimetria são comparados os picos positivos com os negativos na forma de onda da corrente elétrica, com uma janela deslizante de um ciclo e meio. Em (WANG, X. *et al.*, 2022) a característica de *build-up* da FAI é detectada na corrente de de sequência zero. Utilizando ressonância estocástica e *Variational Mode Decomposition* (VMD), os componentes de alta e baixa frequência desta corrente são separados. Então, índices estatísticos como curtoses e obliquidade

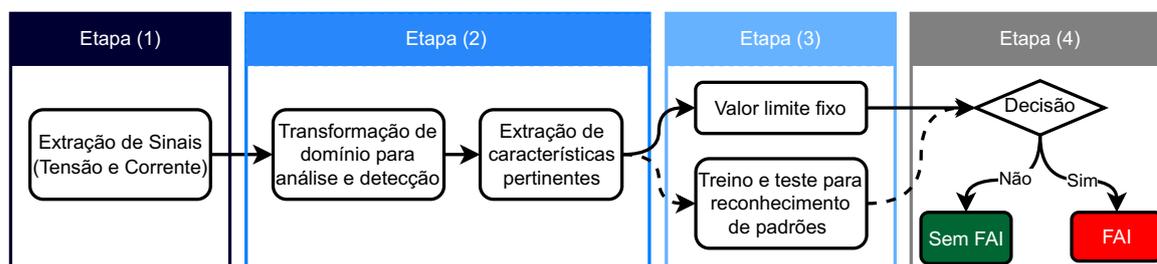
(*skewness*) permitem fazer a diferenciação de FAI em relação a chaveamento de carga e banco de capacitores, além da corrente de *inrush*.

- **Desequilíbrio de Tensão:** quando um condutor do SDE se rompe e cai ao solo, o desequilíbrio resultante nas tensões pode ser percebido pela monitoração das componentes negativa e zero da tensão (MISHRA; PANIGRAHI, 2019). Em 1992 a empresa *Kearny Manufacturing Company* desenvolveu um sistema de detecção de cabos rompidos, usando sensores para monitorar a presença de desequilíbrio tensão no fim de alimentadores radiais (TENGDIN *et al.*, 1996). O trabalho apresentado por (NAYAK *et al.*, 2016) também utiliza o desequilíbrio de tensão como indicador da presença de FAI, mas ele será apresentado detalhadamente na seção 3.3 devido à similaridade com o trabalho aqui proposto.
- **Filtro de Kalman:** Girgis *et al.* (1990) desenvolveu uma técnica de detecção utilizando filtro de Kalman para obter uma melhor estimativa das variações de tempo dos componentes fundamentais e harmônicos. O método foi desenvolvido e aplicado com a utilização de quatro conjuntos de dados oscilográficos para diferentes tipos de solo obtidos da base de dados da Universidade do Texas, obtidos de (AUCCOIN, B. M.; JONES, 1996). Dos resultados observou-se que a terceira harmônica de corrente tem uma variação mais dominante em relação a quinta e sétima, além disso a variação nos harmônicos pares não era tão definida quanto nos de ordem ímpar. Mais recentemente um pesquisador indiano publicou dois trabalhos utilizando filtro de Kalman para extração do conteúdo harmônico do sinal de corrente na detecção de FAI (SAMANTARAY, S.R. *et al.*, 2009; SAMANTARAY, S. R.; DASH, 2010), conforme detalhado na seção 2.3.3.

A evolução tecnológica em SDE possibilitou a aquisição de sinais com uma melhor resolução, associada a maior velocidade e capacidade de processamento dos dispositivos de proteção, resultando na popularização de DSP. Assim, a análise de vários distúrbios na rede elétrica pode ter este tipo de abordagem, conforme apresentado na Figura 15. Essas novas informações vindas do DSP são então utilizadas em TRP, que consistem em quatro etapas que são: (1) aquisição de sinais, (2) extração de características, (3) estabelecimento de limites, (4) decisão.

Na etapa (1) medidas de tensão e corrente são obtidas com transformadores de instrumentação que são processadas usando técnicas de DSP para extração de características úteis para analisar a ocorrência de algum evento na etapa (2). Na etapa (3) um valor limite deve ser estabelecido para as características extraídas de forma a diferenciar faltas de eventos transitórios normais. Se um valor muito elevado for estabelecido certas condições de falta não serão percebidas, assim como um valor muito baixo pode resultar em falsa detecção resultando em desligamento de um sistema saudável.

Figura 15 – Fluxograma da técnica de detecção de FAI com base em DSP.



Fonte: Adaptado de (MISHRA; PANIGRAHI, 2019)

As TRP são uma ferramenta muito útil para a terceira etapa, diminuindo o problema de sensibilidade do método de detecção. Classificadores inteligentes em conjunto com técnicas de DSP para extração de características atuam como um sistema de detecção especializado, mostrado na linha tracejada da Figura 15.

Dentre as técnicas de reconhecimento de padrões mais populares utilizadas para a detecção de faltas em sistema elétricos são: RNA, SVM, LF e abordagem coincidente (GURURAJAPATHY *et al.*, 2017). TRP como árvore de decisão (AD) e algoritmos genéticos (AG) também são populares, com um grande conjunto de dados fornecido ao modelo formando um algoritmo capaz de reconhecer padrões com alto grau de pertinência. A seguir, é apresentada uma visão geral de algumas TRP, junto com conceitos básicos e trabalhos relacionados a tarefa de detecção de FAI.

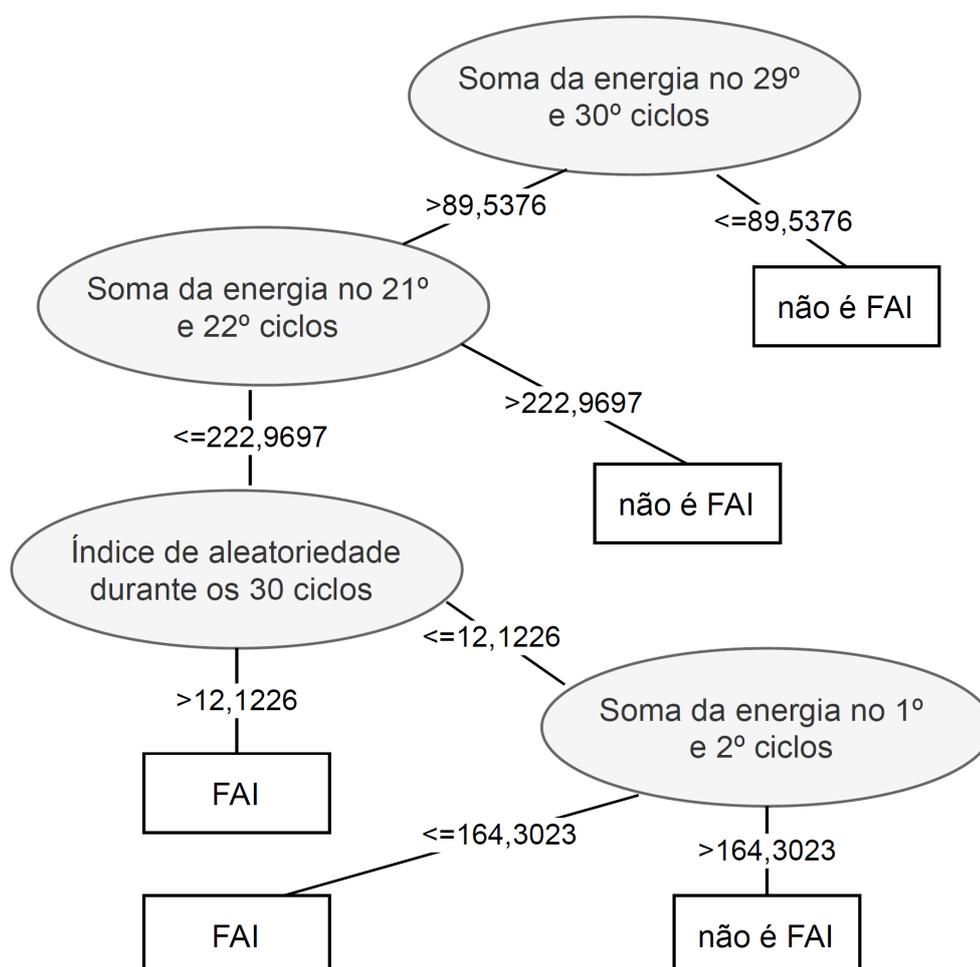
2.3.1 Árvore de Decisão (AD)

AD é uma ferramenta computacional que a partir de regras hierarquizadas, tipo fluxograma na forma de árvore, é possível estabelecer um procedimento para classificação de eventos. Dados de entrada são fornecidos para treinamento que constrói a árvore, composta por nós que determinam o caminho pelos ramos até as folhas com testes de atributos. Cada ramo representa o resultado de um teste e cada folha representa um resultado do classificador.

Em (SHAHRTASH, S. M.; SARLAK, M., 2006) foi utilizada a técnica de árvore de decisão para detecção de FAI em um SDE radial, com tensão de 12,5 kV e 50 Hz de frequência. O algoritmo J48 do *software* WEKA foi utilizado para o desenvolvimento da AD. O sistema foi simulado no *software* ATP com extração de características para o classificador realizados em *software* MatLab. Com o uso do teorema de Parseval é calculado o conteúdo energético das harmônicas pares, ímpares e inter-harmônicas até 400 Hz da corrente. O treinamento foi realizado com 2583 casos e testado para 1331. Na Figura 16 é apresentada a estrutura do classificador, com o caminho para as folhas passando por nós com atributos são avaliados. As folhas são os quadrados

brancos com a classificação final para uma dada entrada e os círculos cinzas são os nós de decisão.

Figura 16 – Algoritmo de AD para detecção de FAI.



Fonte: Adaptado (SHAHRTASH, S. M.; SARLAK, M., 2006)

Amostras de dados com 30 ciclos levam a um melhor desempenho do método com 99,4% de precisão, além de gerar uma árvore menor e mais simples. Também a complexidade da árvore de decisão é inversamente proporcional à taxa de amostragem, que os autores recomendam para ser ajustada em 2 kHz.

Floresta aleatória de decisão (*random decision forests*) é uma ferramenta de mineração de dados que pode realizar classificação com multiplicidade de AD, obtendo desempenho melhor do que uma árvore individual e com melhor generalização. Essa ferramenta foi utilizada em (SAMANTARAY, S.R., 2012) junto com filtro de Kalman para detecção de FAI. O filtro obtém magnitude e ângulo das componentes fundamental, 3ª, 5ª, 7ª, 11ª e 13ª harmônicas da corrente elétrica. Essas características formam um conjunto de dados de entrada para o Classificador. Dois sistemas teste foram utilizados, um em anel e outro radial, totalizando 20580 casos para treinamento da

mesma floresta. Para testar o método, outros 8820 casos foram testados apresentando uma precisão de 99,5%, confiabilidade de 99,6% e um tempo de disparo de 2 ciclos, mesmo em um ambiente ruidoso (*Signal-to-noise ratio* (SNR) 20 dB).

O trabalho (KAR; SAMANTARAY, 2016) descreve um método de detecção de FAI em MR utilizando AD e TW discreta com máxima sobreposição. Com a TW, 12 características estatísticas dos coeficientes de detalhe e aproximação são utilizadas no treinamento do classificador. O trabalho proposto considerou 1493 casos (973 FAI e 520 não FAI) para MR operando no modo conectado e ilhado. Destes 1493 casos, 70% são utilizados para a formação da AD, enquanto os restantes 30% são utilizados para testes.

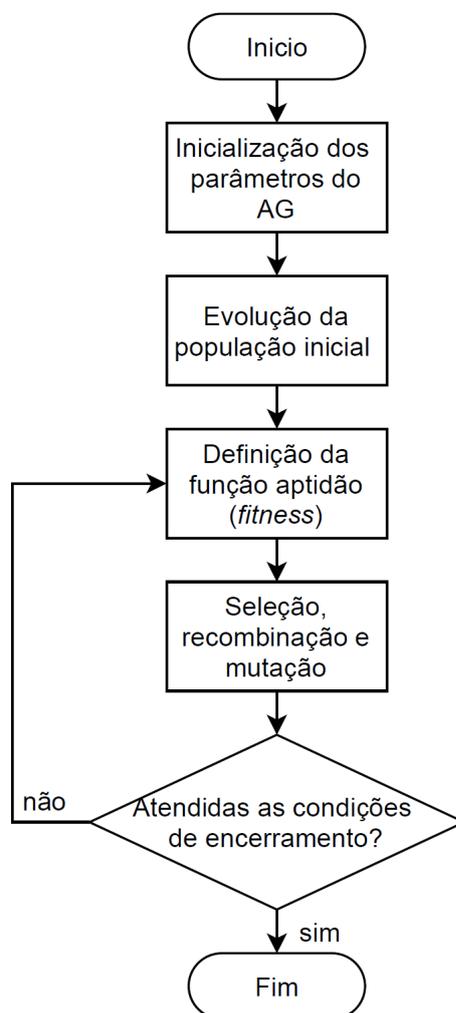
Nos testes foi observado que o método tem um desempenho melhor quando a MR está operando de forma conectada. Para o modo conectado o método obteve 100% de precisão, 100% de confiabilidade e 100% de garantia. No modo ilhado o desempenho foi 99,32% de precisão, 100% de confiabilidade e 98,23% de garantia.

Em (SEKAR *et al.*, 2018) uma técnica que utiliza AD e TW discreta (db4 - 5 níveis) é utilizada na detecção de FAI. O treinamento do classificador AD é feito com 4 características extraídas da corrente trifásica medida na saída do alimentador, que são desvio padrão, energia total, curtose e assimetria. Um total de 936 casos entre FAI e não FAI foram simulados, sendo 655 utilizados no treinamento da AD e 281 para testar o método. O desempenho obtido foi de 98,22% de precisão, 95,79% de garantia e 100% de confiabilidade, para um ruído de SNR 10 dB e 512 amostras por ciclo. Quando o ruído é elevado para relação SNR 30 dB tem-se 94,3% de precisão, 90,71% de garantia e 96,91% de confiabilidade. Já se o número de amostras é reduzido para 128 por ciclo resulta em 93,59% de precisão, 92,43% de garantia e 95,6% de confiabilidade.

2.3.2 Algoritmo Genético (AG)

Algoritmo Genético (AG) é uma estratégia inteligente que também pode ser utilizada para detectar e localizar faltas. Este tipo de algoritmo evolutivo procura soluções para problemas de otimização e busca, com inspiração na evolução biológica utiliza funções como hereditariedade, mutação, seleção natural e recombinação (ou *crossover*). Na Figura 17 é apresentado um fluxograma de AG. A inicialização do AG se dá com uma população de soluções candidatas a um problema de otimização, que é evoluída em direção a melhores soluções. A evolução é um processo iterativo cujas propriedades das soluções candidatas são alteradas por seleção, recombinação ou mutação e sua aptidão é avaliada (valor da função objetiva no problema de otimização). Cada iteração que resulta em uma nova população é chamada de geração. Geralmente, o algoritmo termina quando um número máximo de gerações é produzido, ou quando um nível satisfatório de aptidão é atingido para a população.

Figura 17 – Fluxograma de um algoritmo genético.



Fonte: Adaptado de (GURURAJAPATHY *et al.*, 2017)

Em (SEDIGHI, A.-R. *et al.*, 2005) são apresentados dois métodos de detecção de FAI em SDE, o primeiro baseado em AG e segundo em RNA. No primeiro o AG é utilizado na redução do vetor com as características da FAI para treinamento de um classificador tipo *naive Bayes*. O segundo método reduz o vetor de características com *Principal Components Analysis* (PCA) e classifica com RNA. Em ambos, a TW (rbio3.1) é utilizada para decomposição da corrente (amostragem de 24,67 kHz) para formação do vetor com as características da FAI. Os métodos utilizaram dados reais de FAI e corrente de fuga de isoladores, obtidos com experimentos em um alimentador radial com tensão de 20 kV com 60 Hz de frequência, no Irã, para diferentes superfícies molhadas e secas (asfalto, cimento, solo e madeira). Mas eventos como chaveamento de carga, capacitores, transformadores e faltas monofásicas foram simulados em *Power Systems Computer-Aided Design* (PSCAD) para obtenção das medidas de corrente. Para o sistema em estudo, o método conseguiu 98,3% de precisão, 95% de confiabilidade

e 100% de garantia.

Um AG associado com algoritmo de mineração de dados *k-means* foi utilizado para determinar os pontos de medição de corrente para localização de FAI em um SDE radial com múltiplos alimentadores (HONG; HUANG, W.-S., 2015). Nessas medidas de corrente são realizadas a TW discreta, calculadas as energias (3 níveis) que formam as características de entrada para o treinamento de um classificador do tipo SVM. O sistema teste utilizado continha 18 barras, trifásico/balanceado com tensão de 12,5 kV com 60 Hz de frequência, que foi simulado no *software* MatLab/Simulink. Os resultados mostraram que é possível uma boa precisão na localização com apenas dois pontos de medição, com 98,4% de precisão.

O artigo (ZAMANAN, N. *et al.*, 2007) apresenta uma técnica de detecção de FAI em SDE com o uso de AG. Um sistema teste radial trifásico, tensão de 11 kV e frequência de 50 Hz, 4 barras e linhas modelo Π com 8 km total foi implementado no *software* MatLab. Com ajuda do AG determinou-se que existe uma FAI no sistema sempre que um dos três parâmetros excederem o limite: magnitude do 3^a harmônico de corrente maior que 1% da fundamental, magnitude do 5^a harmônico de corrente maior que 0,5% da fundamental ou deslocamento angular da 3^a harmônica em relação a fundamental exceder 100 graus.

Para detecção e localização de FAI em (SARLAK, M.; SHAHRTASH, S. M., 2013) é apresentado um dispositivo identificador que utiliza SVM e análise do gradiente morfológico multirresolução (AGMM -*multi-resolution morphological gradient*). Um AG é responsável pela seleção das características relevantes obtidas da AGMM para o treinamento e teste do classificador SVM. Dispositivos indicadores devem ser instalados nos postes de maneira tal que seja possível a localização do ramo onde ocorre a FAI no alimentador (no fim dos ramos por exemplo). O sistema teste é o alimentador Palash em Terã, onde foram realizados diversos estudos e experimentos a respeito de FAI. Portanto, medidas reais de corrente elétricas foram convertidas usando cálculo para assinatura do campo magnético, que é o parâmetro de detecção utilizado no método. O método mostrou-se confiável para um ambiente com relação SNR de até 20 db, o aumento do ruído implica na degradação do desempenho do método. Além disso os autores utilizaram medições e parâmetros apenas da fase C, sendo necessário treinar outros dois algoritmos para as demais fases de forma a obter uma generalização do método.

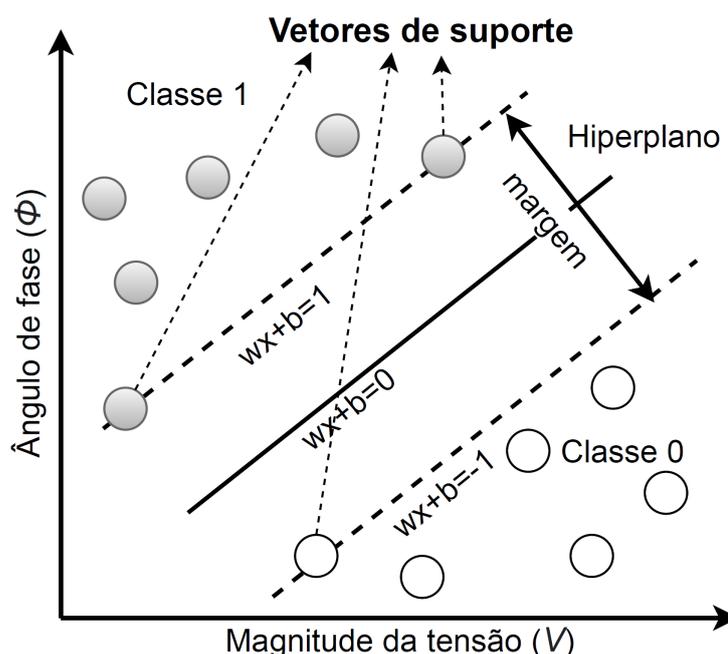
2.3.3 Support Vector Machine (SVM)

SVM é um método de análise de dados para reconhecimento de padrões utilizada em técnicas de classificação e regressão, que vem se popularizando devido ao seu desempenho. Na montagem do algoritmo, o número de vetores de suporte é determinado pelo algoritmo, já em RNA o número de camadas ocultas é determinado

pelo método de tentativa e erro (GURURAJAPATHY *et al.*, 2017). O SVM padrão toma como entrada um conjunto de dados e prediz, para cada entrada dada, qual de duas possíveis classes a entrada faz parte, o que faz do SVM um classificador linear binário não probabilístico.

Na Figura 18 é mostrada a classificação entre Classe 1 e Classe 0 de uma entrada. Os pontos são marcados usando dados de treinamento, com a fase e magnitude da tensão, para a classificação de faltas. Os vetores de suporte são os elementos do conjunto de treino, que identificam o hiperplano divisor, com os círculos cinza da classe 1 e os círculos brancos da classe 0. O hiperplano divisor busca maximizar a distância entre os pontos mais próximos em relação a cada uma das classes. Essa distância é dita margem sendo definida como a soma da distância mínima entre o conjunto de dados de formação e o hiperplano separador. Para uma entrada, com medida de tensão (V e ϕ), o alvo de saída é o tipo de falta com a identificação do hiperplano ótimo. O objetivo é identificar o hiperplano para a classificação das classes 1 e 0.

Figura 18 – Classificação linear com SVM.



Fonte: Adaptado de (GURURAJAPATHY *et al.*, 2017)

Para lidar com padrões não lineares, a SVM tem a função *kernel*, que transforma dados não lineares em um novo espaço de grande dimensão, com um conjunto de dados linearmente separável.

Um método de detecção de FAI em SDE com a utilização de SVM como classificador de padrões foi proposto em (GHADERI, A. *et al.*, 2015). As características utilizadas para treino do classificador são a energia da forma de onda da corrente e

o momento normalizado de tempo-frequência (*normalized joint time–frequency moments*). A eficácia do método é testada com o uso de dados reais obtidos a partir de testes de campo para FAI em concreto, grama e galhos de árvore e com a superfície de contato seca e úmida. Os autores comparam o método proposto com métodos tradicionais usando os seguintes critérios: precisão, confiabilidade, garantia, segurança, sensibilidade, custo, objetividade, integralidade e velocidade. São comparados os classificadores como função discriminante linear, função discriminante quadrática, *naive Bayes*, RNA e SVM que se mostrou mais adequado para o algoritmo de detecção. O método apresenta bom desempenho e baixo custo computacional, porém, só é aplicável em sistemas radiais. Além disso, para utilização do método em relés microprocessados, os autores recomendam testes mais abrangentes com uma maior variedade de superfícies e cenários mais realistas.

Em (SARLAK; SHAHRTASH, S., 2011b) é apresentado um método baseado em SVM para detecção de FAI em SDE radiais. A TW discreta é aplicada para extração de características da corrente. Então, utiliza-se a PCA para obtenção do melhor conjunto de características para treinamento da SVM, obtendo a mínima dimensionalidade no vetor de entrada sem perdas de informação. Os autores testaram o algoritmo para condutores partidos, FAI com arco elétrico e eventos semelhantes como: chaveamento de capacitores, magnetização de transformadores sem carga, chaveamento de cargas e cargas não lineares obtendo 99,6% de confiabilidade, 99,8% de garantia e 1,5 ciclos para detecção. Além disso, o método com SVM apresentou melhor desempenho em comparação com classificadores *naive Bayes* e redes neurais *perceptron* multicamadas.

Uma metodologia que monitora as correntes em um alimentador de distribuição para detecção de FAI é apresentado em (SAHOO; BARAN, 2014). Os autores observaram que todos os eventos similares a FAI tem componentes de alta frequência na corrente, porém, elas desaparecem após dois ciclos em eventos como chaveamentos de cargas e capacitores. Mas no caso de FAI, elas permanecem durante todo o tempo da falta. Assim, foi utilizada a TW discreta para extrair essas componentes de alta frequência e foi calculada sua energia. Esse parâmetro de energia foi utilizado como índice de detecção em um classificador do tipo SVM. Simulações foram realizadas no *software* MatLab/Simulink para formação de um banco de dados com medições de corrente na saída do alimentador com 64 amostras/ciclo. Então, 80% dos dados foram utilizados para treinamento e o resto para teste, com parâmetros regularização (C - *regularization parameter*) e γ (γ - *kernel function parameter*) ajustados em 10000 e 0,01 respectivamente. Nos testes realizados com simulação, o método obteve 94,9% de precisão, 90% de confiabilidade, 90,9% de garantia e 0,9 ciclos para detecção.

Uma abordagem combinando filtro de Kalman estendido e SVM é apresentada

no artigo (SAMANTARAY, S. R.; DASH, 2010). Com o filtro de Kalman são extraídas as componentes fundamental, 3^a, 5^a, 7^a, 11^a e 13^a harmônicas da corrente elétrica. A magnitude e fase desses componentes totalizam 12 entradas para a classificação da SVM com *kernel* gaussiano. Foram realizadas 500 simulações em *software* MatLab/Simulink para um sistema em anel e outro radial operando com tensão de 25 kV e 60 Hz de frequência, com taxa de amostragem de 960 Hz, para eventos como chaveamentos de carga monofásica e trifásica, energização de transformadores e capacitores. Desse conjunto de dados, 300 simulações foram utilizadas no treinamento da SVM e 200 para verificação de seu desempenho. Os autores não fizeram um estudo comparativo para o classificador SVM, nos testes realizado obtiveram 99% de precisão, 98% de confiabilidade e 100% de garantia.

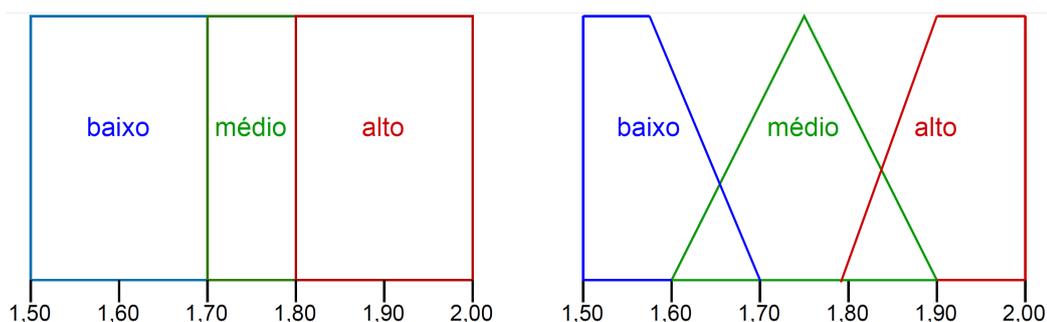
Em (SARLAK, M.; SHAHRTASH, S. M., 2008) foi utilizada TW (db3) para extração de características da corrente com frequência de até 6,25 kHz. O cálculo da energia do coeficiente de detalhe e aproximação da TW resultam em 36 características. A seleção das melhores características para treinamento do classificador SVM é feita por análise de PCA e análise linear discriminante (*Linear Discriminant Analysis* (LDA)). Simulações foram realizadas para o sistema teste IEEE *Four Node Test Feeder*, composto por dois segmentos de linha com um banco de transformador trifásico entre eles e as medidas adquiridas com uma taxa de amostragem da corrente de 12,5 kHz. Foi realizado um estudo comparativo com outros classificadores, sendo a precisão do SVM superior aos classificadores *naive Bayes* e Parzen no espaço de características originais e reduzido por PCA. O desempenho do classificador SVM foi um pouco inferior a RNA com o uso das características originais, porém, com a redução LDA o SVM não é melhor que os outros classificadores. O único critério estatístico de avaliação do método indicou um desempenho de 97,5% de precisão.

Por último, o artigo (ESLAMI *et al.*, 2021) traz diferentes cenários para extração de dados de treinamento, levando em consideração três unidades de medição incorporadas em uma MR de 25 kV com GD. Os dados coletados geram 27 características que são a magnitude do primeiro, segundo, terceiro, quarto, quinto e sétimo harmônicos, a fase do terceiro harmônico, o valor RMS e o valor THD do sinal de corrente. Utilizando os métodos de Coeficiente de Correlação de Pearson (PCC) e a PCA essas características são processadas e reduzidas a duas. Em seguida, os dados processados são classificados utilizando o método SVM com o *kernel* mais apropriado. O método PCC-SVM demonstrou uma precisão promissora de 99,02% na identificação de FAI, entretanto, o método requer um esforço computacional considerável devido às etapas de processamento do enorme volume dos dados de entrada.

2.3.4 Lógica *Fuzzy* (LF)

LF é a forma de lógica em que um atributo pode assumir qualquer valor entre 0 e 1, diferentemente da lógica booleana na qual os valores lógicos podem ser apenas 0 ou 1. Na teoria clássica de conjuntos, a pertinência de um dado elemento determina se ele pertence ou não a um conjunto. O gráfico apresentado do lado esquerdo da Figura 19 representa um exemplo típico da teoria clássica e descreve a altura de uma pessoa com três conjuntos: baixo, médio e alto. Nesse exemplo, dado um elemento x qualquer, o mesmo pertencerá a um dos conjuntos do gráfico; por exemplo, se $x = 1,65$, então x pertence ao conjunto médio e não aos demais, ou seja, um elemento pertence ou não a um determinado conjunto e, além disso, tal elemento não pertence a mais de um conjunto.

Figura 19 – Classificação da altura pela lógica convencional (esq.) e da lógica *Fuzzy* (dir.).



Fonte: Adaptado de (MARRO *et al.*, 2010)

Desta forma, na LF existe o conceito de que entradas podem ser classificadas com graus de pertinências, modelando assim uma lógica mais próxima ao senso comum do ser humano. Então a LF pode ser considerada como um conjunto de princípios matemáticos para a representação do conhecimento baseado no grau de pertinência dos termos (graus de verdade), ou seja, um elemento pertence a um conjunto com um certo grau de pertinência, fazendo com que uma determinada sentença possa ser parcialmente verdadeira e parcialmente falsa.

Um sistema de LF pode ser visto como um mapeamento não linear a partir do espaço de entrada para o espaço de saída e executa as seguintes etapas:

- **Fuzzificação:** mapeamento das entradas e saídas em conjuntos *Fuzzy*, definido a quantidade de conjuntos para cada variável, as funções de pertinência e os seus intervalos.
- **Inferência:** transforma um conjunto *Fuzzy* de entradas e um conjunto *Fuzzy* de saída por meio das regras definidas e mecanismos de inferência (avaliação das

regras e agregação dos resultados de todas as regras).

- **Desfuzzificação:** determina uma saída numérica a partir de um conjunto *Fuzzy*, ou seja, é a operação inversa àquela feita inicialmente. O método desfuzzificação deve ser adequadamente escolhido pois ele implica em perdas de informação. São eles o método do centro de gravidade, média dos máximos, maior dos máximos, menor dos máximos entre outros.

Em (JOTA, F.; JOTA, P., 1998) é apresentada uma metodologia com uso de LF para identificação de FAI em alimentadores com medidas de ondas viajantes. Essas ondas são periodicamente injetadas no alimentador e a reflexão dessas ondas é mensurada e processada. Um classificador faz uso da LF com 81 regras para classificar a variável desvio em pequeno, médio e grande. A metodologia foi aplicada em um alimentador na cidade de Caratinga-MG pertencente a distribuidora CEMIG. Nos testes realizados foi obtida uma taxa de 95,6% de confiabilidade, porém, quando a FAI ocorre muito próxima a uma seccionadora apenas 42% das FAI foram corretamente detectadas. No ano seguinte, os mesmos autores apresentaram outro artigo com a metodologia mais amadurecida (JOTA, P. R.; JOTA, F. G., 1999). Neste artigo, o classificador consistem uma RNA com neurônios 'neo-Fuzzy' treinados para reconhecimento de padrões das mesmas ondas viajantes do primeiro artigo. Cada um desses neurônios é treinado para uma configuração de rede específica, sendo a quantidade de neurônios igual ao número de configurações possíveis que são 11. Este novo classificador obteve 81% de confiabilidade comparado a 42% do anterior quando a FAI ocorre muito próxima a uma seccionadora. Nos dois trabalhos, as medições das ondas viajantes foram realizadas com o alimentador desligado (sem a presença de tensão de Corrente Alternada (CA)).

Para detecção de FAI em SDE uma abordagem com o uso de TW discreta combinada com função de aproximação *Fuzzy* foi proposta em (BANEJAD; IJADI, 2014). As características de detecção foram obtidas das medidas de tensão, corrente e soma da tensão trifásica das quais foram calculados 7 níveis de detalhes para 17 wavelets mãe diferentes. Para cada nível de detalhe de cada wavelet, foi calculada a soma absoluta dos coeficientes de detalhe SAD, originando as duas características utilizadas no treinamento do classificador: média do SAD e variância do SAD, que resultaram em níveis de precisão distintos. Para o treinamento da função de aproximação *Fuzzy*, foram considerados 80 pares entradas-saídas para treino e 20 pares entradas-saídas para testes. Nos testes a melhor precisão (94,19%) foi obtida com o uso da medida soma da tensão trifásica, wavelet mãe 'Demy' com o 6º nível de detalhe.

Em (AZIZ *et al.*, 2012) é apresentado um método para detecção, classificação e localização de FAI em SDE com a utilização de sistema de inferência neuro-Fuzzy adaptável (ANFIS - *Adaptive Neuro-Fuzzy Inference Models*). Os ANFISs representam

uma abordagem de RNA para estruturar um sistema de inferência com LF. O sistema teste é composto por um alimentador radial 13,8 kV de 33 km, com 3 cargas espaçadas igualmente e conectadas usando transformadores ideais. Foram implementados três ANFIS diferentes para de acordo com a tarefa a ser realizada: detecção, classificação e localização. Com as medidas de corrente trifásica são calculadas as componentes de 3ª harmônica (magnitudes e ângulos) que são entradas do ANFIS de detecção que calcula o índice de FAI. Caso o limite seja atingido, é ativado o modo de classificação que processa o tipo de FAI. Finalmente o ANFIS de localização é ativado calculando a distância da falta a partir do início do alimentador. As entradas testadas foram: componentes fundamentais (magnitudes e ângulos) das correntes trifásicas (seis entradas); magnitudes fundamental e 3ª harmônica de correntes trifásicas (seis entradas); componente 3ª harmônica (magnitudes e ângulos) de correntes trifásicas (seis entradas). Observou-se que a magnitude e ângulo da 3ª harmônica de corrente apresentaram o melhor desempenho para detecção e localização de FAI. A componente fundamental (magnitude e ângulo) de corrente tem um papel essencial para tarefa de classificação.

ANFIS também foi proposto por (ETEMADI; SANAYE-PASAND, 2008) associado com TW para detecção de FAI em SDE. O ANFIS combina duas regras de aprendizagem, a retropropagação e mínimos quadrados lineares, obtendo um algoritmo de aprendizagem híbrido aprimorando a busca por parâmetros ótimos. O sistema teste é composto de um alimentador de 20 kV com 20 km, que alimenta uma carga linear e uma não-linear na sua extremidade final, foi implementado no *software* PSCAD. Foram utilizados 400 casos para treinamento do algoritmo, cujas medidas de corrente tinham 4 kHz de taxa de amostragem. As características de entrada são os dois primeiros níveis de detalhes da TW (rbio3.3), a relação da amplitude da 3ª harmônica e a fundamental além a soma das amostras do sinal por um determinado período. Nos testes o método conseguiu 99,5% de precisão, 99% de confiabilidade, 99,8% de garantia e uma velocidade de 20 milissegundos.

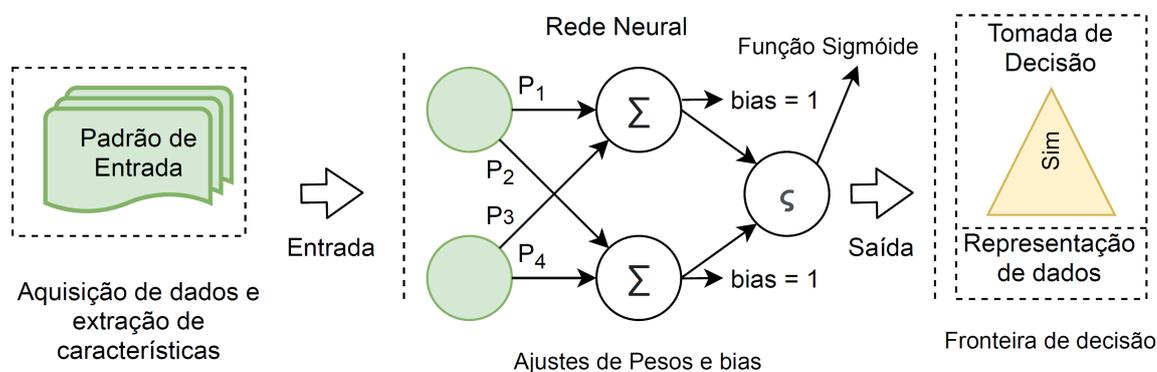
Em (TONELLI-NETO *et al.*, s.d.) foram comparadas duas metodologias baseadas em LF para diagnóstico de FAIs em alimentadores de distribuição de energia elétrica. O método associa a TW, a teoria da evidência de Dempster-Shafer, um esquema de votação, um sistema de inferência fuzzy e RNA. O sistema teste utilizado foi IEEE-123 *distribution feeder*, modelado no *software* EMTP-RV, que tem como característica um acentuado desequilíbrio de carregamento. Foram utilizadas 963 simulações de FAI, com uma frequência de amostragem de 15,36 kHz (256 amostras por ciclo), e coletadas as seguintes variáveis: o ângulo de inserção da falta (0°, 45° e 90°), a fase de incidência da falta (a, b e c), o barramento da falta e o comportamento da falta. Os resultados mostram que as metodologias são eficientes na detecção e classificação de faltas de alta impedância, oferecendo uma precisão de 99,02%.

2.3.5 Redes Neurais Artificiais (RNA)

As RNAs são modelos de dados estatísticos não lineares que emulam o funcionamento biológico do cérebro, que tem a capacidade de realizar aprendizado de máquina bem como TRP. Dentre esses modelos as redes neurais recorrentes, redes neurais convolucionais, rede *perceptron* multicamadas e camada única são os mais utilizados em TRP. Entretanto existem outros modelos melhorados que dependendo da aplicação podem apresentar melhor desempenho (ABIODUN *et al.*, 2019).

Na Figura 20 é apresentada a estrutura simplificada de uma RNA para reconhecimento de padrão e o fluxo das informações entre entrada e saída. Os neurônios de entrada (em verde) recebem os dados que são repassados para os neurônios da próxima camada, que são ponderados e transformados de acordo com uma função obtida por meio de treinamento. O treinamento da rede consiste em fornecer um conjunto de dados já classificados e, assim, são estabelecidos pesos para cada sinal bem como o *bias*, que é um parâmetro de relaxamento para adaptação da rede as entradas fornecidas. Então, após os dados percorrerem os neurônios/camadas da rede, é tomada a decisão, determinando se a entrada é compatível com o padrão estabelecido durante o treinamento.

Figura 20 – Fluxo de dados em RNA com TRP.



Fonte: Adaptado de (ABIODUN *et al.*, 2019)

Sarлак e SM Shahrtash (2011a) apresentam uma técnica para detecção de FAI que combina o resultado da classificação de três RNA *perceptron* multicamadas. A decisão se a FAI ocorreu é obtida do método médio dos três classificadores. Esta abordagem utiliza o gradiente morfológico multi-resolução (*multi-resolution morphological gradient*), que fornece as características no domínio do tempo extraídas da corrente. Foram utilizadas medições reais de um SDE radial (alimentador no sudoeste de Teerã), sendo que cada uma das RNA foi treinada a partir do primeiro, segundo e terceiro semiciclos pós-distúrbio, separadamente. Nos testes realizados, o método obteve 97,3% de precisão, 98,3% de confiabilidade e 96,3% de garantia pra detecção de FAI em um

alimentador radial.

Em (KEYHANI *et al.*, 2001) dois tipos RNA *Feedforward* e *Perceptron* foram testadas para detecção de FAI em um SDE cuja relação SNR pode variar entre 0 e 14 db. O sinal de corrente elétrica é decomposto com a FFT em sub-bandas de frequência. Depois disso, é calculado o nível de energia de cada banda que alimentam o treino das RNA para distinguir entre FAI ou correntes de magnetização e *inrush* de transformadores. O desempenho obtido na detecção é 99,8% de precisão, 99,0% de confiabilidade, 100% de garantia e uma velocidade de 10 milissegundos. Entretanto, como apontam os próprios autores, não foram considerados transitórios de chaveamento ou cargas não lineares.

Um estudo utilizando filtro Kalman com RNA na detecção de FAI é apresentado em (SAMANTARAY, S.R. *et al.*, 2009). Nesta abordagem o filtro de Kalman é utilizado para estimar as componentes fundamental, 3^a, 5^a, 7^a, 9^a, 11^a e 13^a harmônicas de corrente que são utilizadas como características no treinamento de uma RNA probabilística e uma RNA *feedforward*. Os testes foram realizados empregando simulação no *software* MatLab/Simulink para um SDE radial e anel, operando com 25 kV e carga não linear com retificador de 6 impulsos. Segundo os autores, quando apenas cargas lineares são consideradas a detecção de FAI se torna mais fácil. Isto porque o conteúdo harmônicos na corrente é mais pronunciado sob FAI em comparação com eventos de chaveamento sob condição de carga linear. Os resultados mostraram que a RNA probabilística tem um tempo de treinamento e testes consideravelmente reduzido em relação à RNA *feedforward*, sendo assim mais adequada a função de proteção. Além disso, a RNA probabilística obteve uma taxa de acerto marginalmente melhor e quando adicionado relação SNR de 20 db os dois classificadores tiveram também uma pequena degradação no desempenho.

Em (SHARAF *et al.*, 1993) os autores apresentaram um método que utiliza as características no domínio da frequência da tensão e correntes, em conjunto com uma RNA *feedforward* para detecção de FAI em SDE. A FFT de um ciclo é aplicada nas tensões e correntes de sequência negativa e zero, assim como relação entre a componente zero e negativa (V_0/V_2 e I_0/I_2), obtendo-se as componentes de 2^a, 3^a e 5^a harmônicas. Essas características são utilizadas no treinamento da RNA *feedforward* com algoritmo de *backpropagation*, uma camada oculta e quinze neurônios. Os autores recomendam a utilização de uma lógica com contador para que o método não confunda FAI com outros eventos transitórios rápidos como chaveamentos de linhas e banco de capacitores. Uma abordagem semelhante foi utilizada mais recentemente em (EISSA *et al.*, 2006).

Em (ZADEH, 2005) as componentes de 2^a e 3^a harmônica da tensão ($V_r = V_a + V_b + V_c$), corrente ($I_r = I_a + I_b + I_c$) e impedância residuais ($Z_r = |V_r/I_r|$) são as características para detecção de FAI em um SDE operando com tensão de 20 kV e

50 Hz de frequência. A FNN multicamadas com 6 entradas e uma saída, com oito neurônios e 4 camadas ocultas é responsável pela classificação dos eventos. Nas camadas ocultas foi utilizada a função de ativação do tipo tan-sigmóide e para a camada de saída a função linear saturada. No treinamento foram comparados os algoritmos de *backpropagation* e *Marquardt-Levenberg* este último com melhores resultados. O autor implementou o algoritmo em um *hardware* (TMS320C25) da *Texas Instruments* para testes em diferentes sistemas e transitórios simulados em EMTDC. Os resultados mostraram que o método é confiável e que é possível embarcar algoritmos baseados em RNA na nova geração de relés de proteção de alta velocidade.

Gu *et al.* (2021) desenvolveram um método com TW para extração de atributos dos sinais de FAI que são classificados por uma RNA. Este modelo foi embarcado em um dispositivo já existe no alimentador como forma de atualizar e aprimorar o seu desempenho. O equipamento, chamado de *feeder terminal unit*, possui um sensor de corrente de alta frequência e um processador de sinais digitais embarcado. Os resultados para 200 FAI ensaiadas na subestação de Tai-Xi, sob várias condições, ficou demonstrada a eficácia e viabilidade de implementação da proposta.

2.3.6 Aprendizagem Profunda (AP)

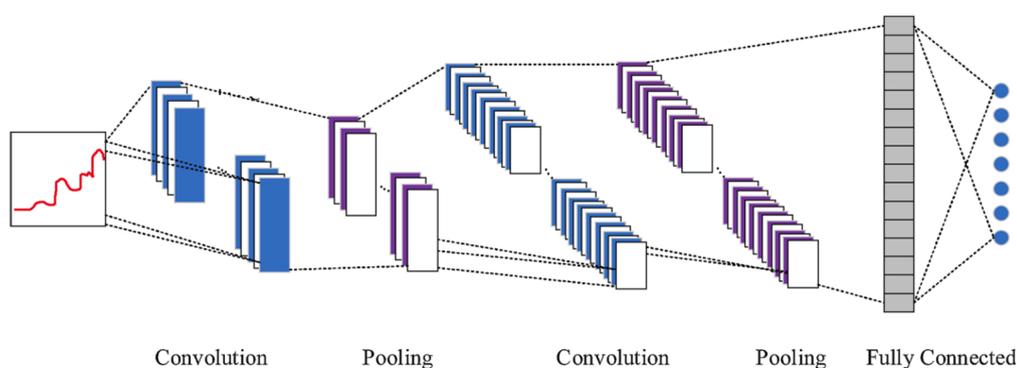
As RNA são técnicas de aprendizagem de máquina muito popular no desenvolvimento de métodos de detecção de FAI, com aproximadamente 23% do total, devido a sua alta precisão como classificador, generalização de padrões e rápida resposta com capacidade de isolar ruídos (GHADERI, Amin *et al.*, 2017). Além disso, se trata de uma técnica já amadurecida que já era proposta para essa função no início da década de 1990 (SULTAN, A. F. *et al.*, 1992). Mas isso não significa que é uma ferramenta defasada e que tenha parado no tempo. Essas técnicas de aprendizagem de máquinas tem evoluído com o surgimento de algoritmos mais rápidos e precisos, tais como Redes Neurais Profundas (RNP), RNC e Redes Neurais Recorrentes (RNR). Esses são métodos que permitirão relés digitais mais rápidos e confiáveis em um futuro próximo (LEI; SUI, 2019).

Esse tipo de aprendizagem profunda surgiu como uma nova classe de algoritmos para aprendizagem de máquinas, que representam dados de sistemas de energia por meio de um grande espaço de hipóteses, sendo o estado da arte em desempenho se comparado aos algoritmos orientados por dados (*data-driven*) mais recentes (MOHAMMADNIAN *et al.*, 2019; KAVOUSI-FARD *et al.*, 2021). Devido a sua alta capacidade de generalização, estes modelos são amplamente aplicados à avaliação da estabilidade, detecção de faltas, bem como previsão de geração de fontes renovável (KHODAYAR *et al.*, 2021).

Os modelos são treinados com uma grande quantidade de dados, e durante o treinamento ele aprende a ajustar seus parâmetros para minimizar o erro de classifi-

cação. Uma vez treinado, o modelo pode ser usado para fazer classificação em novos dados. Essa técnica é chamada de "profunda" porque envolve uma série de camadas intermediárias (também chamadas de camadas ocultas) entre a entrada e a saída do modelo, o que a distingue de redes neurais rasas com apenas uma ou duas camadas intermediárias (LECUN *et al.*, 2015). Estas camadas realizam operações que alteram os dados com o objetivo de aprender características específicas dos dados, que podem ser observadas na Figura 21.

Figura 21 – Arquitetura de uma RNC unidimensional com filtros de diferentes resoluções.



Fonte: (YANG, H. *et al.*, 2021)

As camadas mais comuns são a *Convolution*, *ReLU*, *Pooling*, *Flatten*, *Fully connected* e *Softmax*. Estas camadas são frequentemente utilizadas em conjunto em RNC para classificação de imagens (LECUN *et al.*, 2015), e são descritas a seguir:

- *Convolution*: faz passar as imagens de entrada por um conjunto de filtros convolucionais, cada um dos quais ativa determinadas características das imagens. Esses filtros deslizam sobre a imagem e calculando o produto escalar do filtro com a imagem em cada localização, retornando um mapa de características em cada localização da imagem.
- *ReLU*: é uma camada de ativação que utiliza a função de unidade linear retificada (*Rectified linear unit*), que permite um treinamento mais rápido e eficaz, mapeando os valores negativos para zero e mantendo os valores positivos. Assim, apenas as características ativadas são transportadas para a camada seguinte. Essa função introduz a não linearidade na rede neural, que permitindo a aprender relações mais complexas entre os dados de entrada.
- *Pooling*: simplifica a saída reduzindo as dimensões espaciais de um mapa de características. Uma janela desliza sobre o mapa de características e tomando

o valor máximo ou médio da janela em cada localização. O resultado de uma camada de *Pooling* é um mapa de características de dimensão reduzida.

- *Flatten*: essa camada achata um mapa de características multidimensional num único vetor. Isto é frequentemente feito antes da camada totalmente ligada final da RNC, uma vez que as camadas totalmente ligadas (*Fully connected*) esperam que a sua entrada seja um único vetor.
- *Fully connected*: é uma camada totalmente ligada em que cada nó está ligado a todos os nós da camada anterior. Este tipo de camada é frequentemente utilizado como camada de saída, permitindo a aprendizagem das relações complexas entre todas as características de entrada.
- *Softmax*: é uma camada de ativação cuja função recebe um vetor de entradas e produz um vetor de probabilidades. As probabilidades representam a probabilidade de a entrada pertencer a cada uma das classes possíveis de saída.

Sirojan *et al.* (2022) propôs um método para detecção de FAI, embarcado em dispositivos do tipo *edge devices* instalados aos logo do SDE, com a classificação por aprendizagem profunda. Um transformador de corrente tradicional foi utilizado para coletar o sinal de corrente a uma taxa de 20 kHz, permitindo a análise de componentes de alta frequência. Após a aquisição do sinal, um pré-processamento é realizado, incluindo a aplicação de FFT de curto período. A técnica foi validada, em laboratório, para uma sistema radial composto por: uma fonte CA de 5,55 kVA, um transformador 240 V - 11 kV, uma barra de alumínio nu com 7,5 mm de diâmetro, uma resistência limitadora de corrente de 6,25 k Ω para proteção do transformador. As FAI foram geradas encostando objetos no condutor de alumínio, a tensão aplicada variou de 2 kV à 8 kV com a corrente de FAI de 0,01 A à 0,2 A. A técnica demonstrou a capacidade de detectar FAI em tempo real com baixa latência (115,2 ms) e alta precisão (98,67%). Entretanto é preciso ponderar que o sistema teste não representa um SDE em toda sua complexidade, desconsiderando a presença de cargas não lineares e fontes do tipo VSC.

O estudo apresentado em (LAVANYA *et al.*, 2022) traz o uso de uma RNC profunda de seis camadas para classificar FAI em SDE. Os dados de treinamento consistem em um total de 10.400 amostras em um sistema radial de 11 kV - 50 Hz, com seis pontos de medição de corrente e um modelo de FAI proposto por (SEDIGHI, A. R.; HAGHIFAM, 2010) e analisado em detalhes na seção 4.3.3. As simulações incluindo sinais com e sem FAI, bem como condições como chaveamento de cargas lineares e não lineares e banco de capacitores. Foram adicionados níveis de ruído ao conjunto de dados, variando de 20 dB a 40 dB, para refletir distorções reais aos sinais coletados por sensores. O modelo RNC profunda de seis camadas demonstrou alta

precisão, atingindo 100% de precisão, em comparação com modelos de quatro e oito camadas que alcançaram 98,66% e 99,6% de precisão, respectivamente. O modelo de seis camadas também se destacou em ambientes ruidosos e reduziu o atraso de detecção para 23,66 ms, tornando-o adequado para aplicações em tempo real.

Em (SHIHABUDHEEN *et al.*, 2019) para treinar o modelo de Aprendizagem Profunda (AP) foram utilizados o sistema teste IEEE-9 Barras e o modelo de (EMANUEL *et al.*, 1990). A detecção de FAI é realizada por meio das características extraídas do sinal de tensão via TW e classificação com a técnica de AP chamada *Long short-term memory* (LSTM). O sistema é dividido em três zonas de monitoramento para facilitar a localização da falta. Neste estudo a base de dados foi composto por 900 amostras de FAI e 948 de não FAI de simulações com 0,5 segundos de duração. Esses dados foram submetidos à TW e a energia do coeficiente de detalhe é usada como entrada para as técnicas de classificação SVM e LSTM, resultando em uma precisão de 71,85% e 92,59% respectivamente.

As LSTM é sua capacidade de lidar com séries temporais, mantendo informações de longo prazo e superando o problema de perda de gradiente (*Vanishing Gradient Problem*) que afeta as RNR tradicionais, sendo amplamente utilizada para previsão de demanda e da geração de energia eólica e solar (NAZARI-HERIS *et al.*, 2021). Porém, essa capacidade de lidar com dependências de longo prazo em sequências temporais resulta em complexidade computacional, limitando o seu uso em dispositivos com recursos limitados como relés de proteção (IBRAHIM *et al.*, 2020).

O trabalho de Rai *et al.* (2021) propôs uma abordagem que combina TW AP e para a detecção e classificação de FAI em SDE. Os banco de dados utilizado é composto por 210 simulações de FAI, obtidas por meio de simulação *software* PSCAD com sistema teste IEEE-13 *Node Test Feeder* de 4,16 kV e um modelo de FAI adaptado de (EMANUEL *et al.*, 1990). A classificação é realizada usando Autoencoder Convolutivo (CAE) que necessita de treinamento apenas para os sinais de tensão e corrente de FAI, eliminando a necessidade de diversos cenários não FAI. O CAE distingue as HIFs das condições de funcionamento não HIF empregando a correlação cruzada. Para distinguir as FAIs de outros transitórios utiliza a curtose, uma medida estatística relacionada a forma de onda. O método obteve 100% nas métricas de performance analisadas, que foram: precisão, segurança, confiabilidade, segurança e sensibilidade.

A detecção em tempo real de FAI é testada em laboratório e apresentada em (SIROJAN *et al.*, 2022), com o uso de *edge devices* montados no topo de postes de distribuição processando algoritmos baseados em aprendizagem profunda. Os processos de aquisição de dados, extração de características e detecção de falta, são realizados nesses dispositivos diminuindo a latência e o tráfego de dados. Este método utiliza imagens bidimensionais produzidas pela FFT de tempo curto como dados de entrada de uma RNC. Nos testes realizados foi possível detectar FAI com uma latência

inferior (115,2 ms) e uma precisão 98,67%.

2.3.7 Análise Comparativa entre as Técnicas de Reconhecimento de Padrões.

De uma forma geral e resumida na Tabela 3 são apresentadas algumas das principais as vantagens e desvantagens dos classificadores investigados para detecção de FAI.

Tabela 3 – Comparação entre Técnicas de Inteligência Artificial (GURURAJAPATHY *et al.*, 2017).

Técnica	Vantagens	Desvantagens
Árvore de Decisão (AD)	Simplicidade de interpretação e combinável com outros classificadores.	Sensível a pequenas mudanças nos dados, que podem afetar sua estrutura. Tendência a criar ramos mais profundos com atributos adicionais.
Algoritmo Genético (AG)	Melhora a velocidade de simulação e reduz a dimensão de soluções possíveis.	Resultados de localização de falhas inconsistentes devido à aleatoriedade.
Support Vector Machine(SVM)	Rápido e eficaz, mesmo em problemas complexos. Limites superiores no erro de generalização não dependem da dimensionalidade.	Escolha da função <i>kernel</i> e parâmetros crítica para o desempenho.
Lógica <i>Fuzzy</i> (LF)	Lida com incerteza e modela relacionamentos de entrada/saída por meio de regras.	Dificuldade em determinar o mínimo global usando funções de associação <i>Fuzzy</i> . Requer aprimoramento na extração de recursos.
Redes Neurais Artificiais (RNA)	Simplicidade na implementação. Realiza relações não lineares.	Desempenho depende da qualidade dos dados de treinamento. Treinamento com lenta convergência. Requer ajuste de parâmetros por tentativa e erro.
Aprendizagem Profunda (AP)	Aprende representações hierárquicas e automáticas dos dados. Usado em diversas aplicações, como visão computacional e processamento de linguagem natural.	Requer grandes volumes de dados de treinamento e recursos computacionais significativos.

Fonte: Adaptado de (GURURAJAPATHY *et al.*, 2017)

Foi observado que os métodos de detecção de FAI utilizando técnicas de inteligência artificial para reconhecimento de padrões são mais complexos e demandam mais tempo de processamento em relação a métodos convencionais. Entretanto, para SDE maiores os métodos convencionais se tornam imprecisos. A adequação do método vai depender da complexidade da rede e da disponibilidade de dispositivos de medição.

Portanto, não existe uma categorização que aponte o melhor ou o pior método, sendo necessária uma avaliação da aplicação desejada. Além disso, métodos que usam dados para aprender padrões e fazer previsões são muito dependentes da qualidade, quantidade e precisão dos dados utilizados para treinamento do algoritmo classificador. Esta questão é especialmente importante para detecção de FAI, devido

as suas características singulares e a imensa maioria das técnicas utilizarem dados de simulação.

3 MICRORREDES

Um SEP é planejado e construído de forma a alocar as usinas perto de grandes fontes de energia. Esta energia, já convertida em eletricidade, é transportada em linhas de transmissão até os centros consumidores. Entretanto, pesquisas e estudos propõem mudanças nesse modelo.

Com a crescente preocupação com a emissão de gases de efeito estufa, fim das atuais reservas de combustíveis fósseis até 2050 (SHAFIEE; TOPAL, 2009), as fontes de energia estão no centro das atenções. Nesse contexto, Agência Internacional de Energia (AIE) publicou um relatório que traça o caminho para o setor de energia global alcançar emissões líquidas zero de gases de efeito estufa até 2050 (BOUCKAERT *et al.*, 2021). Este relatório traz um plano para reduzir pela metade até 2030 e atingirem zero líquido até 2050, como forma de impedir aumento global de temperatura de 2,7 graus Celsius até o final do século.

Se trata de uma meta ambiciosa, que deve custar cerca de US\$ 5 trilhões por ano em investimentos. Para alcançar esse objetivo, O relatório destaca uma série de ações importantes que precisam ser tomada:

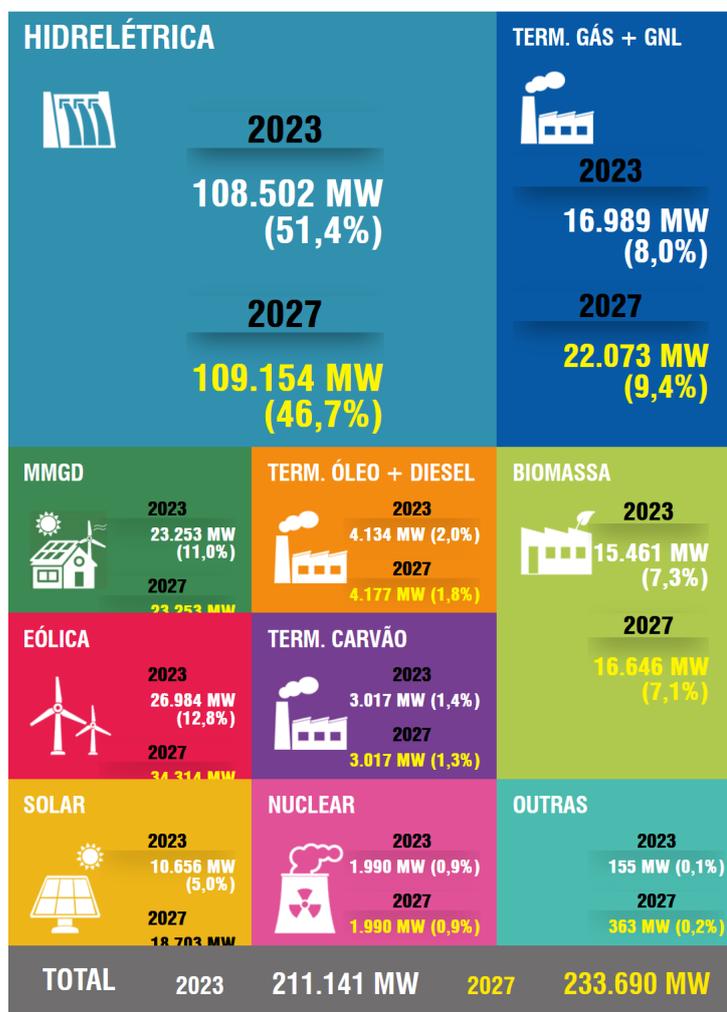
- Uma transição rápida para a geração de energia limpa, com fontes de energia renovável, como energia solar e eólica, se tornando a principal fonte de energia até 2050.
- Uma eletrificação significativa do transporte e de outros setores da economia.
- Uma melhoria significativa na eficiência energética em todos os setores.
- O uso de tecnologias de captura, utilização e armazenamento de carbono para capturar e armazenar emissões de dióxido de carbono de processos industriais e usinas de energia.

No relatório de perspectivas energéticas mundiais (IEA, 2022), divulgado pela AIE, é previsto um aumento global na demanda por energia elétrica entre 5 900 TWh e até 7 000 TWh para o ano de 2030. Este aumento é equivalente a dobrar o consumo nos Estados Unidos e na União Europeia. Para o ano de 2050, a demanda global de eletricidade deve ser 75% maior, no cenário de políticas energéticas atuais, e 150% maior com a adoção de políticas de emissão zero.

O setor elétrico brasileiro se destaca globalmente devido à abundância de recursos naturais exploráveis e à vasta extensão territorial do país. Cerca de 82% da capacidade de geração de energia elétrica em 2018 provém de fontes renováveis, tornando a matriz energética majoritariamente sustentável (PESQUISA ENERGÉTICA, 2018). Além disso, o Brasil possui uma das maiores redes de transmissão do mundo, com 179.311 km instalados em 2023 e projeção de 216.759 km em 2027. Em termos

de geração, a expansão prevista vai de 211.141 MW em outubro de 2023 para 233.690 MW, como pode ser visto na Figura 22.

Figura 22 – Projeção da Capacidade instalada no Sistema Interligado Nacional.



Fonte: Adaptado de (SISTEMA ELÉTRICO, 2023).

No Brasil a maior parte do potencial hidráulico já está sendo explorado, restando a possibilidade de Pequena Central Hidrelétrica (PCH)s e os rios na região norte cujo relevo predominante de planície inviabiliza grandes represas. Também, associam-se os grandes impactos sociais e ambientais decorrentes da construção de usinas hidrelétricas. Esses fatores explicam a projeção da diminuição de 51,4% para 46,7% da participação desse tipo de fonte na matriz nacional, apresentado na Figura 22. Assim, fontes alternativas de energia e a GD se mostram uma alternativa natural para o atendimento do contínuo aumento de demanda por energia elétrica (LASSETER, R. H., 2002).

Além disso, do ponto de vista técnico, esse *status quo* dos SEP apresenta desafios para os operadores devido ao seu tamanho e complexidade. Pode ser considerada

a máquina mais complexa já construída, pois a sua operação exige o equilíbrio entre geração e carga em tempo real. Devido ao seu tamanho e interdependência, uma falha pode causar um efeito em cascata, levando a interrupções no fornecimento de energia e impactos negativos, como perda de produção e receita em indústrias. Além disso, é necessário equilibrar a confiabilidade do sistema com os custos operacionais (HEMAPALA; PERERA, 2022).

A GD pode ser integrada ao SDE para atender às cargas próximas, por meio de sistemas de energia solar fotovoltaica, turbinas eólicas, geradores a diesel e baterias de backup. Para converter a saída dessas fontes de energia renovável em eletricidade utilizável, dispositivos eletrônicos de potência, como inversores, são empregados como interfaces para melhorar o controle das fontes de energia renovável e garantir a qualidade da energia (SHUAI, 2021).

A tendência de mudança no modelo de sistema elétrico baseado em geração centralizada em larga escala, com transmissão e distribuição com fluxo unidirecional não é algo novo. Esse novo modelo descentralizado, capaz de integrar a GD já foi proposto por Ackermann *et al.* (2001), e vem sendo estudado, aprimorado e adotado gradativamente ao longo dos anos.

O novo modelo incorporara as fontes de energias renováveis, GD em pequena escala, fluxos de potência bidirecionais e consumidores conectados ao sistema tendo um papel mais participativo, podendo consumir e fornecer energia. Para este novo modelo, as MR se tornam uma solução muito atrativa, pois conseguem incorporar as novas tecnologias no atual sistema, aumentando a qualidade e confiabilidade do suprimento de energia (HEMAPALA; PERERA, 2022).

As MR não devem ser confundidas com sistemas miniaturizados ou isolados, seu grande diferencial é a possibilidade de operar de forma isolada ao sistema elétrico de forma autossuficiente. O conceito de MR diz que se trata de um grupo de cargas e GD que podem operar isoladamente ou conectas ao SDE, com fronteiras bem determinadas, um controlador para o gerenciamento e operação, além de um ponto de conexão com a rede principal, denominado *Point of Common Coupling* (PCC) (BEHESHTAEIN *et al.*, 2019).

Esse novo paradigma traz consigo as seguintes vantagens: (i) aumento da confiabilidade e qualidade de energia, (ii) unidades geradoras de menor porte mais rápidas e baratas de serem implantadas como alternativa para expansão da rede elétrica, (iii) capacidade de limitação de pico de demanda (*peak shaving*), (iv) armazenamento de energia (v) inserção de fontes não convencionais. Por outro lado, existem desafios tecnológicos a serem vencidos como por exemplo: regulação da tensão, presença de distorções harmônicas, aumento e dificuldade de determinação da corrente de curto-circuito, fluxos de potências bidirecionais e necessidade de estudos do comportamento dinâmico das redes de distribuição (FAHIMI *et al.*, 2011; ZHENG *et al.*, 2021).

Para superar esses desafios para implantação de MR é necessário, uma nova infraestrutura de proteção e controle, mais flexível, reconfigurável e com capacidade de trocar informações em alta velocidade (FAHIMI *et al.*, 2011).

O controle e proteção de uma MR não devem ser encarados como um SDE convencional com adição de unidades geradoras locais, pois é preciso adaptá-los para operação no modo conectado ou ilhado. A MR deve ter capacidade instalada para suprir toda suas cargas ou pelo menos as mais críticas. Desta forma, se há um distúrbio na rede principal a MR é desconectada a partir do PCC. A MR volta ser conectada ao resto do sistema assim que o problema é eliminado. Determinar o momento específico do ilhamento de acordo com o tipo de contingência e o esquema de proteção adequadamente coordenado nesse modo de operação é um dos desafios na implantação de MR (PARHIZI, S. *et al.*, 2015; SHUAI, 2021).

Ainda segundo (CHOWDHURY; CROSSLEY, 2009; BEHESHTAEIN *et al.*, 2019), MR com a presença de GD conectados à rede por meio de dispositivos de eletrônica de potência, necessitam de uma proteção com requisitos diferentes dos encontrados na rede de distribuição. Isto se deve ao fato de que os conversores de frequência têm características relevantes para proteção, que podem variar significativamente dependendo do projeto e aplicação, assim não é possível obter um modelo que represente-os como uma classe homogênea de equipamentos.

Para a consolidação definitiva das MRs é ainda necessário o amadurecimento de várias técnicas e desenvolvimento de novas tecnologias. Muitos pesquisadores estão concentrando esforços em muitas questões técnicas da MR, como a qualidade da energia, gerenciamento de energia, controle da rede, sistemas de comunicação e proteção. Dentre todos eles, a proteção da MR é um dos desafios mais críticos de ser superado (PARHIZI, S. *et al.*, 2015).

3.1 DESENVOLVIMENTO E PERSPECTIVAS FUTURAS

Segundo McCullough (2020) as MR se tornam o último estágio da história social da eletrificação. A próxima melhor coisa depois de ter eletricidade em sua casa é ter eletricidade quando a maior parte da cidade não tem. Além disso, este autor adota uma abordagem experiencial e evita os clichês e idealismos comuns associados às cidades inteligentes e tecnologia. Em vez disso, ele oferece um novo contexto cultural para esse tópico, afastando-se do futurismo, jargões ecológicos e teorias críticas, proporcionando uma perspectiva diferente sobre ciência e tecnologia.

No livro (MCCULLOUGH, 2020) são descritas as três eras da eletrificação na América do Norte: inovação, consolidação e descentralização. Ele considera o boom das MR e sua relevância para o ambiente construído como "a borda da rede da arquitetura", ponderando que infraestruturas críticas devem considerar a sua adoção desde a sua concepção. Isto mostra que as MR deixaram de ser um assunto tratado apenas

por pesquisadores e empresas envolvidas diretamente com o SEP, entrando em um contexto mais amplo de planejamento futuro.

Nos últimos anos, os custos de geração de energia renovável caíram significativamente, tornando possível a geração de eletricidade em pequenas redes independentes da rede principal. Os custos de instalação de geração de energia renovável diminuíram substancialmente, com reduções notáveis nos custos desde 2010, como 89% para energia solar fotovoltaica, 69% para energia solar concentrada, 69% para energia eólica terrestre e 59% para energia eólica marítima. Além disso, o custo ponderado de eletricidade da energia eólica terrestre era 95% mais alto do que o custo mais baixo de combustíveis fósseis. Em 2022, esse custo para novos projetos de energia eólica terrestre estava 52% abaixo da solução de combustíveis fósseis mais barata (IRENA, 2023).

Então, as MR desempenham um papel de crescente relevância na infraestrutura energética, tornando possível que unidades de geração sejam alocadas mais próximas das áreas de demanda, viabilizando a operação autônoma garantindo confiabilidade de suprimento. Além disso, muitos pequenos sistemas isolados são alimentados por geradores a diesel, aplicação para a qual as MRs podem ter o maior impacto, com sistemas de energia renovável e baterias, tornando mais econômico a sua operação (ZHENG *et al.*, 2021).

As primeiras MR tinham um papel de demonstração de tecnologia, instaladas em universidades e centros de pesquisa. A primeira MR é a CERTS (*The Consortium for Electric Reliability Technology Solutions*), que foi iniciada em 1999 e liderada pelo Laboratório Nacional Lawrence Berkeley sob o Departamento de Energia dos EUA. Universidades, empresas de energia elétrica, fabricantes, institutos de pesquisa pública, etc., participaram deste projeto (LASSETER, R. *et al.*, 2002).

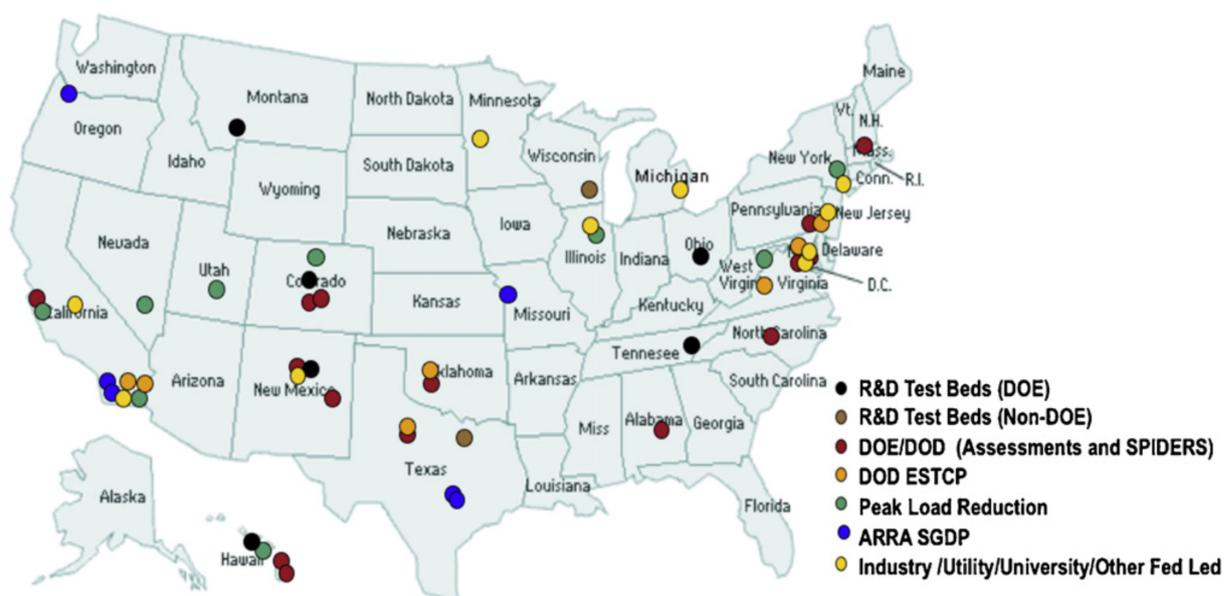
Existem diferentes motivação para adoção de MR no mundo, de acordo com as características do sistema de energia em cada região. Nos Estados Unidos, a confiabilidade do sistema de energia elétrica é uma questão importante. Na Europa os objetivos são expandir o uso de energia renovável e construir um sistema de energia independente em ilhas remotas. No Japão, o desastre ocorrido na Central Nuclear de Fukushima resultaram em maior investimento em GD de fonte renovável. Em países em desenvolvimento, por outro lado, as MR servem ao propósito básico de suprir áreas rurais não eletrificadas (IEA, 2022). Microrredes baseadas em energia renovável podem para contribuir significativamente para melhorar essa situação (ZHENG *et al.*, 2021).

Nos Estados Unidos o departamento de energia lançou o programa *The U.S. Department of Energy's Microgrid Initiative* de forma a dar direcionamento as pesquisas nessa área (TON; SMITH, M. A., 2012). Esta iniciativa se encontra dentro de um programa de Pesquisa e Desenvolvimento (P&D) maior, chamado *Smart Grid R&D*

Program, cujo objetivo final é acelerar a implantação e integração de comunicação, controle e tecnologias da informação que são necessário para modernizar a rede de distribuição elétrica. Este programa também estabelece objetivos desejados em relação ao custo, confiabilidade, eficiência energética e emissões para o novo SEP.

Há uma grande quantidade de projetos de MR que fazem parte desse programa, mostrados na Figura 23, cuja finalidade é identificar as lacunas de P&D e definir um plano para preenche-las. O Departamento de Energia identifica nas MR um bloco chave na construção de redes inteligentes e área focal chave para o seu desenvolvimento.

Figura 23 – MRs apoiadas pelo Departamento de Energia e Defesa Norte Americano.



Fonte: (TON; SMITH, M. A., 2012)

O *Office of Electricity* atualmente trabalha em um programa com nome de MGRD (textitMicrogrids R&D), com objetivos de melhoria da resiliência, descarbonização e redução de custos estabelecendo metas para os próximos 5 e 10 anos. Este programa contém diversas iniciativas para o aprimoramento da infraestrutura e operações, análises e ferramentas para promover a padronização de MR (POC *et al.*, 2021).

Na Europa também existem esforços no mesmo sentido, em (SANZ *et al.*, 2014) os autores fazem uma análise das políticas e incentivos para MR. Os europeus veem nas MRs uma oportunidade para cumprir as metas da Comissão Europeia de diminuição das emissões de gases de efeito estufa. Isto se dá pelo aumento de fontes renováveis de energia e melhorando a eficiência energética do SDE.

O arcabouço regulatório da União Europeia envolve as diretivas: (i) 2006/32/EC trata das metas para eficiência energética, (ii) 2009/28/EC que trata da inserção de fontes renováveis no sistema, (iii) 2004/8/EC regulamenta a autoprodução e arma-

zenamento de energia elétrica e (iv) 2009/72/EC que trata da conexão com a rede. Além disso, a política de incentivos fiscais para a implantação de energias renováveis tem sido tão efetiva que já se estuda uma redução para o mínimo necessário. Dando tempo para criar o ambiente adequado para essas fontes mas sem penalizar este mercado (COMMISSION *et al.*, 2013).

Mas o trabalho (SANZ *et al.*, 2014) apresenta a particularidade regulatória da União Europeia e seus países membros, uma vez que nem sempre há uma sintonia. Na Espanha, por exemplo, existem regulamentações que impedem o uso de MR como a proibição da operação ilhada, sistemas de armazenamento não podem ser utilizados com fontes renováveis e não existe regulamentação para conexão de sistemas de armazenamento no SDE.

No entanto, pode-se dizer que a maioria dos estados membros estão introduzindo novas regulamentações em conformidade com o implementação do conceito de MR. Visando assim atingir as metas para fontes renováveis na matriz energética, de 20% de participação em 2020 e 45% em 2030 (MUTH; SMITH, E., 2011). Em 2020, a UE atingiu uma quota de 22,1 % de energia proveniente de fontes renováveis no consumo final bruto de energia.

A participação das energias renováveis tem aumentado em média 0,8 pontos percentuais por ano desde 2011, mas houve um crescimento significativo de 2,2 pontos percentuais entre 2019 e 2020. No setor de eletricidade, as fontes de energia renovável contribuíram com 37,5% em 2020, apresentando um aumento notável de 2 pontos percentuais entre 2018 e 2019, e um aumento ainda maior de 3,4% entre 2019 e 2020 (SIKSNELYTE-BUTKIENE *et al.*, 2022).

Soares e Oliveira (2022) apresentam uma linha do tempo de legislações e incentivos às MRs no Brasil. Além disso, aponta como essas leis de incentivo determinaram a sua disseminação e crescimento no Brasil, e comparação a outras regiões do mundo.

Em (TENFEN *et al.*, 2013) os autores apresentam os aspectos regulatórios e de mercado para implantação de MR no Brasil. Nele são discutidos os Ambiente de Contratação Livre (ACL) e Ambiente de Contratação Regulado (ACR), bem como o incentivo a microgeração usando compensação de energia (*Net Metering*) e a simplificação para acessar redes de distribuição elétrica. A regulamentação da microgeração (de 1 à 100 kW) e a minigeração (de 101 à 1000 kW) de energia elétrica já existe, o que incentiva a sua instalação. Um problema que pode surgir é que as distribuidoras de energia tem a obrigação de contratar 100% da demanda. Entretanto, não há mecanismos para regradar o avanço da inserção de microgeração e minigeração podendo resultar em penalizações por sobre contratação.

A Universidade Federal de Santa Catarina teve um Laboratório de Microrredes Inteligentes, durante a execução de um projeto de Pesquisa e Desenvolvimento da ANEEL financiado pela empresa Engie Brasil Energia. Neste laboratório, existia uma

MR instalada com diversas fontes de energia distribuídas, carga, armazenamento e sistemas de controle centralizado e descentralizados. As fontes eram geração fotovoltaica com 20 kW pico, um emulador de geração eólica de 11 kW, emulador de micro turbina a gás de 30 kW e um banco de baterias de íon de lítio, totalizando uma capacidade de 11 kWh (ORTMAN *et al.*, 2015).

A tese de Bellido (2018) apresenta um estudo de viabilidade para implantação de uma MR no campus da Universidade Federal do Rio de Janeiro. Também discutida a viabilidade econômica das MR, que ainda são consideradas uma tecnologia não viável, uma vez que as várias tecnologias que a constituem, são custosas quando da não existência de algum mecanismo de apoio. No aspecto regulatório evidencia que as normas que tratam a respeito da integração GD com a rede, estas, não têm sido expressamente elaboradas para lidar com MR.

Assim, foi constatado que os próximos passos no aprimoramento de SDE do ponto de vista técnico será a expansão do uso MR. Com elas é possível aumentar a confiabilidade do suprimento, reduzir a emissão de gases de efeito estufa, viabilizar a custos acessíveis áreas remotas e atender a demanda futura com a integração de GD de fontes renováveis. Apesar dos obstáculos regulatórios e econômicos existentes no Brasil, temos que acompanhar essas tendências sob pena de nossa indústria ficar defasada nestas tecnologias. A implementação de MRs virá acompanhada de outras inovações para acomodar a GD, sistemas de armazenamento e modos de operação (conectada e ilhada) o que trará ótimas oportunidades para criação de novos produtos e soluções.

3.2 SISTEMAS DE PROTEÇÃO EM MICRORREDES (MR)

As MRs baseadas em GD necessitam de um sistema de proteção adequado, para manter um fornecimento de energia seguro, confiável e ininterrupto. Assim, a penetração e o controle de GDs representam um desafio vital para a proteção, bem como para o aspecto de estabilidade da MR. As fontes de renováveis, como a solar, a eólica, etc., são amplamente investigadas para resolver a crise energética e os problemas ambientais (SARANGI *et al.*, 2021).

De acordo com Shuai (2021), a energia produzida por fontes renováveis tem de ser transferida para o padrão utilizado na rede, assim dispositivos eletrônicos são como interfaces para melhorar o controle e garantir a qualidade da energia. Devido às vantagens desse dispositivos na conversão de energia, a utilização sua utilização aumentou drasticamente nos últimos anos. Isto representa um desafio significativo ao SDE tradicional, que são listados a seguir:

- Capacidade térmica limitada: dispositivos de eletrônica de potência, como IGBT, MOSFET, JFET, são como interruptores controlados que possibilitam a conversão

de energia. Porém, a seleção dos seus parâmetros devem levar em consideração o compromisso entre economia e confiabilidade ao mesmo tempo. Geralmente, esses dispositivos são escolhidos com o dobro do valor nominal, mas isso pode resultar em correntes de *inrush* elevadas durante o período transitório, ameaçando a segurança dos dispositivos. Mesmo com materiais como SiC e GaN, que possuem melhor capacidade de sobrecorrente, ainda persistem desafios na operação segura dos dispositivos eletrônicos de potência durante o período transitório.

- Não linearidade acentuada: dispositivos de eletrônica de potência realizam a conversão de energia controlando o estado dos interruptores (ligado ou desligado). Conforme o estado dos interruptores muda, a topologia do sistema também varia, tornando o sistema de potência eletrônica um sistema não linear e variável no tempo, o que dificulta a modelagem e análise do sistema. Além disso, unidades de limitação, como limitadores de corrente, podem transformar o sistema de controle em malha fechada em um sistema de malha aberta. Quando o inversor opera no modo de sobremodulação, o sistema pode se tornar um sistema de retroalimentação positiva, o que pode levar à instabilidade do sistema.
- Resposta dinâmica em múltiplas escalas de tempo: as MR podem realizar a conversão de energia de forma rápida e flexível, apresentando características de resposta dinâmica em uma ampla faixa de frequência em comparação com o sistema de potência tradicional. Em níveis de dispositivos eletrônicos de potência, os interruptores eletrônicos de potência respondem em uma faixa de tempo de microssegundos a minutos. Nos níveis de controle, as malhas de controle de tensão e corrente operam na faixa de milissegundos, enquanto o controle de potência responde em uma faixa de 100 milissegundos a segundos, e a otimização do controle do sistema geralmente ocorre em uma faixa de minutos.
- Baixa inércia: ao contrário dos geradores síncronos tradicionais, os dispositivos eletrônicos de potência não possuem unidades de rotação física, o que resulta em pouca inércia no sistema. Isso pode levar a oscilações e instabilidade do sistema em resposta a perturbações, como flutuações de carga e faltas à terra, devido à baixa inércia e capacidade de amortecimento.
- Suprimento intermitente de energia: as fontes de energia renovável, como energia solar e eólica, dependem de condições climáticas e ambientais imprevisíveis, tornando a saída de energia dos dispositivos eletrônicos intermitente em uma escala de tempo longa. Sistemas de armazenamento podem mitigar a oscilação da saída de energia, mas aumentam significativamente os custos do sistema.

Todas essas características demonstram a necessidade de soluções inovadoras que abordem desafios únicos das MR, incluindo a proteção dos SDE e MR em ambos os modos, conectado e ilhado, e na transição entre eles. Existem lacunas relacionadas à proteção de MR que não foram devidamente abordadas na literatura e normas atuais (VENKATA *et al.*, 2019). Existe um Grupo de Trabalho empenhado no desenvolvimento do guia para projeto de proteção de microrredes (*IEEE Draft Guide for the Design of Microgrid Protection Systems*), patrocinado pelo Comitê PE/PSRCC - *Power System Relaying and Control* (IEEE. . . , 2022).

Sarang *et al.* (2021) afirmam que a proteção de MR ainda precisa de desenvolvimento para ter aplicação prática, pois considera que a maioria das obras publicadas está em estágio conceitual ou inicial. No seu trabalho de mapeamento da literatura técnica sobre o tema trouxeram as seguintes constatações:

- Muitos dos trabalhos discutidos são propostas conceituais em vez de implementações práticas.
- A infraestrutura de rede e os canais de comunicação são fundamentais para um esquema de proteção CA adaptativa e inteligente. Para garantir sua utilização e cobrir todos os tipos possíveis de faltas, é necessário aprimoramento e melhorias que resultem em um proteção mais segura e confiável.
- As FAIs têm magnitudes de corrente semelhantes às cargas normais, portanto, um sistema de proteção robusto deve ser capaz de detectá-las. No entanto, esse problema é abordado por um número limitado de pesquisadores.
- A maioria dos algoritmos é adequada para sistemas radiais. Os sistemas em malha também devem ser considerados em ambos os modos de operação. Os parâmetros de desempenho, facilidade de implementação e restrições econômicas devem ser considerados levando em conta tanto as estruturas radiais quanto em malha.
- Todos os métodos descritos têm em comum a necessidade de um canal de comunicação confiável e robusto, em vez de um tipo de operação centralizada ou distribuída.
- Um sistema ótimo e robusto de proteção precisa de uma arquitetura híbrida de diferentes esquemas.
- Para tornar uma abordagem baseada em inteligência artificial mais eficiente, são necessários dados mais adequados para AP, algoritmos de mineração de dados e arquitetura de IoT.

Assim, fica demonstrada a grande oportunidade de desenvolvimento de estudos e pesquisas no desenvolvimento de técnicas de proteção de MR, pois é a direção que se apresenta para evolução dos SDE e existem vários desafios a serem superados pela inserção de GD baseada em fontes de energia renováveis.

3.3 DETECÇÃO DE FAI EM MR

Nesta secção são apresentados trabalhos existentes na literatura que, de alguma forma se assemelham ao trabalho proposto, e assim a esclarecer a contribuição pretendida com a Tese. As FAIs não são um problema novo em sistemas de distribuição, a literatura também traz diversos trabalhos com abordagens que se utilizam de inteligência computacional para a sua detecção. Entretanto, microrredes são um novo ambiente onde este tipo de falta irá ocorrer, novos desafios se apresentam devido à presença de GD conectada à rede por meio de dispositivos de eletrônica de potência.

O artigo apresentado em (WANG, X. *et al.*, 2019) utiliza VMD para a extração de características da corrente elétrica medida no início do alimentador a uma taxa de 20 amostras por ciclo. O método de detecção proposto foi testado empregando simulações implementadas no *software* MatLab/Simulink para diversos cenários. Foi utilizado o sistema teste IEEE-13 Barras modificado com adição de GD, o modelo de FAI do tipo proposto por Emanuel *et al.*, 1990 mas com os resistores R_P e R_N variando aleatoriamente entre 40Ω e 150Ω . A classificação de padrões foi feita com SVM e avaliada utilizando os critérios estatísticos apresentados na seção 4.5.1. Entretanto, a modelagem dos GD não foi apresentada, assim, fica subentendido que foram utilizadas fontes ideais existentes no simulador. Também é importante notar que se trata de um SDE radial com a presença de GD e, portanto, não foi considerada a possibilidade de ilhamento do sistema.

Em (HEN-GEUL YEY *et al.*, 2014) é feito um estudo comparativo do desempenho de 3 algoritmos ortogonais para detecção de FAI em MR de média tensão. Estes algoritmos são baseados na FFT, transformada Walsh Hadamard e TW discreta (db2) com janela móvel e não sobreposta. As medidas de tensão e corrente tem uma taxa de 16 amostras por ciclo e foram obtidos na base de dados do DOE *Electric Power Research Institute* (EPRI), sendo os eventos #0067 e #3894. Os resultados obtidos pelos autores mostraram que a TW discreta tem a maior efetividade, com uma melhor precisão e rapidez. Infelizmente, a base de dados utilizada para o estudo não está mais disponível no endereço informado. Dessa forma, não é possível avaliar o modelo de MR e FAI utilizados neste comparativo.

Os autores de (NAYAK *et al.*, 2016) apresentam um método baseado na soma de um ciclo das componentes sobrepostas de tensão residual para auxiliar a proteção convencional de sobrecorrente na detecção de FAI. As medidas de tensão trifásicas foram obtidas a uma taxa de 20 amostras por ciclo. A soma das tensões trifásicas da

amostra atual é subtraída da soma das tensões na amostra anterior, então cada uma destas diferenças é somada para um ciclo de 50 Hz completo (20 amostras), o que produz o índice de detecção utilizado. Um SDE de 11 kV, radial de 7 barras e com GD foi implementado no *software* PSCAD gerando os dados posteriormente processados e analisados via *software* MatLab. O sistema testes possui apenas um gerador síncrono no papel de GD e o modelo de FAI do tipo proposto por Emanuel *et al.* (1990) mas com os resistores R_P e R_N variando aleatoriamente entre 300 Ω e 400 Ω . O sistema teste é relativamente simples e balanceado, apesar dos testes com chaveamento de carga monofásica e capacitores, não há garantias que esse método seja eficiente em um sistema desequilibrado e com cargas e GD que causem distorções harmônicas.

Um método para detectar e classificar faltas em MR utilizando a transformada Hilbert–Huang com classificador de aprendizagem de máquina, é apresentado em (MISHRA; ROUT, 2017). As correntes trifásicas são medidas em diferentes pontos a um taxa de 64 amostras por ciclo, para serem processadas por um método de decomposição empírica que extrai diferentes funções de modo intrínseco (*intrinsic mode functions (IMFs)*). Estas características extraídas, então, formam um vetor de entrada para ferramentas de aprendizagem de máquina. Foram comparados os desempenhos na detecção para SDE radial e em anel de três classificadores: classificador naive Bayes, SVM e aprendizado de máquina extremo, com este último obtendo resultados superiores em relação aos demais. Este trabalho apresentou um esquema de proteção completo, com proteção primária e retaguarda, sendo as FAI um tipo dentre os vários tipos de falta a serem detectadas.

Laaksonen e Hovila (2017) apresentam um esquema de proteção aprimorado para MR de média tensão, capaz de detectar FAI dispensando comunicação de alta velocidade. O parâmetro de detecção utilizado é a média móvel, por um período de 100 ms, da magnitude de tensão de sequência zero na frequência nominal. O sistema teste possui duas unidades de GD, cujo modelo não foi apresentado, e topologia em anel. O modelo de FAI utilizado é encontrado em (SORTOMME *et al.*, 2010) que se baseia na natureza aleatória do fenômeno. O modelo consiste em variar aleatoriamente a resistência de falta, entre 50 Ω e 1000 Ω por períodos aleatórios de 10 μ a 5 ms. Em série com esse resistor um componente determinístico reproduz as características de *shoulder* e *buildup* e outros dois resistores fixos garantem a assimetria. Porém os próprios autores que propõem esse modelo de FAI alegam ser necessários mais testes para validação do modelo. Além disso, o método de classificação é pouco sofisticado utilizando-se de lógica com limitadores.

No trabalho apresentado em (SOHEILI *et al.*, 2018) o sistema teste utilizado para simulações não possui GD, mas sim a existência de cargas não lineares, que também causam distorções dificultando a detecção das FAI. O parâmetro utilizado na detecção da falta é a análise do conteúdo harmônico presente na soma das correntes

das três fases. Simulações foram realizadas para o sistema teste IEEE-13 barras, com FAI do modelo (EMANUEL *et al.*, 1990) com algumas adaptações, no *software* PSCAD. Os dados obtidos nas simulações foram processados para aplicação da técnica de detecção no *software* MatLab. O método também foi testado a partir da medição (taxa de 64 amostras por ciclo) de 3 casos reais no SDE da cidade de Teerã (Capital do Irã), para uma superfície de concreto com 10 e 20 cm espessura e asfalto com 2 cm de espessura. Os autores basearam seu método pelo uso de limitadores, sem empregar técnicas avançadas de classificação, e um número limitado de casos. Além disso, foi observado que o chaveamento de uma grande quantidade de carga pesada pode interferir no método.

O estudo (KAR; SAMANTARAY, Subhransu Rajan, 2014) apresenta um esquema de proteção diferencial para MR, usando a transformada-S, capaz de detectar faltas de baixa e alta impedância. As correntes são medidas nos barramentos extremos da MR, processadas usando transformada-S para obtenção dos contornos de tempo-frequência e então a energia espectral dos contornos é calculada. Por fim, são comparadas as energias nos dois pontos de medição, que resulta na energia diferencial, estabelecendo padrões para falta na MR em operação ilhada e conectada. O esquema foi validado para uma MR com estrutura compatível com o padrão IEC 61850-7-420 (USTUN *et al.*, 2012), para diferentes faltas *shunt* (simétricas e assimétricas) e FAI (modelo tipo (EMANUEL *et al.*, 1990)) para MR com topologia radial e em anel. A energia cresce de forma positiva para faltas no modo conectado e negativa para o modo ilhado, já para FAI o nível de energia diferencial é consideravelmente menor exigindo um ajuste especial nos limitadores. Este trabalho propõem um esquema de proteção para MR, com requisito de rápido processamento e atuação, diferente de uma técnica de detecção de FAI, cuja precisão é o requisito mais importante.

Em (LIMA *et al.*, 2021) foi proposto um método de detecção de FAI, considerando a presença de cargas não lineares em um SDE radial, utilizando o erro cumulativo no ângulo de fase da terceira harmônica de corrente. Os testes incluíram eventos como comutação de bancos de capacitores, FAI, energização de transformadores e alimentadores, juntamente com comutações de cargas lineares e não lineares. Também foram realizados testes de resiliência a presença de ruído nas medições de corrente. O modelo de FAI utilizado é apresentado em (SANTOS *et al.*, 2013) e se baseia no modelo de Nam *et al.* (2001). Além disso, registros oscilográficos reais de FAI também foram usados para validação.

Mumtaz *et al.* (2022) apresentaram um esquema de proteção, com base no Filtro de Kalman, para detectar e classificar faltas em MR incluindo FAI. O Filtro de Kalman é aplicado individualmente a cada corrente, gerando resíduos e Distorção Harmônica Total *Total Harmonic Distortion* (THD). Com o Filtro de Kalman também extrai-se a terceira harmônica dos sinais de corrente e tensão trifásicos, permitindo a obtenção

da potência reativa, que é usada para localizar faltas na MR. Os modelos detalhados do sistema teste são apresentados em (USTUN *et al.*, 2012; KAR *et al.*, 2017), com simulações realizadas no *software* MATLAB/Simulink. Entretanto, apesar de alegar que o esquema é capaz de detectar FAI, foram utilizadas apenas resistências fixas de 20, 45 e 60 Ω que não as características relevante do fenômeno, como já demonstrado na seção 2.1.2.

Um esquema de proteção para MR híbridas, baseado em LSTM e sensível a FAI, resistente à intermitência climática e adaptável a contingências N-1 foi proposto em (RAMESHRAO *et al.*, 2022). O sistema teste foi modelado de maneira detalhada e simulado em MatLab/Simulink, com 8 pontos de medição de corrente, a MR híbrida é dividida em três sub-redes: MR-1 CA, MR-2 CA e MR-3 CC (ORTIZ *et al.*, 2019). Para a FAI foi utilizado o modelo proposto em (LAI *et al.*, 2005), que também é utilizado nesta tese e apresentado em detalhe no seção 4.3.1. A combinação de dados meteorológicos e a inclusão de dados de contingência no treinamento do modelo LSTM, permitiu ao esquema proposto alcançar alta sensibilidade a FAI com imunidade à intermitência do clima e contingências N-1.

Este estudo (CHANDRA *et al.*, 2023) apresenta um algoritmo de proteção para detectar FAI em MR. Utilizando a Decomposição Empírica de Modo (EMD) e o Operador de Energia Teager-Kaiser (TKEO), dos sinais de corrente coletados de ambas as extremidades da linha, é possível distinguir FAIs de perturbações não relacionadas a faltas. O *software* PSCAD foi usado para construir e simular o sistema de teste de 11 kV 60 Hz, que consiste em uma MR com 33 barras operando de modo ilhado e conectado. O modelo de FAI utilizado é um desenvolvimento dos autores, composto por três circuitos em paralelo do modelo de Emanuel *et al.* (1990) interligados por nove chaves, que são capazes de diferentes tipos conexão entre o circuito de FAI e o terra. Esse esquema foi testado para 6.100 transitórios de FAI e não FAI e obteve um precisão de 98,89%.

3.3.1 Discussão

Os trabalhos apresentados são alguns dos mais recentes disponíveis na literatura técnica. A detecção de FAI em MR é um problema mais complexo em relação a um SDE com GD. A maioria das MR considera que os GDs são compostos por unidades com interface baseada em conversores de frequência, que além de ter capacidade limitada de alimentar a corrente de falta ainda inserem grande distorção harmônica no sistema.

Adicionalmente, durante a operação em modo ilhado da MR o nível de corrente de falta diminui consideravelmente bem como a direção dos fluxos de corrente dentro da MR. Muitos trabalhos desconsideram a operação ilhada da MR.

Desta forma, a MR é um ambiente com uma maior carga de distorção nas formas

de onda da tensão e corrente, o que pode mascarar a assinatura da FAI, afetando a extração de características e a distinção entre outros eventos de chaveamento. Além disso, métodos que trabalham com limitadores simples ou limitadores com contador devem levar em consideração a possibilidade da MR operar ilhada e conectada, pois o parâmetro de detecção escolhido pode ser afetado.

Apesar da grande quantidade de estudos e artigos apresentados neste trabalho, nenhum trata especificamente do impacto que os geradores do tipo VSC tem para a detecção de FAI. Da revisão bibliográfica realizada, os trabalhos de S.R. Samantaray *et al.* (2009) e Soheili *et al.* (2018) levaram em conta distorções harmônicas causadas por cargas não lineares e Laaksonen e Hovila (2017) descreve o possível problema causados pelos geradores do tipo VSC, mas o modelo utilizado nas simulações não foi apresentado.

Entretanto, Ortiz *et al.* (2019) utilizaram um sistema teste com GD de modelagem detalhada, porém, sem analisar o seu impacto para o desenvolvimento e desempenho do método. Também foram necessários oito pontos de coletas de corrente e dados meteorológicos para alcançar o desempenho apresentado. A técnica apresentada em (CHANDRA *et al.*, 2023) utilizou modelos de simulação detalhados para a GD. Neste caso, não há GD ao longo das linhas de distribuição da MR, e as medições são coletadas nas suas extremidades. Não há garantias que o método funcione em caso de inserção de GDs ao longo dessas linhas, ou será necessário uma reconfiguração da MR.

Isto indica a necessidade de uma investigação mais aprofundada sobre o impacto de modelos de simulação detalhados. Adicionalmente, foi desenvolvido um método de detecção de FAI aplicável em MR com geradores do tipo VSC, o qual não foi tentado até agora na literatura disponível. Utilizando apenas um ponto de medição de corrente e sem a necessidade de ajustes para operação conectada ou ilhada da MR.

4 METODOLOGIA E SISTEMA TESTE

Os SDEs estão integrando continuamente novas fontes GD, com interface de conversores VSC, visando o atendimento sempre crescente da demanda. Também existe uma maior disponibilidade de informações de monitoramento desses sistemas, na mesma medida do desenvolvimento de novas tecnologias de relés e dispositivos associados. Isto torna possível o desenvolvimento de técnicas de proteção mais complexas, capazes de processar um grande volume de informação e encontrar padrões.

Neste capítulo é apresentada a técnica proposta, o sistema teste utilizado, também as simulações realizadas e os parâmetros para avaliação do desempenho.

4.1 MÉTODO DE DETECÇÃO DE FAI PROPOSTO

A construção do método foi iniciada pela investigação de características nas medidas de tensão e corrente poderiam ser utilizadas na detecção de FAIs em MR. Neste processo não foi possível encontrar uma característica obtida a partir do processamento digital do sinal para ser associada a um limitador, então foi necessário integrar uma TRP mais adequada.

Desta forma, foi necessário avaliar TRP mais sofisticadas com capacidade de classificar séries temporais, como técnicas de aprendizagem de máquina com o uso de RNA. Uma das dificuldades do uso deste tipo de abordagem é a necessidade de uma grande quantidade de dados para treinamento dos modelos. Também, dados reais de FAI não são fáceis de encontrar e a imensa maioria dos trabalhos existentes na literatura se baseia em simulações.

Para analisar o impacto das GDs baseada em VSC é necessário a utilização de modelos de simulação detalhados, que exigem grande esforço computacional para representar as comutações em alta frequência que causam distorções nos sinais de corrente e tensão na MR. Desta forma, a criação de base de dados para treinamento de um modelo de classificação demanda muito tempo, sendo preferível técnicas que possam utilizar uma quantidade mais restrita de dados para treinamento.

Na literatura existe uma técnica muito útil para aprendizagem de máquina chamada Aprendizagem por Transferência (AT), que permite aproveitar os conhecimentos adquiridos numa tarefa e aplicá-los a outra tarefa relacionada (PAN; YANG, Q., 2010). A ideia principal por trás da AT é que os modelos treinados em conjuntos de dados grandes e diversificados aprenderam representações ricas em características para uma vasta gama de dados (YANG, H. *et al.*, 2021).

A RNC recebe uma imagem como entrada e, em seguida, produz uma classificação para o objeto na imagem, juntamente com as probabilidades para cada uma das categorias de objetos. Assim, é possível utilizar uma RNC pré-treinada como ponto de partida para aprender uma nova tarefa. O ajuste, é geralmente, muito mais rápido e fá-

cil do que treinar uma rede do zero com pesos inicializados aleatoriamente e utilizando um número menor de imagens de treinamento (ZHUANG *et al.*, 2021).

Para utilizar essas RNCs pré-treinadas é preciso transformar os dados como tensão e corrente em imagens representativas de tempo-frequência. O que não é impeditivo, o trabalho apresentado em (ZHOU *et al.*, 2021) uma combinação de RNC e imagens geradas a partir de sinais acústicos são utilizados para detectar defeitos em ímã de arco de motores CC de ímã permanente, pois os métodos tradicionais têm baixa precisão e baixa eficiência.

Benyahia *et al.* (2022) propõem um radar FMCW MIMO (*Frequency Modulated Continuous Waveform Multiple-Input Multiple-Output*) baseado em AP para estimativa de alcance, ângulo e Doppler na presença de interferências e *jammers*. Esses radares são de grande interesse para a indústria automotiva, para funções de assistência como aviso de saída de faixa, controle de cruzeiro adaptativo e assistência de estacionamento, bem como para veículos inteiramente autônomos. A abordagem proposta baseia-se na AT da RNC Squeezenet (IANDOLA *et al.*, 2016) para superar a escassez de dados e tempo de treinamento. A abordagem proposta supera o método MVDR (*Minimum Variance Distortionless Response*) e pode atingir uma resolução angular elevada de 2 graus.

Em (WANG, A. *et al.*, 2019) uma técnica com a utilização de RNC foi capaz de modelar a superfície do terreno tridimensionalmente. Neste trabalho foram criadas representações digitais de dois conjuntos de dados diferentes Bayview Park e Recology, que foram criados para uma competição realizada pelo IEEE em 2012. Esses dados são medidas de LiDAR (*Light Detection and Ranging*) e estão disponíveis publicamente. O método apresentado obteve precisão e eficiência computacional competitivas em comparação com vários métodos de classificação de atuais.

O trabalho realizado por A. Ghaderi *et al.* (2015) mostra um método de detecção de FAI em SDE que utiliza parâmetros no domínio tempo-frequência. São executados cinco passos para extrair um conjunto de características minimamente relevantes da corrente medida. Estas tarefas são complexas e envolvem a criação de matriz bidimensional com atributos de tempo-frequência, redução da dimensionalidade das características via PCA, e classificação por SVM.

O método de detecção aqui proposto também utiliza as características de tempo-frequência da corrente, mas com menos passos. A partir das medições da corrente trifásica, calcula-se a corrente residual instantânea ($I_R(t) = I_a(t) + I_c(t) + I_c(t)$) (ESLAMI *et al.*, 2021), e este parâmetro foi escolhido por apresentar o melhor desempenho geral nos testes realizados e apresentados no Apêndice A. Aplicando a TW contínua neste sinal de corrente obtém-se uma imagem bidimensional *Red, Green and Blue* (RGB) utilizada como dado de entrada da RNC pré-treinada com um grande banco de imagens.

Tabela 4 – Parâmetros de algumas RNC treinadas com Imagenet.

Rede	Camadas	Tamanho	Parâmetros	Entrada
Squeezenet	18	5.2 MB	1.24 M	227-por-227
Googlenet	22	27 MB	7.0 M	224-por-224
Inceptionv3	48	89 MB	23.9 M	299-por-299
Densenet201	201	77 MB	20.0 M	224-por-224
Mobilenetv2	53	13 MB	3.5 M	224-por-224
Resnet18	18	44 MB	11.7 M	224-por-224
Resnet50	50	96 MB	25.6 M	224-por-224
Resnet101	101	167 MB	44.6 M	224-por-224
Xception	71	85 MB	22.9 M	299-por-299
Inceptionresnetv2	164	209 MB	55.9 M	299-por-299
Shufflenet	50	5.4 MB	1.4 M	224-por-224
Nasnetmobile	*	20 MB	5.3 M	224-por-224
Nasnetlarge	*	332 MB	88.9 M	331-por-331
Darknet19	19	78 MB	20.8 M	256-por-256
Darknet53	53	155 MB	41.6 M	256-por-256
Efficientnetb0	82	20 MB	5.3 M	224-por-224
Alexnet	8	227 MB	61.0 M	227-por-227
VGG16	16	515 MB	138 M	224-por-224
VGG19	19	535 MB	144 M	224-por-224

Fonte: Adaptado de (MATLAB, 2022b)

A arquitetura da RNC elimina a necessidade de extração de características dos dados de entrada uma vez que ela aprende a partir dos dados (PAN; YANG, Q., 2010). Assim, foi utilizada uma técnica chamada aprendizagem por transferência que reduz a necessidade e o esforço para a captação de dados de entrada para o treinamento. Além disso, a AT é aplicada aproveitando-se das RNC existentes que foram treinadas em grandes conjuntos de dados, tais como ImageNet (DENG *et al.*, 2009) para classificação de imagens.

A seleção dessa RNC representa uma escolha de compromisso entre três parâmetros: precisão, velocidade e tamanho. As RNC VGG19, Squeezenet, GoogleNet, e AlexNet foram examinadas e testadas, com algumas características apresentadas na Tabela 4. SqueezeNet foi escolhida devido ao seu melhor desempenho nos testes e com um número muito menor de parâmetros. Também apresenta um tamanho compacto que facilita a implementação em dispositivos do tipo *edge devices* (SIROJAN *et al.*, 2022; PRADEEP *et al.*, 2018).

A SqueezeNet é uma arquitetura de rede neural convolucional compacta e eficiente que foi desenvolvida em 2016 (IANDOLA *et al.*, 2016), composta por 18 camadas, incluindo 12 camadas convolucionais, 5 camadas de totalmente conectadas e 1 camada *softmax*. A AT utilizando um modelo pré-treinado, também foi utilizada na detecção de FAI em (ZHANG *et al.*, 2020a, 2020b; FAN; YIN, 2019), mas não para classificação de imagens diretamente.

O método proposto em (ALMALKI, 2022) apresenta semelhanças com a proposta defendida nessa tese, mas se propõem a detectar faltas em SDE convencionais,

sem a configuração de MR ou a presença de GD. O banco de dados utilizado contém uma pequena variedade de eventos, sendo eles FAI, chaveamento de carga e banco de capacitores e faltas incipiente. A RNC escolhida foi Alexnet, que apresenta maior velocidade e menor precisão e em contrapartida tem tamanho 43 vezes maior (RUS-SAKOVSKY *et al.*, 2015), visto na Figura 24 com destaque em vermelho para as RNC testadas no desenvolvimento deste trabalho.

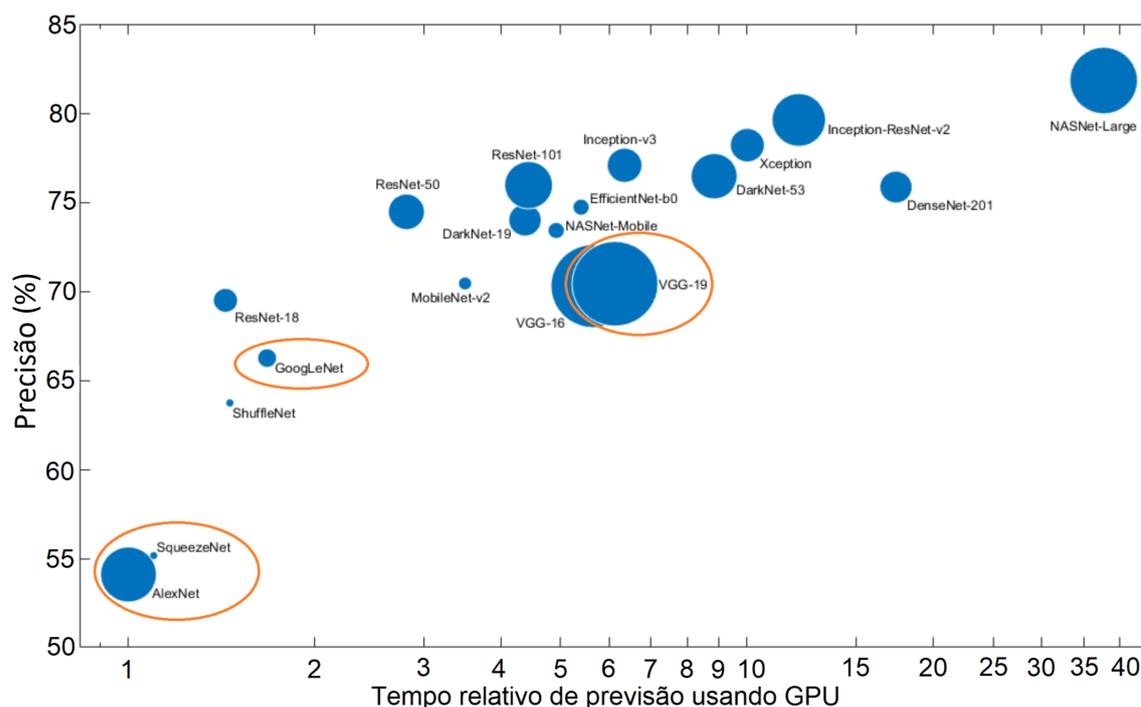


Figura 24 – Gráfico que aponta tamanho, velocidade e precisão de algumas RNC treinadas com ImageNet.

Fonte: Adaptado de (MATLAB, 2022b)

4.1.1 Detecção utilizando imagens

O método desenvolvido é dividido em três passos, como apresentado na Figura 25. O primeiro passo consiste em capturar a corrente trifásica no ponto de medição da MR e calcular a corrente residual I_R .

O segundo passo é converter a I_R em uma imagem de escalograma, que é o valor absoluto dos coeficientes da TW contínua de um sinal. Cada uma das simulações realizadas resultam em uma imagem RGB de tamanho correspondente 224-por-224-por-3, em que o 3 corresponde ao número de canais de cores. Estas imagens formam o conjunto de dados para treinamento e teste para a RNC SqueezeNet (IANDOLA *et al.*, 2016), e são representações no domínio tempo-frequência da corrente I_R . Na Figura 26 são apresentados alguns exemplos dessas imagens, sendo as 3 na parte superior resultados de eventos FAI e as três na parte inferior de outros transitórios.

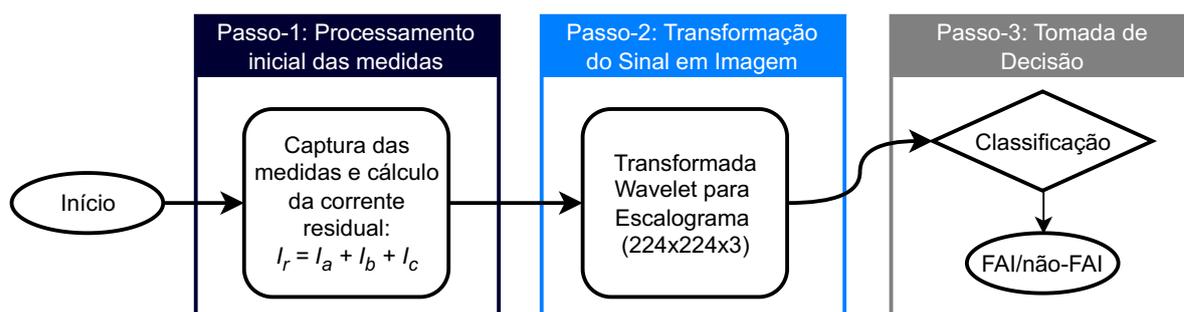


Figura 25 – Método de detecção desenvolvido.

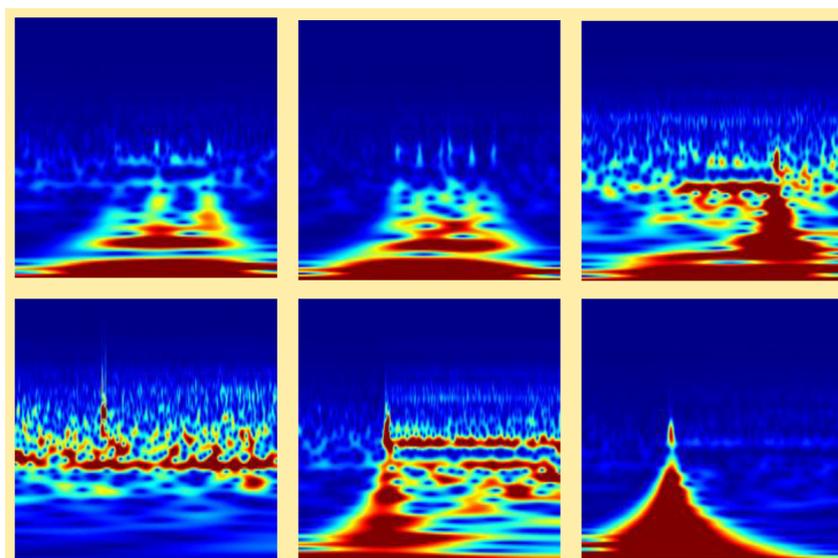


Figura 26 – Exemplos de escalogramas: as 3 imagens na parte superior da figura correspondem a FAI enquanto as na parte inferior são obtidas a partir de outros eventos.

O terceiro passo consiste no treinamento da RNC para reconhecer FAI. O processo de aprendizagem por transferência se dá pela substituição de algumas das 18 camadas da arquitetura SqueezeNet, que são substituídas por novas camadas. As primeiras camadas da rede são responsáveis por identificar as características mais comuns em imagens (manchas, bordas e cores), já as últimas concentram-se em características específicas para distinguir as classes. A camada 'drop9', responsável por evitar *overfitting*, é substituída por uma camada 'dropout' com probabilidade de 60%. Também a última camada com capacidade de aprendizagem, chamada de 'conv10', é substituída por uma nova com dois filtros que são o número de classe do conjunto de dados (FAI e não FAI). Para terminar o ajuste, a camada de classificação é substituída por uma nova camada sem classes.

De forma resumida, o método de detecção proposto usa como entrada os sinais de corrente convertidos em imagens bidimensionais RGB, que são classificadas por

uma RNC pré-treinada para o reconhecimento de imagens e treinada para detecção de FAI. Esta abordagem tem a vantagem de ser independente da experiência ou intervenção humana, para extração de características das medidas, apresentada na Figura 27.

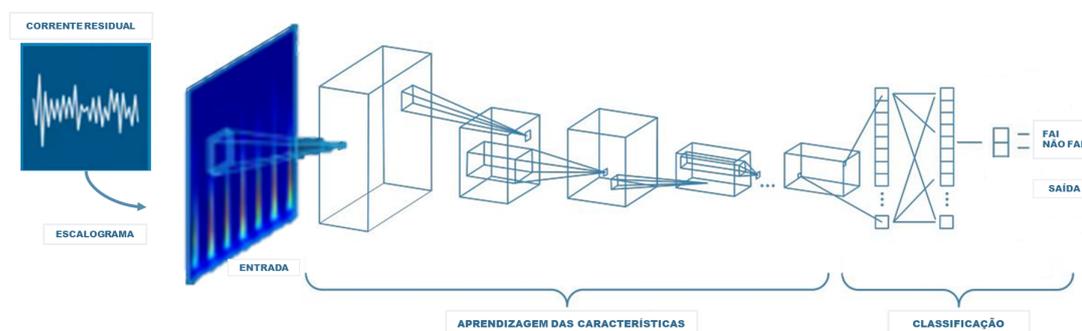


Figura 27 – Método de detecção proposto utilizando a RNC SqueezeNet.

Fonte: Adaptado de (MATLAB, 2023)

O método proposto em (ALMALKI, 2022) apresenta elevada semelhança com a proposta defendida nessa tese, mas existem sutis diferenças. A maior é que este método pretende detectar faltas em sistemas elétricos convencionais, sem a presença de GD. O banco de dados utilizado contém uma pequena variedade de eventos, sendo eles FAI, chaveamento de carga e banco de capacitores e faltas incipiente. A RNC escolhida foi Alexnet, que apresenta precisão e velocidade menor e em contrapartida tem tamanho 43 vezes maior (RUSSAKOVSKY *et al.*, 2015), visto anteriormente na Figura 24.

4.2 SISTEMA TESTE

O sistema teste foi modelado utilizando o *software* Simulink (MATLAB, 2021), combinando um modelo de teste de MR com modelos de GD encontrados na literatura. Para a integração entre os modelos foi necessário testar extensivamente a MR para validação dos resultados obtidos. Um dos primeiros problemas encontrado foi que os modelos de GD possuíam algumas variáveis com o mesmo nome, então quando operavam juntos esses geradores perdiam suas referências resultando em erros ou grandezas elétricas pouco realistas. Além disso, o sistema de controle desses GDs entravam em conflito para alguns pontos de operação da MR, causando instabilidades que elevavam a frequências a níveis muito superiores as recomendadas para a operação normal e segura. Esta interação dinâmica entre os GD ajudou a determinar os pontos de instalação dessas fontes, as de maior capacidade de geração foram posicionadas no ponto de maior densidade de carga.

Os modelos utilizados para simulação são do tipo discreto, o *solver* foi ajustado para escolha automática e passo de integração de 5 microssegundos. Este passo redu-

zido resulta em uma boa qualidade das medidas de tensão e corrente para transitórios rápidos e foi escolhido pois era a constante de tempo dos modelos detalhados de GD. Isto é necessário para reproduzir a comutação dos VSC que refletem o aparecimento de componentes de alta frequência nas formas de onda de tensão e corrente. Porém, essa constante de tempo reduzida associada a modelos de simulação complexos causam um elevado tempo para processamento dessas simulações, sendo necessários até duas horas para simular 2 segundos de operação.

A MR utilizada como sistema teste é uma adaptação de um dos sistemas testes apresentados em (C6.04.02, 2014) pela comissão C6 (Sistemas de Distribuição e Geração Distribuída) do CIGRE. O objetivo dessa comissão foi criar uma base comum para testes, análise e validação da integração das tecnologias de GD renováveis e *Smart Grid*. Para cada sistema teste a comissão apresentou dois modelos, uma versão para o sistema europeu 50 Hz e outra para o sistema norte americano 60 Hz. Os membros do grupo tarefa também encorajam os usuários a adequar os sistemas testes para suas próprias exigências regionais e nacionais, e a adaptá-los ao seu melhor uso com base em sólidas práticas de engenharia.

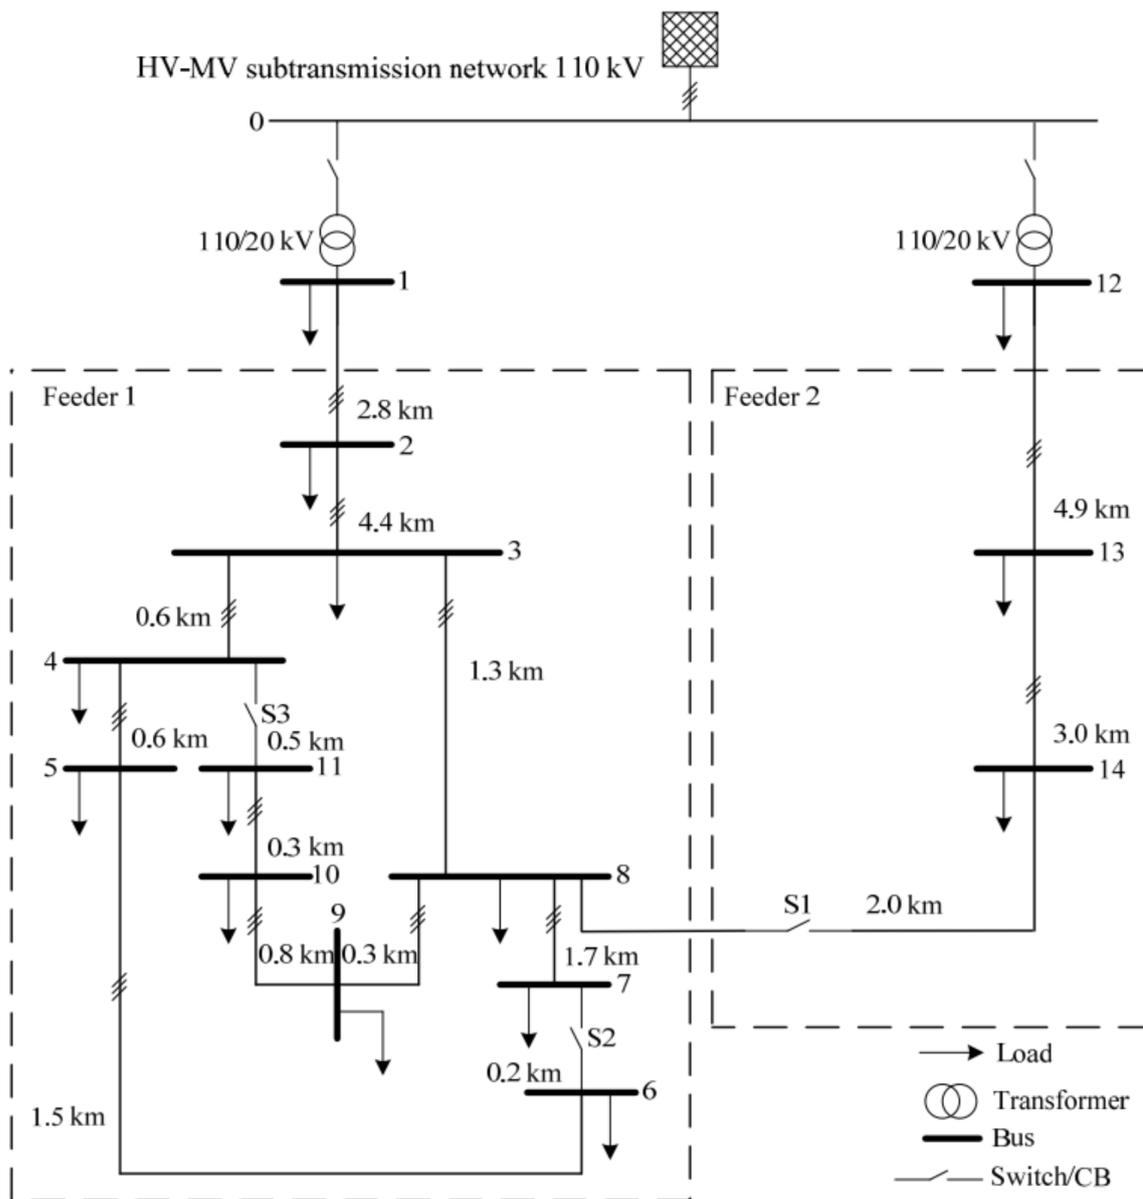
Desta forma, foi escolhido o sistema europeu por apresentar maior semelhança com os SDEs existentes no Brasil, este sistema é chamado de *Topology of European MV distribution network benchmark*. As adaptações implementadas se deram principalmente por dois motivos, aproximar um pouco mais a realidade brasileira e também adaptar aos modelos de simulação disponíveis.

A estrutura do sistema teste escolhido possibilita a operação como uma MR, sendo composto por dois alimentadores mostrados na Figura 28. Entretanto, neste trabalho apenas foi considerado o alimentador 1 (*Feeder 1*), contido no quadro tracejado a esquerda na Figura 28. O segundo alimentador foi desconsiderado por ser pequeno, com apenas cargas e 3 barras, o que não traria nenhum ganho do ponto de vista deste estudo. A operação do sistema foi alterada da tensão 20 kV para 25 kV e a frequência de 50 Hz para 60 Hz, pois o sistema brasileiro é 60 Hz e os modelos de GD disponíveis operam em 25 kV.

As cargas são preferencialmente balanceadas, mas é aceitável 10% de desequilíbrio caso seja necessário. As linhas de distribuição são todas trifásicas de dois tipos: aéreas e subterrâneas. As aéreas tem condutores de alumínio não isolado, já as subterrâneas são isoladas do tipo *Cross-linked polyethylene (XLPE)*, com condutores de alumínio redondos trançados e protegidos com fita de cobre. Neste caso optou-se por manter o balanceamento das cargas e tonar todas as linhas de distribuição aéreas.

Em (C6.04.02, 2014) é dito que o aterramento é questão de preferências regionais, sendo as redes de distribuição europeias tipicamente isoladas ou aterradas por impedância. Neste trabalho foi considerado um transformador de aterramento, conectado em zig-zag, na saída da subestação e seus parâmetros serão detalhados

Figura 28 – Modelo de referência de SDE europeu.



Fonte: (C6.04.02, 2014).

posteriormente.

As fontes de GD foram incluídas usando modelos detalhados para os inversores que são do tipo VSC, com os comandos de comutação dos *Insulated Gate Bipolar Transistor* (IGBT)s e controladores do tipo *Maximum Power Point Tracking* (MPPT). As unidades de GD são três usinas solares, um parque eólico e um gerador diesel. No modo de operação isolada o gerador diesel funciona como gerador de folga, uma vez que o controle dos outros geradores não está programado para responder a variações de frequência oriundas do sistema.

4.2.1 Microrrede

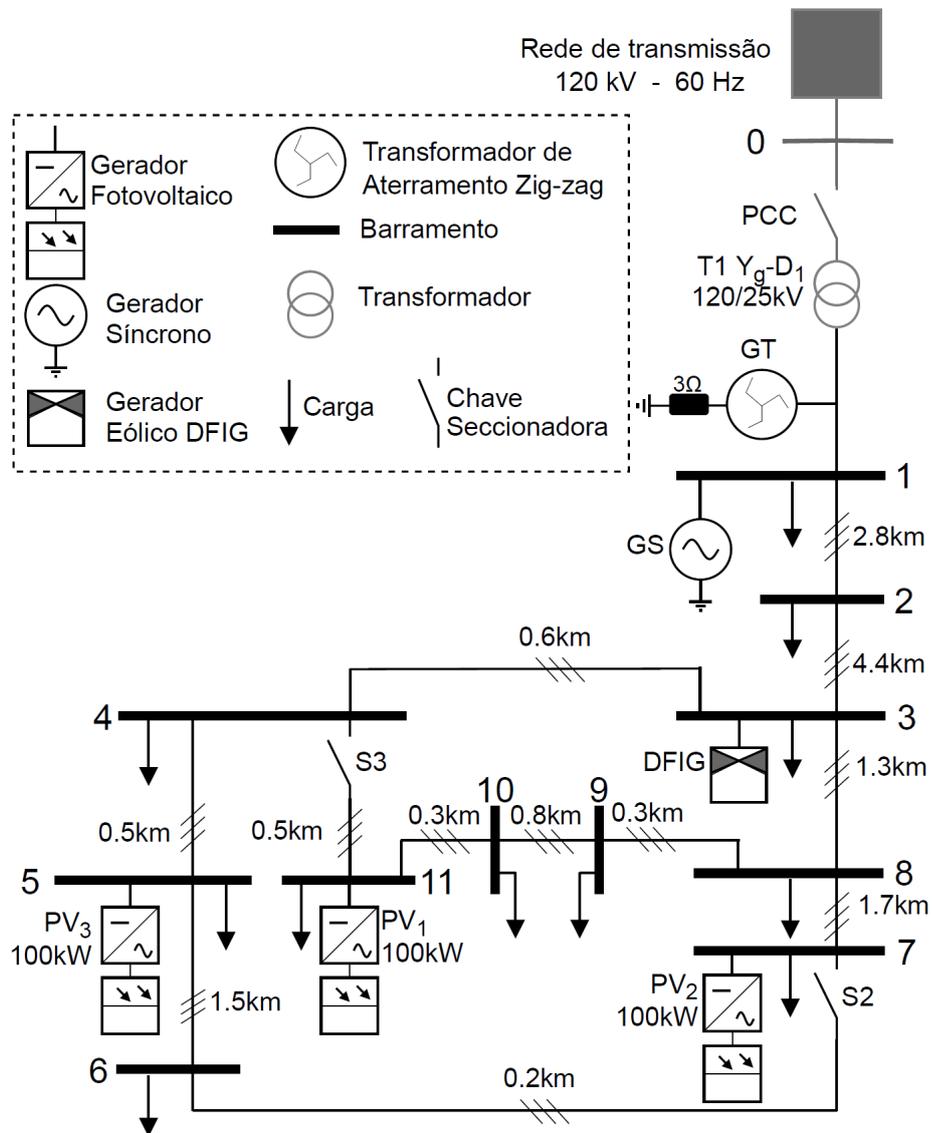
O sistema teste implementado adota uma configuração de MR e é apresentado na Figura 29, onde verifica-se a disposição das cargas, dos GDs, das barras, chaves seccionadoras, transformadores e comprimento das linhas de transmissão. As chaves seccionadoras desempenham dois papéis, sendo a chave S1 localizada no PCC que possibilita a MR operar no modo ilhado ou conectado. Já as chaves seccionadoras S2 e S3 permitem a reconfiguração da rede, quando fechadas a MR tem um sistema em duplo anel e abertas o sistema se torna radial. Essa mudança de configuração é explorada nas simulações, o que possibilita a operação ilhada ou conectada. Além disso, todos os transitórios simulados são realizados para a MR radial ou anel. A abertura e fechamento dessas chaves é tema de um testes específico do método de detecção.

Em (C6.04.02, 2014) há um item específico que traz algumas sugestões para a integração de GD. Além dos mais comuns, como gerador eólico e solar, são propostas a inclusão de micro turbina, células combustíveis e um banco de baterias. A integração dos modelos de simulação se mostrou bastante desafiadora, e como não é o objeto principal deste trabalho, foram escolhidos apenas dois tipos de GD.

Nas redes de distribuição subterrâneas ou linhas aéreas compactas semi-isoladas há uma probabilidade menor de eventos de FAI. Este tipo de falta é muito mais frequente em linhas de distribuição que tenham cabos em mau estado de conservação, que ficam submetidos a condições climáticas severas, operam em condição de sobrecargas e estão localizadas em lugares arborizados (TENGDIN *et al.*, 1996). Além disso, a quantidade de linhas de distribuição subterrâneas no Brasil ainda é insignificante se comparadas as aéreas.

Desse modo, todo o sistema de distribuição da MR contém apenas linhas de distribuição aéreas, sendo as linhas subterrâneas substituídas mas respeitando os comprimentos estabelecidos em (C6.04.02, 2014). As linhas aéreas foram modeladas como cabos de alumínio nú sem reforço de aço (A1 ou A1/SA1) e sem condutores de neutro. A partir das informações dos condutores, apresentados na Tabela 5, e da geometria dos condutores no poste, da Figura 30, foram calculados os parâmetros das

Figura 29 – MR baseada na *European MV distribution network benchmark*.



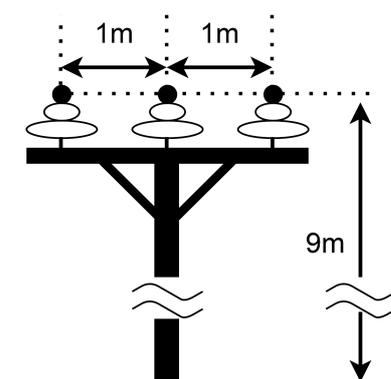
Fonte: Adaptado de (C6.04.02, 2014).

linhas.

Tabela 5 – Parâmetros dos condutores das linhas de distribuição aéreas.

Resistência (Ω/km)		Indutância (H/km)		Capacitância (F/km)	
R_1	R_0	L_1	L_0	C_1	C_0
0,51	0,658	0,0012	0,0051	10,097 η	4,0744 η

Figura 30 – Topologia das linhas de distribuição.



Fonte: Adaptado de (C6.04.02, 2014).

Foi observada a conversão para 60 Hz dos parâmetros das linhas de transmissão inseridas no *software* Simulink (MATLAB, 2021). Um dos itens considerado para a escolha pelo sistema europeu é que as linhas de transmissão de média tensão não possuem condutor de neutro diferente do norte americano.

A área ocupada pela MR é relativamente pequena, pois o comprimento das linhas de distribuição varia de 200 metros a no máximo 4,5 km. O modelo de simulação das linhas foi do tipo π , com parâmetros concentrados e correção hiperbólica dos parâmetros.

Os transformadores utilizados na MR tem seus parâmetros na Tabela 6. Em relação ao sistema europeu, proposto em (C6.04.02, 2014), para o transformador 1 as tensões foram alteradas de 110 kV - 20 kV para 120 kV - 25 kV e a potência de 25 MW para 47 MW (a impedância do transformador muda por consequência). O transformador 2 foi retirado pois era parte do alimentador 2 que foi desconsiderado. Também foi adicionado o transformador (T_g) de aterramento, conectado entre a barra 1 e o transformador 1 de forma a criar um caminho de baixa impedância para correntes de sequência zero e de alta impedância para correntes de sequência positiva. Este transformador de aterramento proporciona a uma carga monofásica (ou a FAI) um caminho de retorno da corrente em um sistema de fornecimento em delta.

Os valores de potência nominal e impedâncias são os disponíveis nos modelos encontrados no *software* Simulink (MATLAB, 2021). Os modelos são bastante deta-

lhados e demandam parâmetros que não estão facilmente disponíveis. Isto explica a potência elevada do transformador de aterramento. Os transformadores T_{solar} e $T_{eólico}$ não são apresentados de maneira explícita na Figura 29, mas são modelados dentro dos blocos de GDs implementados em Simulink (MATLAB, 2021), que estão detalhados na seção 4.2.2.

Tabela 6 – Parâmetros dos transformadores da MR.

Equipamento	T_1	T_{solar}	$T_{eólico}$	T_g
Potência	47 MVA	100 kVA	10,5 MVA	100 MVA
Conexão	3-ph Ygd1	3-ph Ygd1	3-ph Ygd11	3-ph Dz
Tensão	(120/25) kV	(25/0,26) kV	(25/0,575) kV	(25/-) kV
Impedâncias	$R_{1,2} = 0,08/30$ pu	$R_{1,2} = 0,001$ pu	$R_{1,2} = 0,025/30$ pu	$R_0 = 0,025$ pu
	$L_{1,2} = 0,08$ pu	$L_{1,2} = 0,03$ pu	$L_{1,2} = 0,025$ pu	$L_0 = 0,75$ pu

Na Tabela 7 são fornecidos os parâmetros equivalentes da rede de alta tensão conectado no transformador 1, que são necessários para simulação de curto-circuitos com a MR conectada. Esses parâmetros são diferentes dos fornecidos em (C6.04.02, 2014), principalmente a potência de curto-circuito que é a metade e a relação R/X (resistência por impedância) que era 0,1 e foi considerada 7. Este modelo equivalente do sistema de alta tensão pode ser encontrado em (MATLAB, 2022a).

Tabela 7 – Parâmetros do sistema equivalente da rede alta tensão.

Tensão nominal	Potência de curto-circuito	Relação R/X
[kV]	[MVA]	
120	2500	7

As cargas da MR estão listadas na Tabela 8 com sua potência nominal, a carga da barra 1 foi reduzida em relação ao sugerido em (C6.04.02, 2014), de 19 MW para 10 MW. Essa carga concentrada, muito maior que as demais, representa outros alimentadores supridos pelo transformador 1 que por uma questão de simplificação foram agregados. As cargas em cada barra foram agregadas em uma única carga, visto que o sistema original separava as cargas das barras em industriais e residenciais.

Um desequilíbrio de até $\pm 10\%$ é considerado razoável por (C6.04.02, 2014), mas o sistema teste implementado tem todas as cargas equilibradas. As simulações realizadas consideram três níveis de operação da MR, carregamento leve, médio e pesado. O ajuste no nível de carga da MR se dá pela modificação da carga 1, sendo o carregamento pesado 100% da carga 1, carregamento médio para 80% da carga 1 e carregamento leve 60% da carga 1. O modelo de simulação para as cargas é do tipo trifásica, linear, conectada em delta do tipo impedância constante.

Tabela 8 – Parâmetros de carga da MR utilizada nas simulações.

Barra	Potência Ativa kW	Potência Reativa kVAr
1	10.000	1.500
2	—	—
3	499	209
4	431	108
5	727	182
6	548	137
7	76	47
8	587	147
9	574	355
10	543	161
11	330	83

Fonte: Adaptado de (C6.04.02, 2014).

4.2.2 Geradores Distribuídos

A conexão direta com a MR não é possível para algumas fontes de GD, sendo necessário uma interface usando de dispositivos de eletrônica de potência. Essa integração também traz novos desafios em relação ao controle e à proteção (GURURAJAPATHY *et al.*, 2017). A resposta transitória destes dispositivos é bastante diferente da observada em geradores síncronos tradicionais. Assim, a proteção da MR para este tipo de GD é diferente do SDE tradicional, especialmente em termos de intermitência da geração, fluxo de energia bidirecional, capacidade limitada de sobrecorrente, etc Shuai (2021). Por isso é importante a modelagem adequada desse tipo de GD, de forma que as simulações resultem na resposta transitória condizente com as características deste tipo de GD.

As fontes de GD baseadas em energias renováveis são modeladas como geradores do tipo VSC e, conseqüentemente, inserem distorções harmônicas na MR. No sistema teste também foi considerada uma fonte de energia fóssil, sendo um gerador síncrono com motor diesel, de maneira semelhante ao que foi proposto por (C6.04.02, 2014).

O uso misto de fontes renováveis e não renováveis se mostra adequada por dois motivos principais. Primeiro porque as fontes renováveis são intermitentes, pois a disponibilidade de energia depende de fatores ambientais não controláveis, assim o gerador diesel garante o suprimento em momentos adversos durante a operação isolada. Segundo, porque os modelos de simulação dos GDs apresentam um sistema de controle programado para extrair a máxima potência disponível da fonte primária (sol ou vento) e não são capazes de responder as variações de frequência na MR de forma corretiva. Esta tarefa de assegurar o equilíbrio entre geração e carga, e conseqüentemente, o controle de frequência, cabe ao gerador Diesel. Este controle

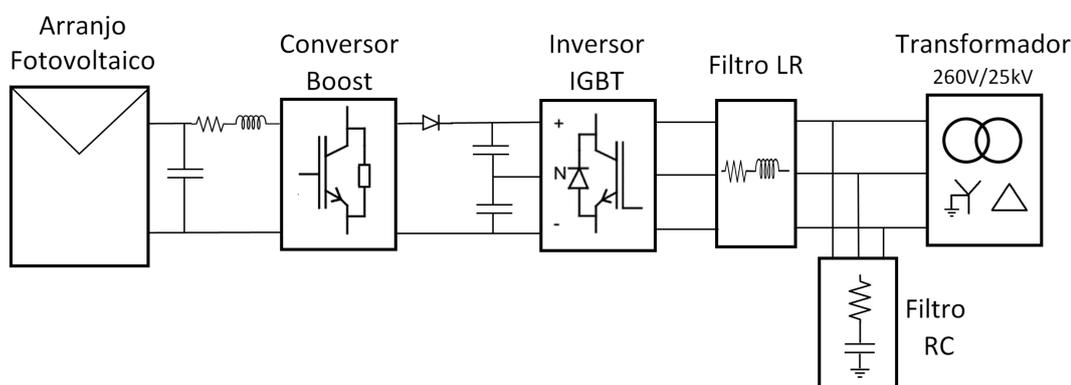
é mais crítico quando a MR está operando de modo ilhado se comparado ao modo conectado.

A seguir são apresentados os modelos de cada um dos GDs e carga não linear utilizados na MR em estudo.

- Gerador Fotovoltaico

A MR proposta neste trabalho contém três usinas fotovoltaicas de 100 kW de potência cada, conectadas à rede por um transformador de 25 kV - 600 V (D11yg) de 100 kVA (GIROUX *et al.*, 2022). As usinas tem dois conversores, um CC-CC e outro do tipo VSC. O conversor CC-CC do tipo *Boost* tem como função elevar e regular a tensão de saída dos painéis fotovoltaicos ($273 V_{CC}$ na potência máxima) para $500 V_{CC}$, pois ela varia de acordo com a temperatura. O outro conversor do tipo VSC converte essa tensão contínua de $500 V_{dc}$ para um sistema trifásico de $260 V_{ca}$ com fator de potência unitário. Este conversor utiliza interruptores IGBTs, com uma frequência de comutação 1980 Hz, em uma configuração de ponte de três níveis com três braços.

Figura 31 – Modelo do Gerador Fotovoltaico.



Fonte: Adaptado de (GIROUX *et al.*, 2022).

Esses geradores operam sob uma filosofia de controle do tipo MPPT (*Maximum Power Point Tracking*) que ajusta o ponto de operação dos conversores para o maior rendimento energético. As simulações foram realizadas com a temperatura de $45^{\circ} C$ e uma irradiância de $1000 W/m^2$. Também fazem parte da usina um filtro capacitivo, um filtro indutivo e um transformador (ver Tabela 6) para conexão com a MR. Outros parâmetros podem ser consultados em (AZIM *et al.*, 2017) que utiliza o mesmo modelo.

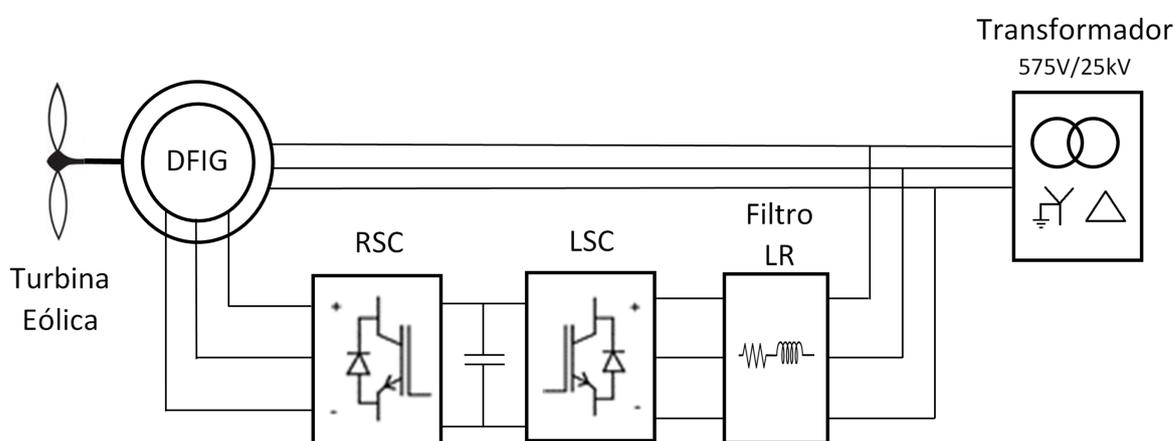
- Gerador Eólico

A usina eólica modelada é baseada no gerador do tipo *Doubly-Fed Induction Generator* (DFIG). A usina é composta por seis geradores, com uma tensão de saída de 575 V,

conectados ao barramento 3 da MR por meio de um transformador de 25 kV - 575 V (D11yg) de 9 MW (GAGNON, 2022).

A Figura 32 mostra o esquema para um desses geradores, cujo modelo implementado inclui a representação desses conversores baseados em IGBTs. O enrolamento da armadura (ou estator) é conectado à rede e o enrolamento de campo (rotor) é conectado a conversores VSC. Os conversores são chamados de *Rotor Side Converter* (RSC) e *Line Side Converter* (LSC) e permitem que a frequência no enrolamento de campo seja ajustável, assim o gerador pode operar em velocidades variáveis aumentando a eficiência na absorção de energia eólica.

Figura 32 – Modelo detalhado de gerador eólico.



Fonte: Adaptado de (GAGNON, 2022).

Nas simulações a usina opera com o vento constante em 15 m/s e a potência reativa é regulada para 0 MVar. O mesmo modelo é utilizado em (KAR; SAMANTARAY, Subhransu Rajan, 2014) e (MISHRA; ROUT, 2018).

- Modelo do Gerador Diesel Simplificado

A Usina térmica composta por motor diesel conectado a um gerador síncrono está conectada a barra 1 da MR sem a necessidade de transformador. Esta opera com uma tensão de saída de 25 kV, tendo a potência nominal de 16 MVA e serve como referência de tensão e regulador de frequência para as simulações. O seu modelo consiste no bloco de fonte trifásica (MATLAB, 2022c) disponível em (MATLAB, 2021). A sua ligação também é estrela aterrada, configurado como gerador *Swing*, tem resistência interna de $0,8929\Omega$ e indutância de 16,58 mH.

Este mesmo modelo de gerador é utilizado para substituir as demais GDs quando a simulação é dita de tipo simplificado. Mas neste caso a sua configuração é ajustada para gerador de potência fixa (PQ), gerando a mesma potência do GD

que está substituindo. Uma avaliação dessa mudança de modelagem detalhada e simplificada, sob a ótica de detecção de FAI, é apresentada no capítulo 5.

- Modelo de Carga não Linear

Cargas não lineares têm algumas características em comum com as FAIs, podendo causar falsas detecções de falta. Essas cargas, tais como soldadores a arco, fornos, computadores e outras aplicações não lineares, produzem distorções harmônicas (SULTAN, A.; SWIFT, 1991). Assim, é necessário testar a capacidade dos métodos de detecção de distinguir entre as FAIs e o chaveamento deste tipo de carga.

O tipo de carga escolhido para este teste é apresentado na Figura 33, sendo duas cargas alimentadas por retificadores com pontes de tiristores. Este modelo de carga também foi implementado no *software* Simulink (MATLAB, 2021) e está disponível em (MATLAB, 2022d). Como o modelo apresentado é para um sistema de 6,6 kV, foi necessário adicionar um terceiro transformador para conexão com a MR. Este terceiro transformador tem a conexão 25 kV - 6,6 kV (D11yg), potência de 2 MVA, resistência e indutância de sequência $R_{1,2} = 0,025/30$ pu e $inL_{1,2} = 0,025$ pu respectivamente.

A carga 1 é suprida por um retificador com pontes de tiristores de doze pulsos, as conexões em CA são feitas por um transformador com dois enrolamentos secundários (delta e estrela) de 1,25 kV e enrolamento primário em 6,6 kV ligado em estrela aterrado. A carga 2 utiliza um retificador com uma ponte de tiristores de seis pulsos, combinado com um transformador com 6,6 kV estrela aterrado no enrolamento primário e 2,5 kV em estrela isolado no secundário. A combinação das duas cargas resulta em um consumo de 500 kW 800 kVAr com 17% de distorção harmônica total na corrente.

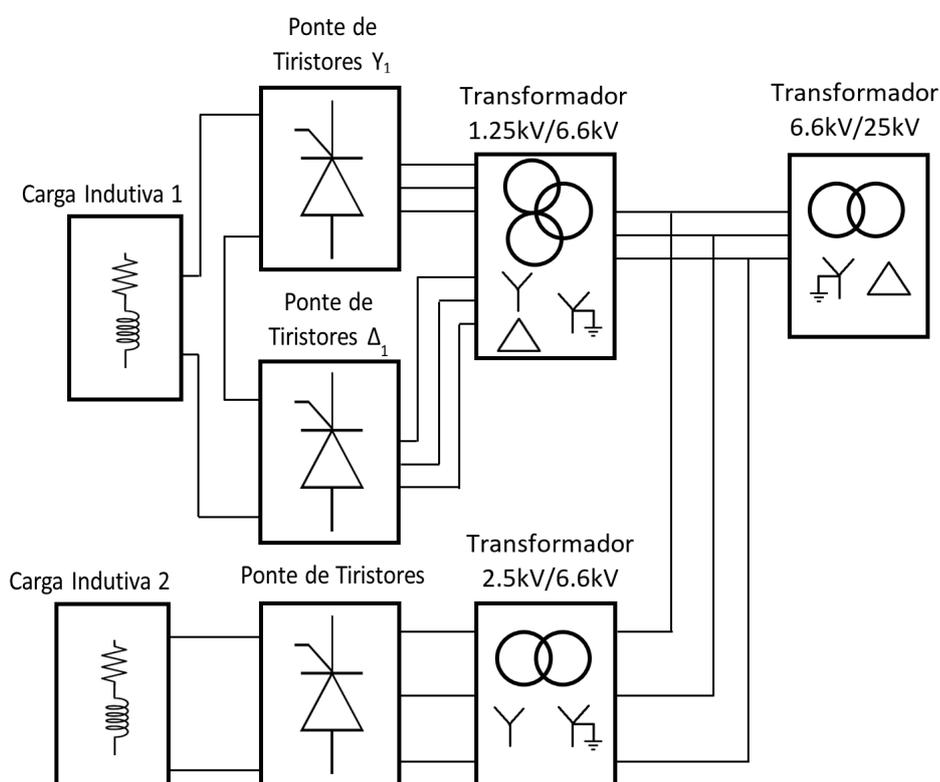
4.3 MODELOS DE FAI UTILIZADOS

Este trabalho utilizou três diferentes modelos de simulação de FAI para criar uma base de dados, que precisa ser relativamente grande (VAISH *et al.*, 2021), auxiliando a construção do método de detecção que alcançasse um melhor desempenho. Eles são variações do modelo baseado em circuitos elétricos proposto por Emanuel *et al.* (1990), com fontes de tensão de corrente contínua, diodos, indutores e resistores. Este modelo foi previamente apresentado na seção 2.1.2.

Os parâmetros do circuito são ajustados para o nível de tensão do SDE e conectados entre uma das fases e o aterramento. Neste modelo, como apresentado na Figura 34(a), o ramo positivo (R_P e V_P) tem valores menores que o ramo negativo (R_N e V_N). Isto visa reproduzir a assimetria entre os semiciclos positivo e negativo, além da intermitência na extinção do arco elétrico observável na forma de onda de corrente, visto na Figura 34(b).

Neste tipo de modelo, durante o semiciclo positivo, a corrente flui para o terra quando o valor instantâneo da tensão de fase V_F é maior que a tensão na fonte positiva

Figura 33 – Modelo de simulação de carga não linear com dois retificadores distintos alimentando cargas indutivas.



Fonte: Adaptado de (MATLAB, 2022d).

V_P . Durante a condução pelo ramo positivo o diodo D_N bloqueia o fluxo de corrente pelo ramo negativo. De maneira reversa, durante o semiciclo negativo, a corrente flui para o terra quando o valor instantâneo da tensão de fase V_F é maior que a tensão na fonte negativa V_N e o diodo D_P bloqueia o ramo positivo.

As fontes de tensão CC e os resistores são de magnitude desigual, este arranjo modela a natureza assimétrica da corrente da falta e a extinção intermitente do arco. Os valores dependem da tensão do sistema para o qual a simulação é feita e da quantidade de assimetria a ser modelada.

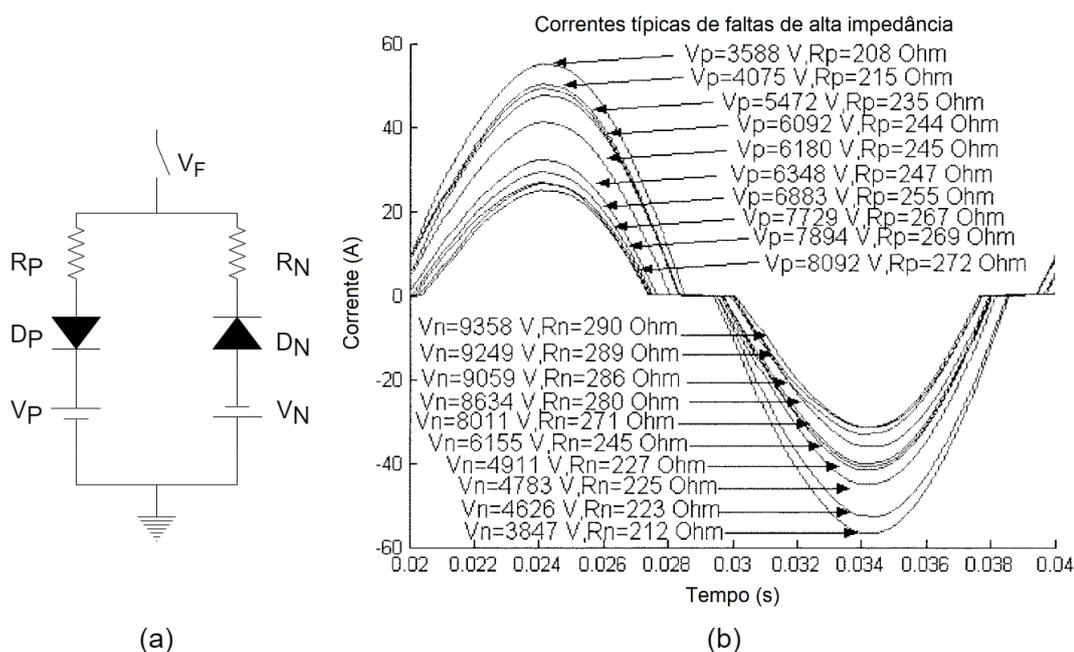
O *software* MatLab/Simulink onde foram implementados os modelos foram utilizados diodos não são ideais, possuindo uma resistência de condução de R_{ON} de $0,001 \Omega$ e tensão de polarização de $0,8 \text{ V}$. Além disso, existe um circuito amortecedor (*snubber*) de tensão com R_S de 500Ω e C_S de $250 \mu\text{F}$.

4.3.1 FAI modelo 1 (LAI *et al.*, 2005)

O primeiro modelo foi escolhido por ser um modelo simples e de fácil implementação. Com relação ao modelo original proposto em 1990 por Emanuel *et al.* (1990), pode ser dito que ele reproduz a corrente de falta com as características de ampli-

tude reduzida, não linear e assimétrica. Entretanto para métodos de detecção mais eficientes devem ser considerados também os fenômenos de *buildup shoulder* e intermitência. Apesar dessa debilidade o modelo é amplamente utilizado na literatura. Na Figura 34 temos as informações disponíveis na referência, o circuito com os valores dos parâmetros para o nível de corrente desejado em um sistema de 25 kV.

Figura 34 – Circuito elétrico do Modelo 1 de FAI.



Fonte: Adaptado de (LAI *et al.*, 2005).

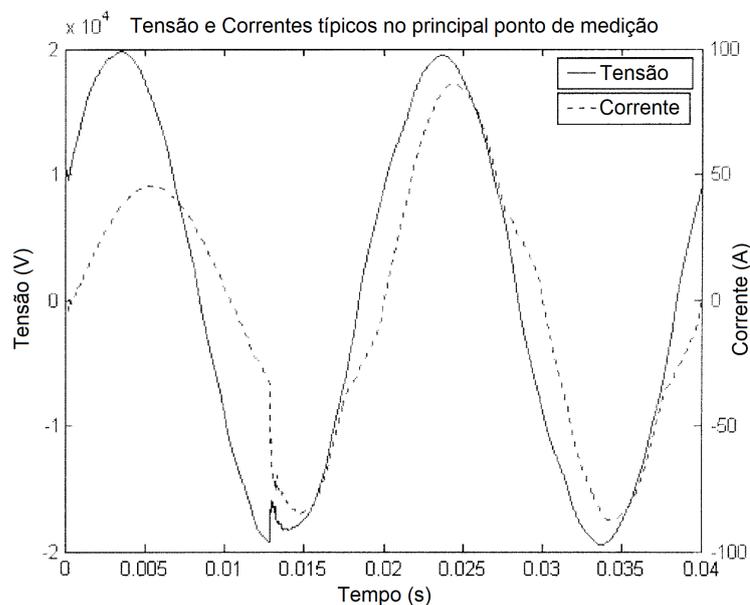
Na Figura 35 são apresentadas as formas de onda de tensão e corrente típicas do modelo. No gráfico são apresentados dois ciclos dessas grandezas, onde o eixo vertical na esquerda está a escala de tensão e à direita a de corrente.

Na Figura 36(a) são apresentadas as formas de onda de tensão e corrente, em Figura 36(b) está a curva característica tensão por corrente obtidas a partir das simulações no *software* MatLab/Simulink. Essas grandezas foram medidas diretamente no ponto da falta. Os autores utilizaram este modelo de falta em um SDE com frequência de 50 Hz, diferente dos 60 Hz do sistema teste aqui utilizado, que já foram apresentados anteriormente neste capítulo. Não há nenhum componente no modelo que seja dependente da frequência, desta forma essa diferença de frequência não prejudica a sua utilização.

4.3.2 FAI modelo 2 (SEDIGHI, A. R.; HAGHIFAM, 2010)

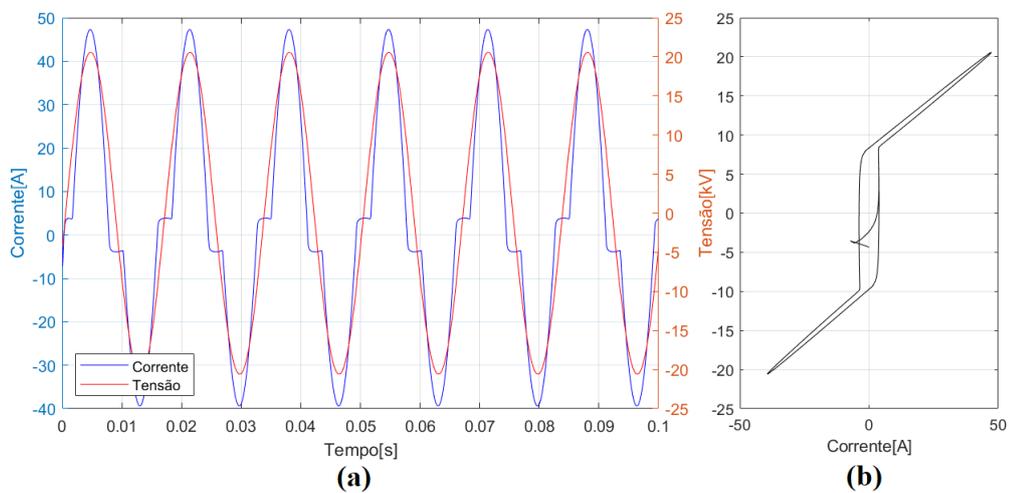
O diferencial deste modelo consiste na utilização de seis circuitos de diodos em antiparalelo e não apenas um, com chaveamentos em tempos pré-determinados. Cada

Figura 35 – Formas de ondas típicas de tensão e corrente para a FAI modelo 1.



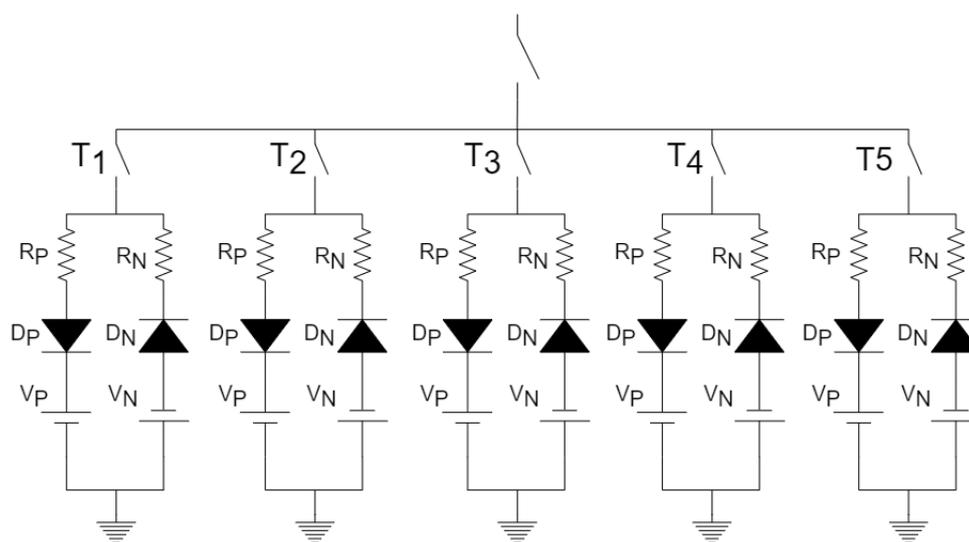
Fonte: Adaptado de (LAI *et al.*, 2005).

Figura 36 – Formas de ondas para FAI do modelo 1 simuladas: (a) tensão e corrente, (b) curva característica $V \times I$.



um dos seis estágios se refere a ocorrência de um arco elétrico, sendo os seus valores de resistência e tensão do ramo positivo e negativo apresentados em (SEDIGHI, A. R.; HAGHIFAM, 2010). O circuito elétrico do modelo é mostrado na Figura 37.

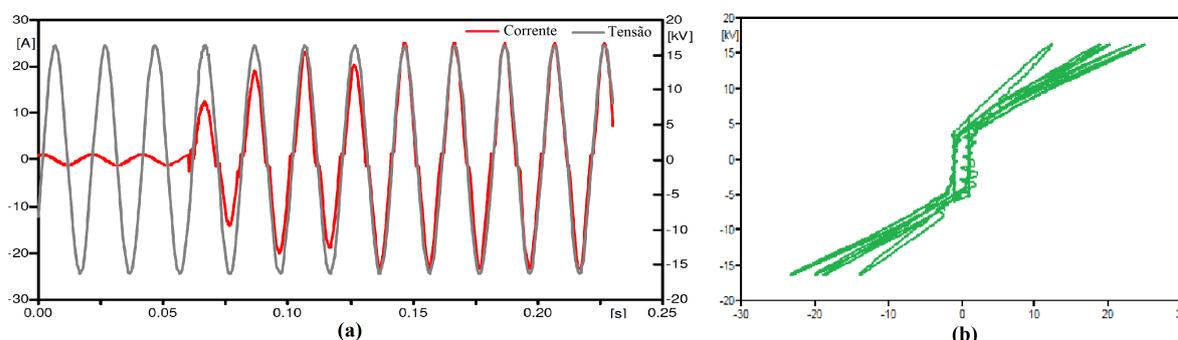
Figura 37 – Circuito do Modelo de FAI com 6 arcos.



Fonte: Adaptado de (SEDIGHI, A. R.; HAGHIFAM, 2010).

Na Figura 38(a) estão as formas de onda de tensão e corrente, com o eixo vertical na esquerda está a escala de corrente e à direita a de tensão. Na Figura 38(b) é apresentada a característica de tensão por corrente do modelo 2 de FAI, onde a não linearidade entre corrente e tensão fica evidenciada.

Figura 38 – FAI modelo 2 do tipo 1 (a) Foma de onda de tensão e corrente, (b) curva característica $V \times I$.



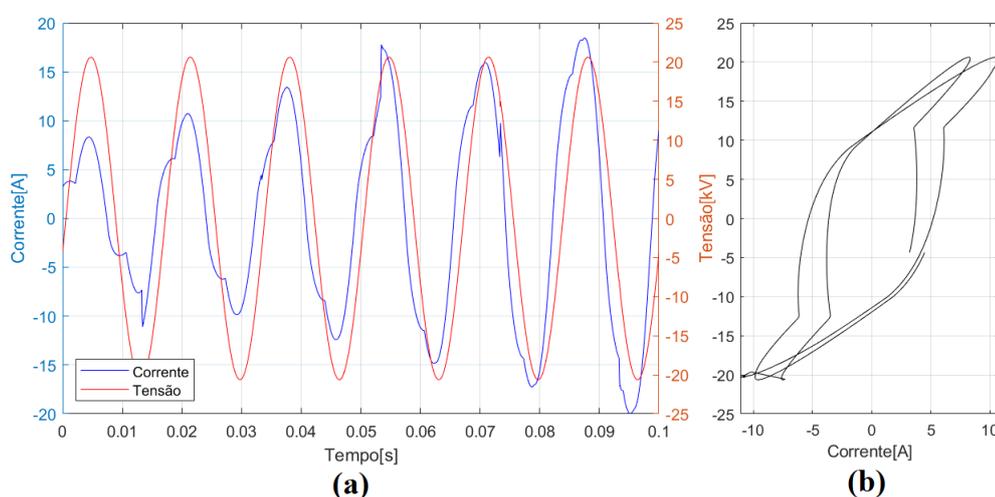
Fonte: Adaptado de (SEDIGHI, A. R.; HAGHIFAM, 2010)

Este modelo foi desenvolvido a partir de medições de faltas aplicadas em um SDE para sete diferentes tipos de solo (asfalto úmido e seco, cimento e solo, e árvore

seca). Estas faltas resultaram em 40 amostras de 15 segundos, com 24,670 kHz de frequência de amostragem. Um método que associa a utilização de FFT e PCA, que serão abordados posteriormente neste trabalho, resultou em cinco tipos de FAI com diferentes magnitudes de corrente. Os autores A. R. Sedighi e Haghifam (2010) apresentam os valores dos parâmetros para as cinco faltas que reproduzem os oito primeiros ciclos da falta.

A implementação desse modelo é apresentada com as formas de onda de tensão e corrente apresentadas na Figura 39(a). Na Figura 39(b) está a curva característica tensão por corrente, referente ao tipo *state 5*.

Figura 39 – Formas de ondas para FAI do modelo 2 simuladas: (a) tensão e corrente, (b) curva característica $V \times I$.



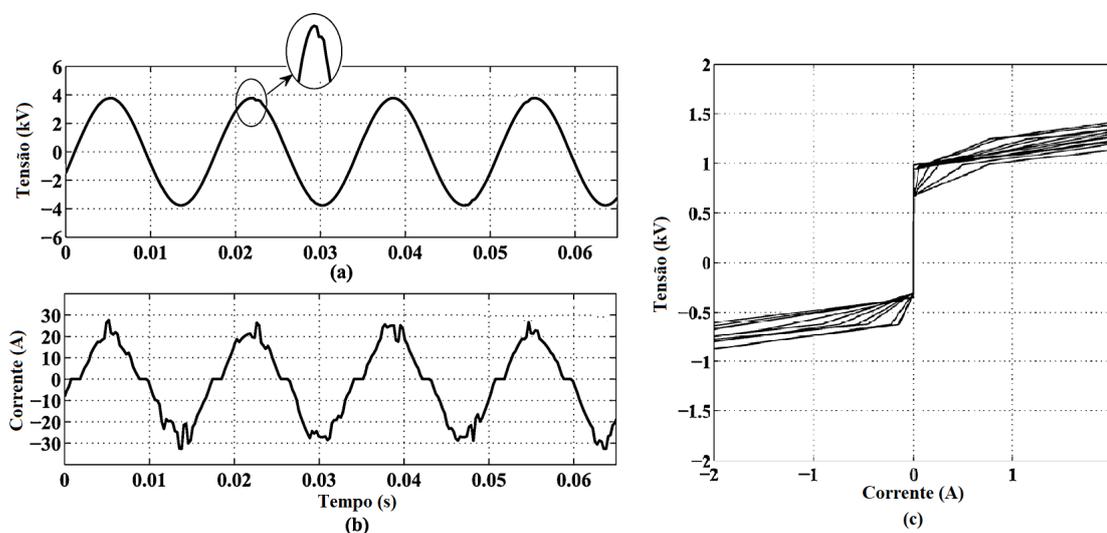
4.3.3 FAI modelo 3 (GAUTAM; BRAHMA, 2013)

Em (GAUTAM; BRAHMA, 2013) os autores proem um modelo de FAI onde as fontes de tensão e resistores variam de forma aleatória a cada 0,1 ms, apresentado na Figura 42. Os parâmetros do modelo são ajustados para se adequarem à tensão do sistema. O modelo é simples, mas cobre todos os aspectos da corrente de FAI, incluindo as dinâmicas do arco e sua extinção intermitente, não linearidade, imprevisibilidade e assimetria na corrente de falha.

Na Figura 40 são apresentadas as formas de onda de tensão e corrente assim como a curva característica tensão por corrente do modelo.

Os valores para os elementos do circuito equivalente apresentados em (GAUTAM; BRAHMA, 2013) são ajustados para um sistema de 4,6 kV. Porém, o sistema teste utilizado neste trabalho opera em 25 kV de tensão. Assim, foram utilizados os parâmetros apresentados por Cui *et al.* (2017) que são adequados ao nível de tensão

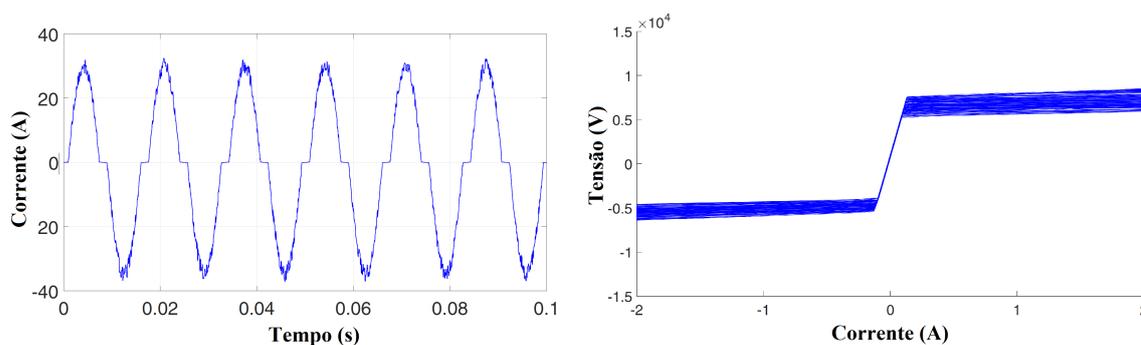
Figura 40 – Formas de ondas para FAI do modelo 3 para um sistema de 4,16 kV: (a) tensão acima e corrente abaixo, (b) curva característica $V \times I$.



Fonte: Adaptado de (GAUTAM; BRAHMA, 2013)

do sistema teste. A forma de onda de corrente e a a curva característica tensão por corrente para esta segunda referência são apresentados na Figura 41.

Figura 41 – Formas de ondas para FAI do modelo 3 para um sistema de 25 kV: (a) tensão acima e corrente abaixo, (b) curva característica $V \times I$.

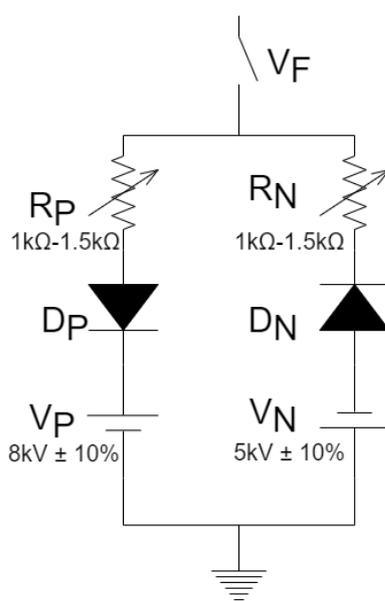


Fonte: Adaptado de (CUI *et al.*, 2017)

Dos parâmetros apresentados por (CUI *et al.*, 2017) foi necessário ajustar o limite inferior de variação dos resistores. Os autores sugerem que os resistores R_N e R_P variem entre 200 e 1500 Ω de maneira aleatória e independente a cada 0,1 ms. No entanto, foi observado um nível de distorção na forma de onda de corrente demasiadamente elevado e bastante diferente do apresentado em seu artigo, mostrado na Figura 41. Desta forma, foi necessário ajustar o intervalo de variação dos resistores para 1000 a 1500 Ω .

A variação dos valores das fontes de tensão CC são de 8 kV para V_P e 5 kV para V_N , variando 10% para mais ou para menos aleatória e independentemente a cada 0,1 ms. Estes valores de tensão seguem os apresentados por (CUI *et al.*, 2017). O circuito utilizado nas simulações realizadas neste trabalho é mostrado na Figura 42.

Figura 42 – Circuito de FAI utilizado nas simulações.

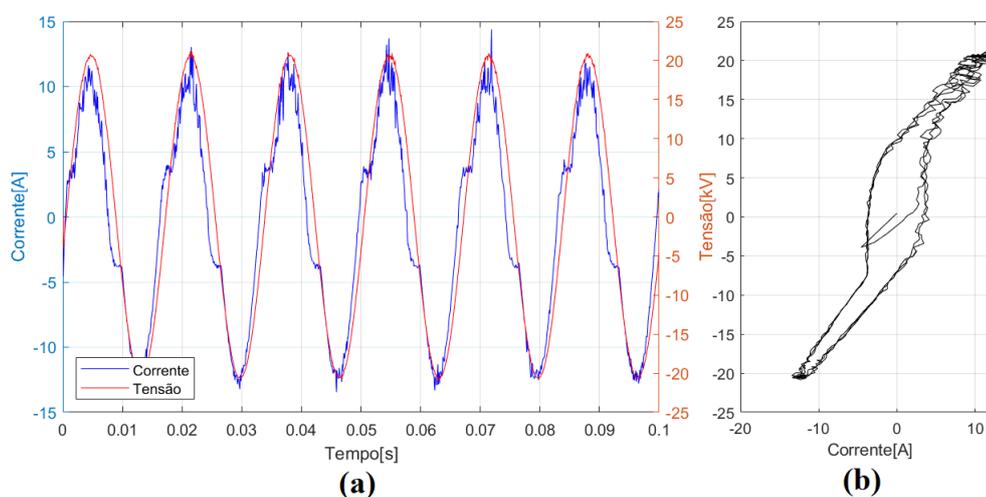


As formas de onda de tensão e corrente para o modelo implementado são apresentadas na Figura 41(a) e na Figura 41(b) está a curva característica tensão por corrente. Estes resultados comprovam a similaridade entre o modelo implementado e os apresentados em (GAUTAM; BRAHMA, 2013) e (CUI *et al.*, 2017).

Dados de tensão e corrente de falta com alta qualidade são essenciais para o desenvolvimento de técnicas eficazes de detecção de FAI. Modelos de simulação computacional são frequentemente empregados porque medidas reais de tensão e corrente de FAI são caras e arriscadas de serem coletadas (TRONDOLI *et al.*, 2022). Além disso, os resultados de simulação podem ser testados extensivamente, são adaptáveis a vários sistemas e com nenhuma ou poucas modificações (GAUTAM; BRAHMA, 2013), facilitando a obtenção de uma base de dados relativamente grande necessária em técnicas avançadas de reconhecimento de padrões (JIAO; ZHAO, 2019).

A utilização de três diferentes modelos de FAI não tem a intenção de realizar um estudo comparativo entre os modelos, mas sim evitar que o método seja eficiente exclusivamente para modelo de falta, impossibilitando uma aplicação mais generalizada. Além disso, como já mostrado anteriormente, FAI tem natureza aleatória e dependente de variáveis ambientais (umidade, superfície de contato e sistema de aterramento), que resultam em uma ampla variação na forma de onda e magnitude de corrente, além do seu conteúdo harmônico. Desta forma, não existe um modelo de simulação padrão

Figura 43 – Formas de ondas para FAI do modelo 3 simuladas: (a) tensão e corrente, (b) curva característica $V \times I$.



que consiga reproduzir todas as possibilidades de FAI real.

As simulações realizadas com os três modelos de FAI, apresentadas nas Figuras 36, Figuras 39 e Figuras 43, são consistentes com os resultados apresentados pelos autores dos modelos e outras fontes disponíveis na literatura. Os modelos apresentaram uma distorção harmônica total na corrente de aproximadamente 30% para o modelo 1, 7% para o modelo 2 e 23% para o modelo 3.

4.4 SIMULAÇÕES E BASE DE DADOS

Transitórios elétricos provocam perturbações nas formas de onda da tensão e corrente em um sistema elétrico. Esse tipo de evento pode ter origem de alguma ação normal dentro da operação do sistema, como por exemplo: chaveamento de carga, energização de transformadores e banco de capacitores ou qualquer outro tipo de chaveamento que leve a uma reconfiguração ou mudança de estado do sistema (JÚNIOR, 2003).

No entanto, transitórios elétricos também podem ser originados de eventos patológicos, como por exemplo: curto-circuito, súbito aumento ou decréscimo de tensão entre outros. Dessa modo, a proteção desse sistema elétrico precisa ser capaz de detectar e distinguir entre esses eventos de forma a garantir sua continuidade e a segurança. Para garantir o funcionamento adequado de um método de detecção, ele deve ser submetido a testes que provem a sua capacidade de distinguir esses tipos de eventos. Isto deve ser feito com critérios objetivos e mensuráveis para avaliação do desempenho de um método de detecção, que serão apresentados na seção 4.5.3.

Como já foi dito, FAI tem características que as distinguem de faltas comuns

e que podem ser interpretadas como outros eventos como chaveamento de linhas, cargas e capacitores que partilham das características de alta frequência. Já as correntes de energização (*inrush*) de transformadores e saturação de transformadores de corrente compartilham as características de baixa frequência e assimetria (MORAVEJ *et al.*, 2015).

Com o sistema teste modelado no *software* MatLab/Simulink foram realizadas diversas simulações para eventos de FAI, dos três modelos selecionados e também eventos que não são FAI. O modelo é do tipo discreto com um reduzido passo de integração de 5 microssegundos, devido aos modelos de GD que contém frequências de comutação de 5 kHz para o gerador fotovoltaico e 2,7 kHz para o gerador eólico (DFIG). Destas simulações foram coletados a corrente residual I_R medidas na barra 3, com uma de amostragem de 15,36 kHz.

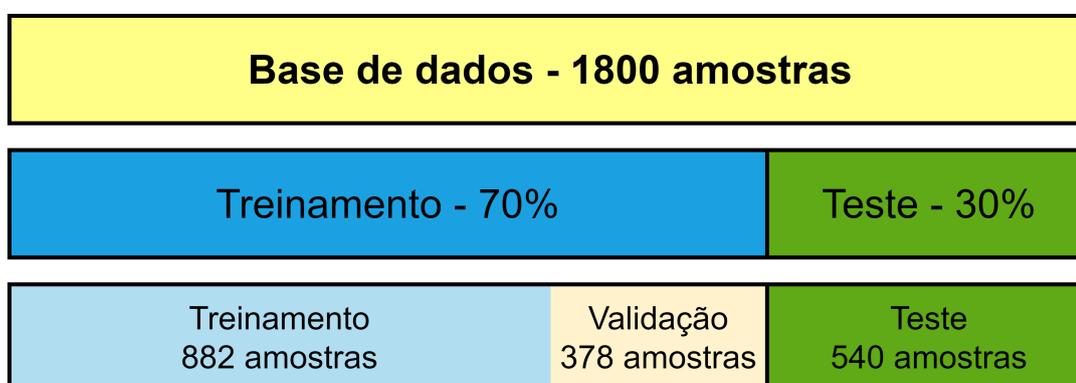
Todas as simulações duram 2 segundos. Durante os primeiros 0,5 segundos o sistema se estabiliza e entra em regime permanente. Assim, apenas os 1,5 segundos finais foram considerados para obter os sinais avaliados. Isto é válido para o método proposto e para o método utilizado para comparação. As simulações do conjunto de dados de treinamento estão listadas abaixo. Todos os eventos simulados consideram o carregamento de 100%, 80% e 60% de carga na MR em todas as combinações de topologia (anel ou radial) e modo de operação (conectada ou em ilha).

1. Falhas de alta impedância: intermitentes, com e sem interrupção;
2. Falhas de baixa impedância: trifásica, bifásica, bifásica com terra e monofásica;
3. Chaveamento de banco de capacitores: 600 kVar, 400 kVar and 300 kVar;
4. Chaveamento de transformadores: ligar e desligar com 10 % e 30 % de carga;
5. Chaveamento de cargas lineares: monofásica, bifásica e trifásica conectada em delta e estrela;
6. Chaveamento de carga não linear: conforme apresentada na seção 4.2.2;
7. Chaveamento trifásico de linhas: combinação de abertura e fechamento das chaves S2 e S3, apresentadas na Figura 29;
8. Sem transitório: todas as combinações de modo de operação da MR e topologia (anel ou radial) com as chaves S2 e S3, sem nenhum transitório.

Estes eventos combinados resultam em 1800 simulações para diferentes condições de operação, conforme apresentado na Figura 44. Foram criadas duas base de dados para treinamento contendo 1260 amostras (70% do total). A primeira contém as imagens, geradas de I_R , considerando os modelos detalhados de GD com VSC

apresentados na seção 4.2.2. O classificador treinado com este conjunto de dados é chamado aqui de Classificador Detalhado. A segunda base de dados para treinamento, com os mesmos cenários simulados anteriormente e contendo 1260 amostras. Porém, considera modelos simplificados de GD, utilizando um bloco de fonte trifásica disponível no *software* de simulação (MATLAB, 2022c). Esses geradores foram ajustados para fornecer a mesma potência ativa e reativa que os modelos detalhados de GD. O Classificador Simples foi treinado utilizando este conjunto de dados simplificados. No processo de aprendizagem por transferência, o conjunto de dados para treinamento da RNC Squeezenet é dividido em 70% para treinamento e 30% para validação, mostrado na Figura 44.

Figura 44 – Organização da base de dados para treinamento e teste.



Também foi criada uma única base de dados para testes, composta por amostras diferentes do treinamento, utilizada para testar os Classificadores Detalhado e Simplificado. Esta base contém 540 simulações apenas com GD com modelos detalhados. Os conjuntos para treinamento e teste foram divididos de maneira manual na proporção 70/30, para evitar *bias* que um sorteio aleatório poderia causar. Isto se deve ao relativamente baixo número de amostra para cada evento, como mostrado na Tabela 9. Da lista de simulações, os itens 4, 5, 6 e 7 são agrupados e nomeados como não FAI para simplificação das análises posteriores.

Tabela 9 – Quantidade de simulações realizadas que formam a base de dados.

item	Descrição do Evento	Treinamento	Teste	Total
1	FAI modelo 1	210	90	300
2	FAI modelo 2	210	90	300
3	FAI modelo 3	210	90	300
4	Não FAI	345	147	492
5	Carga não Linear	76	32	108
6	Sem transitório	76	32	108
7	Chaveamento de LT	133	59	192
-	Total:	1260	540	1800

Nesta separação, os conjuntos utilizados para treinamento contém 1260 amostras, sendo 630 de FAI e 630 de eventos não FAI. Um conjunto de treinamento contém as simulações modelos detalhados de GD e o outro modelos simplificados, conforme apresentado na seção 4.2.2. O único conjunto de dados para teste contém 540 amostras, com 270 FAI e igualmente 270 de não FAI.

4.5 AVALIAÇÃO DE DESEMPENHO

Devido à complexidade do fenômeno FAI e das suas técnicas de detecção, é necessário um conjunto completo de critérios para a sua avaliação. Ao mesmo tempo que desligar o sistema elétrico devido à FAI garante a segurança pública, também desliga cargas vitais como semáforos, elevadores e hospitais. Assim, deve ser encontrado um equilíbrio entre critérios de segurança e sensibilidade para SDEs na análise de risco. Uma vez que os métodos de detecção FAI são mais complexos, uma maior variedade de índices é também necessária para avaliar a sua eficácia (GHADERI, Amin *et al.*, 2017).

4.5.1 Índices de Desempenho

A utilização de apenas um parâmetro para avaliar um método de detecção de falta de alta impedância não parece ser adequado, uma vez que nem sempre é uma boa decisão abrir um disjuntor devido a ocorrência de uma FAI. Deste modo é preciso múltiplos critérios para avaliação das características não lineares das FAI e seus métodos de detecção. Serão utilizados cinco índices de avaliação derivados da matriz de confusão. A matriz de confusão é uma matriz de dois por dois definida como:

$$M_C = \begin{bmatrix} VP & FP \\ FN & VN \end{bmatrix} \quad (2)$$

sendo, no caso de algoritmos de detecção, *VP* é o número de detecção correta das FAIs, *VN* é o número de decisões corretas de condições não FAIs, *FN* é o número de casos de FAI erroneamente classificados como sem faltas e finalmente *FP* mostra o número de FAIs que não são detectadas (GHADERI, A. *et al.*, 2015). O objetivo de qualquer método de detecção é atingir os maiores valores possíveis nos cinco índices de confiabilidade listados abaixo.

- Precisão (*Accuracy*): é a quantidade de detecções corretas em relação ao número total de casos. Destaca a precisão geral do método.

$$A = \frac{VP + VN}{VP + FP + VN + FN} \quad (3)$$

- Confiabilidade (*Dependability*) este índice pode ser expresso como a relação entre o número de falhas identificadas e o número real de faltas. A confiabilidade

é definida como precisão na detecção de estados faltosos.

$$D = \frac{VP}{VP + FP} \quad (4)$$

- Garantia (*Security*): demonstra a capacidade de reconhecer FAI somente quando ela está presente e não ser acionada para condições de não FAI. Ele representa a precisão da detecção do estado saudável.

$$S = \frac{VN}{VN + FN} \quad (5)$$

- Segurança (*Safety*): este índice leva em conta a capacidade do método de isolar as faltas que representam um risco para o público em geral, como a FAI em uma área congestionada, assegurando que as faltas não sejam confundidas com a não presença de FAI. O número de não FAI corretamente classificados dividido pelo número total de condições de não FAI determina este critério.

$$SF = \frac{VN}{FP + VN} \quad (6)$$

- Sensibilidade (*Sensibility*): este índice pode ser definido como a porcentagem de FAI detectadas corretamente sobre o número total de FAI. Enfatizando o perigo de acionamento da proteção em cargas sensíveis.

$$SN = \frac{VP}{VP + FN} \quad (7)$$

Estes critérios de avaliação foram utilizados para avaliar o método de detecção proposto neste estudo, tornando possível comparar o seu desempenho frente a outras metodologias existentes na literatura. Das técnicas de detecção de FAI apresentada por Amin Ghaderi *et al.* (2017) ficou demonstrado que apenas uma minoria dos trabalhos utiliza essas métricas para medição de desempenho.

4.5.2 Teste de resistência a ruído

As FAI resultam em características de frequência específicas nos sinais de corrente e tensão. Com processamento destes sinais extraem-se características que fornecem as métricas para as técnicas de detecção de FAI. Como a presença de ruído implica em variações nas frequências dos sinais medidos, testar esses algoritmos em condições de ruído é essencial para técnicas de proteção com uso real (LOPES *et al.*, 2021).

Devido à natureza dinâmica do sistema de energia, o ruído é inevitável. A mudança contínua dos requisitos dos consumidores domésticos e industriais é responsável pela interferência de diferentes frequências e, por sua vez, gera ruído (SARANGI *et*

al., 2022). Para aumentar a confiabilidade, reduzindo o risco de atuação desnecessária da proteção, é preciso que a proteção seja resistente a presença de ruído.

Uma medida da intensidade de um sinal medido em relação à intensidade do ruído de fundo é conhecida como SNR. É uma razão entre a potência do sinal e do ruído, expressa em decibéis (dB), que é calculada utilizando a seguinte fórmula:

$$SNR = 10 \cdot \log_{10} \frac{P_{sinal}}{P_{ruído}} \quad (8)$$

onde, P_{sinal} é a potência do sinal desejado, $P_{ruído}$ é a potência do ruído. Uma relação SNR mais elevada indica uma melhor qualidade do sinal. Por exemplo, uma SNR de 20 dB significa que a potência do sinal é 100 vezes superior à potência do ruído.

No livro *Power systems signal processing for smart grids* de Ribeiro *et al.* (2014), encontra-se a informação de que valores típicos são maiores que 27 dB para testes de ruído, e na prática o valor mais utilizado é 40 dB. Foram encontrados diversos valores para testes de resistência a ruídos na literatura específica de detecção de FAI. O método apresentado em (RAMESHRAO *et al.*, 2022) foi submetido a testes com variações de $10 \text{ dB} < SNR < 30 \text{ dB}$, em (CHAITANYA *et al.*, 2020) utilizaram de 30 dB à 50 dB e em (LOPES *et al.*, 2021) o valor foi de 30 dB. Já o trabalho apresentado em (ZHANG *et al.*, 2020a) utiliza valores de 40 dB, 50 dB e 60 dB, que representa um sistema com baixa presença de ruído. Para o método de detecção de FAI apresentado em (WANG, X. *et al.*, 2022), que se propõem a operar em sistema com elevada presença de ruído de fundo, os testes utilizaram uma relação SNR de -10 dB.

Os testes de resistência a ruído realizados no presente trabalho consideram valores de 0 dB à 30 dB para a SNR, cujos resultados estão na seção 5.7.

4.5.3 Método para comparação

Além de avaliar o método proposto utilizando os índices de desempenho apresentados na seção 4.5.1, foi escolhido um método no estado da arte para comparação dos resultados. O artigo escolhido (VEERASAMY *et al.*, 2021) se concentra na detecção de FAI em sistemas com fontes de energia solar fotovoltaica. Esta é uma fonte com interface VSC, altamente relevante para MR que frequentemente incorpora fontes renovável. O método apresentado utiliza uma abordagem de aprendizado profundo baseada em LSTM, que é uma técnica avançada de aprendizado de máquina, para detecção de FAI em um SDE integrado com GD fotovoltaica. O modelo de FAI é uma variação do modelo de Emanuel *et al.* (1990), que apresenta faixas de variação distintas nos valores das fontes CC e resistores para ramos positivos e negativos do circuito.

Neste estudo, o desempenho do método apresentado também é comparado com outras abordagens tradicionais de aprendizado de máquina, como *K-Nearest*

Neighbor, SVM, AD e Naïve Bayes. A base de dados utilizada foi construída por meio de simulações de um sistema 4,6 kV 60 Hz, realizadas no *software* MatLab/Simulink, totalizando 1.164 amostras. Para treinamento foram utilizadas 970 amostras (706 FAI e 264 não FAI), que corresponde a 80% da base de dados, e 194 amostras (66 FAI e 128 não FAI) para testes.

O método proposto consiste em coletar o sinal de corrente trifásica, processá-lo com TW Discreta com onda mãe *db4* (Daubechies wavelet) para calcular a energia de cada fase conforme a equação a seguir:

$$\text{Valor de Energia} = \sum_{i=1}^k \left[|D_i|^2 \right] + |A_k|^2 \quad (9)$$

em que k representa o número de níveis e é escolhido como 5, D_1 , D_2 , D_3 , D_4 e D_5 representam os níveis de coeficiente de detalhe e A_k é o coeficiente de aproximação do nível final do sinal.

Este parâmetro de energia dos sinais de corrente de cada fase, proposto em (VEERASAMY *et al.*, 2020) é, então, utilizado no treinamento e teste do modelo de LSTM. Os autores obtiveram uma precisão de classificação de 91,21% com uma taxa de sucesso de 92,41% na identificação de FAI para a base de dados utilizada. Esta técnica de detecção foi aplicada ao mesmo conjunto de dados de teste utilizado no método proposto nesta Tese, cujas características serão apresentadas de forma pormenorizada no próximo capítulo.

5 TESTES E ANÁLISE DE RESULTADOS

Sete cenários de teste são estabelecidos a fim de determinar a eficácia da abordagem proposta para a detecção de FAI. O banco de dados completo é usado no teste inicial. A capacidade de reconhecimento dos modelos 2 e 3 de FAI é avaliada no segundo e terceiro testes, respectivamente. O desempenho relativo à diferenciação entre carga não-linear e FAI é analisado no quarto teste. A capacidade de não identificar a comutação em linhas de transmissão MR como FAI é testada no quinto teste. No sexto teste o modelo que não foi treinado utilizando banco de dados com casos sem transitório é testado com a base dados contendo cenários sem nenhum transitório. No sétimo e último teste, o modelo é testado com o banco de dados completo porém com as medidas contaminadas por ruído.

Na seção 4.4 são descritos todos os transitórios simulados, portanto aqui é tratada apenas a organização desses dados, separando-os entre treinamento e teste de acordo com os testes. A separação entre os dados para treinamento e teste foi realizada de modo manual, diversificando a composição de cada um dos tipos de transitório nos conjuntos para treinamento e teste. Isto porque o volume de dados é relativamente reduzido e bastante diverso. Durante o desenvolvimento dessa pesquisa, foi observado que no processo de treinamento o sorteio aleatório dos dados pode gerar resultados bastante discrepantes. Para o treinamento do modelo são sorteados de maneira aleatória 30% dos dados para validação e 70% para treinamento. Quando realizados vários treinamentos com os mesmos ajustes e conjunto de dados a precisão no treinamento variou de maneira significativa e conseqüentemente o desempenho durante os testes.

Isto acontecia principalmente quando a base de dados era menor, com um total de 336 amostras. Por isso a base de dados foi ampliada significativamente. Entretanto evitou-se o processo de treinar e testar o modelo até que o sorteio incluísse os casos mais difíceis na base de treinamento e os casos fáceis na base de teste. Esta dificuldade se dá, principalmente, para eventos que ocorrem mais afastados da barra 3, onde são coletadas as medidas de corrente na MR. Além disso, os modelos de FAI 1 e 2 apresentam ajustes para diferentes magnitudes de corrente de falta, sendo as com menor corrente mais desafiadoras.

Desta forma, a separação manual dos dados de teste e treinamento visa equilibrar a concentração desses casos de FAI em cada um dos conjuntos de dados. Além disso, considerando que o conjunto para treinamento contém 1260 amostras e o conjunto de teste 540, em um sorteio aleatório eventos como chaveamento de carga não linear (108 amostras) pode ser distribuído de maneira desigual. Então, cada rodada de sorteio dos dados pode resultar em um modelo para a *SqueezeNet* com desempenho diferente. Permitindo a quem realiza esse processo parar sempre que obtiver um bom

resultado.

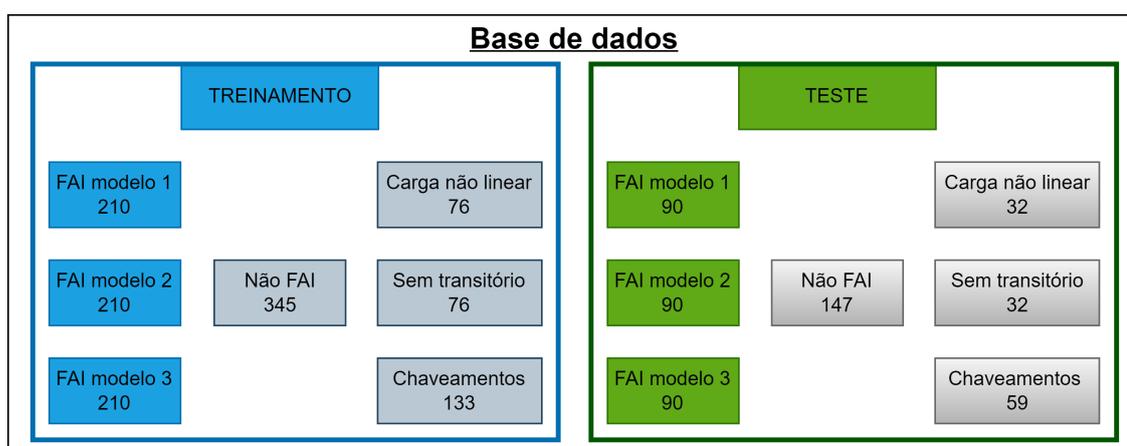
Foi apresentado na seção 4.5.3 o método de detecção de FAI encontrado na literatura, ele será chamado de LSTM (VEERASAMY *et al.*, 2021) e é feita uma análise comparativa de resultados. Em uma mesma figura são apresentados os resultados para os dois classificadores detalhados *SqueezeNet* e LSTM e para os dois classificadores simples *SqueezeNet* e LSTM. Todos os testes foram realizados com dados de simulação pra os modelos GD detalhados, reproduzindo assim um cenário de simulação mais realista.

5.1 TESTE COM A BASE DE DADOS COMPLETA

Na Figura 45 é apresentada a composição completa do banco de dados. As 630 amostras de FAI em azul (210 de cada tipo) são para treinamento, assim como as 180 amostras de FAI em verde (90 de cada tipo) são para teste. O mesmo vale para os outros eventos transitórios. Nos outros testes são realizadas alterações neste ordenamento, então uma figura é apresentada e são descritas de maneira clara os eventos realocados ou excluídos.

O conjunto completo de dados é utilizado neste teste, totaliza 1800 amostras divididas 70% para treinamento (1260) e 30% para teste (540). Esses dois conjuntos tem metade das amostras sendo FAI e a outra metade não é. Como já dito anteriormente, para o treinamento da *SqueezeNet* as 1260 amostras são sorteadas em 30% para validação e 70% para treinamento.

Figura 45 – Base de dados para treinamento e teste utilizada no teste com a base de dados completa.

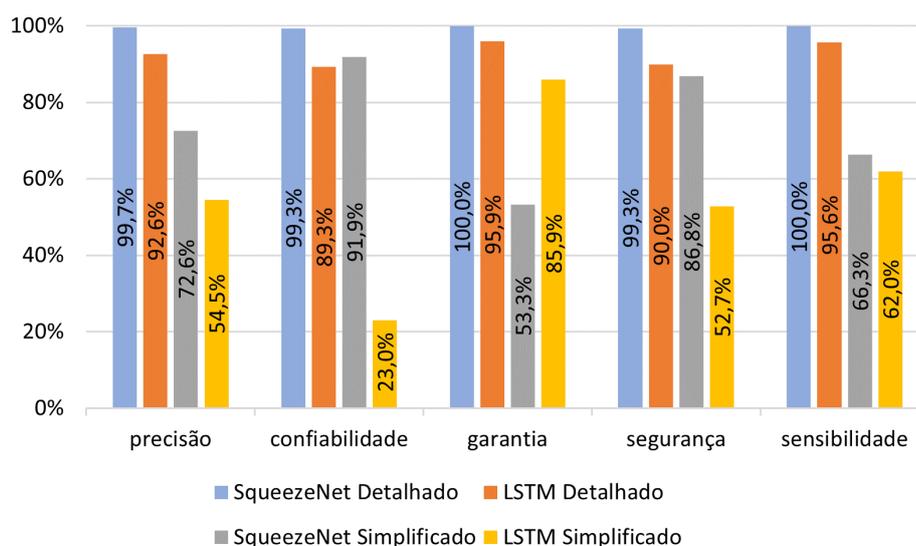


Os resultados deste teste, usando os cinco índices de desempenho mencionados anteriormente na seção 4.5.1, são mostrados na Figura 46. Quando treinado com dados detalhados, o método proposto utilizando o modelo pré-treinado de RNP *SqueezeNet* superou o método que emprega o LSTM (VEERASAMY *et al.*, 2021)

em todos os cinco índices de desempenho. Este resultado é apresentado em azul para o classificador *SqueezeNet* detalhado e em alaranjado para o classificador LSTM detalhado.

Em comparação com os classificadores treinados com dados simplificados, os dois classificadores detalhados produziram um resultado significativamente superior. Os resultados destes testes demonstram que técnicas avançadas de reconhecimento de padrões sem uma boa base de dados levarão a métodos de detecção FAI imprecisos, especialmente se considerarmos as simulações com modelos detalhados de GDs que reproduzem mais fielmente um cenário de aplicação real. A metodologia proposta foi superada apenas no parâmetro de garantia para dados simplificados de treinamento. Este resultado pode ser observado em cinza para o classificador *SqueezeNet* simplificado e em amarelo para o classificador LSTM (VEERASAMY *et al.*, 2021) também simplificado.

Figura 46 – Índices de desempenho para o teste com a base de dados completa.



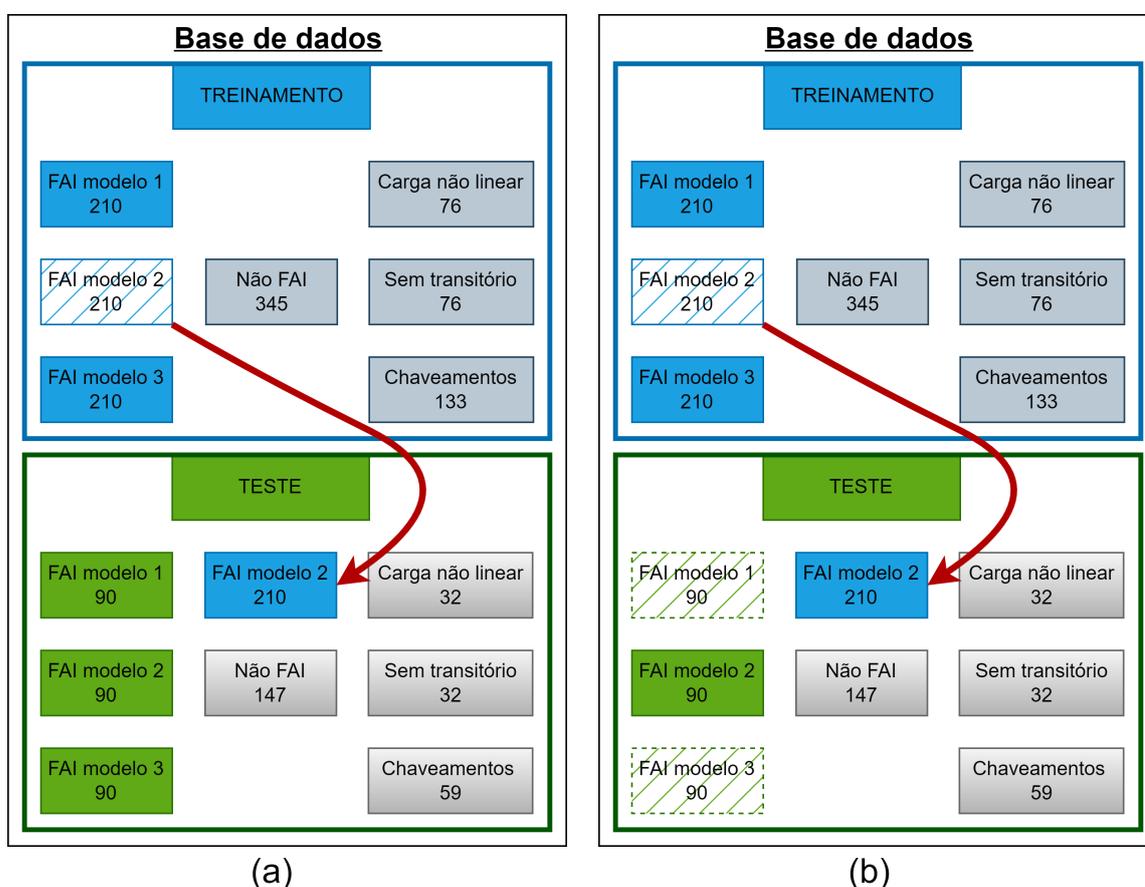
5.2 TESTE PARA A FAI MODELO 2

Existem diversas variáveis que têm influência sobre as FAI, como por exemplo o material da superfície do solo, umidade superficial, arquitetura do alimentador, níveis de tensão, clima e tipo de carga (GHADERI, Amin *et al.*, 2017). Portanto, criar um banco de dados a partir de simulações que possam acomodar todas as configurações imagináveis de eventos FAI em uma MG é uma tarefa bastante desafiadora. Os testes com os modelos FAI 2 e 3 avaliam a resiliência do método de detecção desenvolvido. A ideia é submeter o classificador aos dados de um modelo FAI não utilizado durante o processo de treinamento e avaliar seu desempenho.

Neste teste para o modelo 2 de FAI foram criadas dois conjunto de dados diferente. No primeiro, que pode ser visto na Figura 47(a), as 210 amostras de treinamento da FAI modelo 2 são movidas para o conjunto de teste. Assim, esse conjunto tem para treinamento 1050 casos (420 FAI, 630 não FAI) e para testes são 750 casos (480 FAI, 270 não FAI).

No segundo conjunto, além de mover os eventos FAI modelo 2 de treinamento para teste, os dados para teste dos modelo 1 e 3 foram retirados da base de dados. Esta mudança é apresentada na Figura 47(b), possibilitando avaliar se ao retirar as amostras da FAI modelo 2 o classificador mantém o desempenho para os outros eventos de FAI. Dessa forma verifica-se o benefício de múltiplos modelos de simulação de FAI avaliando se há alguma aprendizagem de forma cruzada, cuja inserção de um novo modelo de FAI amplia a capacidade de detecção de modelos de FAI já existentes na base de dados. Também é preciso levar em conta que os resultados são apresentados de maneira percentual, e que o tamanho das amostras variam entre os testes.

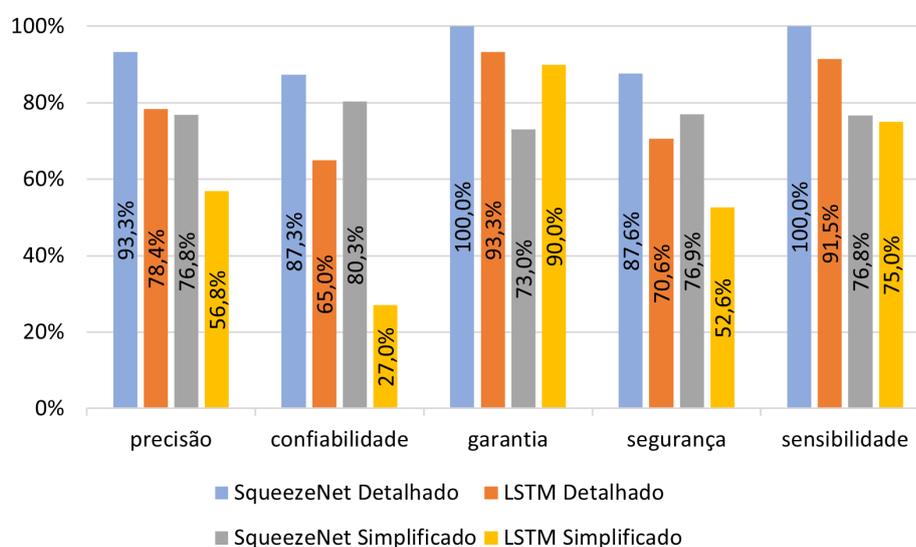
Figura 47 – Base de dados para treinamento e teste utilizada no teste da FAI modelo 2:(a) teste 1 (b) teste 2.



Os resultados do primeiro teste do modelo 2 estão na Figura 48. Comparado ao

caso base, o classificador *SqueezeNet* detalhado manteve os índices de segurança e sensibilidade, uma pequena degradação na precisão e um desempenho ligeiramente inferior a 90% na confiabilidade e segurança. O classificador LSTM (VEERASAMY *et al.*, 2021) detalhado, por outro lado, mostrou uma maior degradação em seus índices de desempenho, caindo de 93% para 78% em precisão e de 89% para 65% em confiabilidade. Quando comparado ao teste de base usando todo o banco de dados, a diferença de desempenho para classificadores simplificados não foi significativa.

Figura 48 – Índices de desempenho para o teste 1 da FAI modelo 2.



5.3 TESTE PARA A FAI MODELO 3

O mesmo procedimento usado no teste anterior foi aplicado para avaliar o modelo 3. Na Figura 49(a) O conjunto de dados de treinamento consiste em 1050 casos (210 FAI modelo 1 e 210 FAI modelo 2, 630 não FAI) e para testar 750 casos (480 HIF modelo 3, 270 não HIF). O segundo teste tem sua base de dados apresentada na Figura 49(b).

Neste teste, os classificadores detalhados produziram os melhores resultados, como visto na Figura 50. A melhor precisão para o classificador *SqueezeNet* simples foi alcançada neste teste.

Para este modelo de FAI, as resistências e fontes CC neste modelo FAI 3 mudam aleatória e independentemente a cada 0,1 ms. Apesar desta disparidade em relação aos outros dois modelos FAI, ambos os classificadores detalhados foram capazes de distinguir as características do sinal de corrente FAI nas imagens do escalograma.

Figura 49 – Base de dados para treinamento e teste utilizada no teste da FAI modelo 3:(a) teste 1 (b) teste 2.

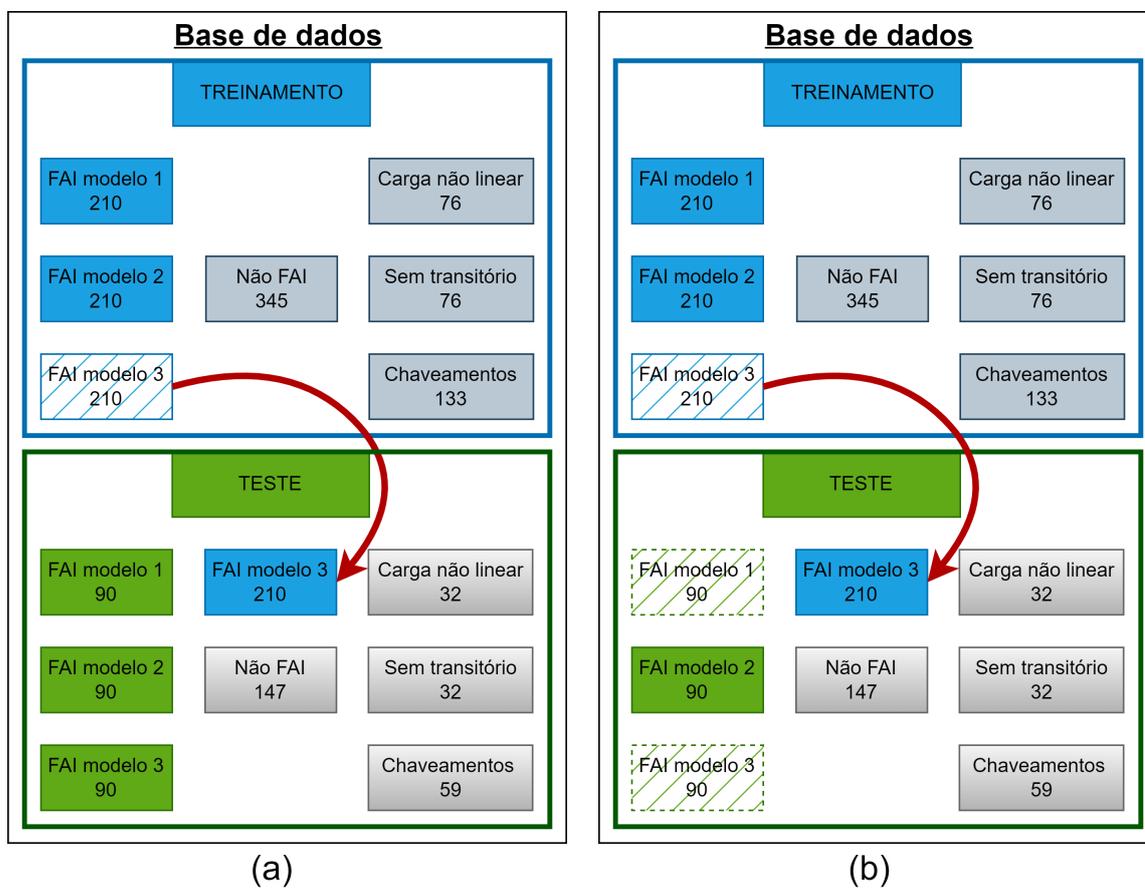
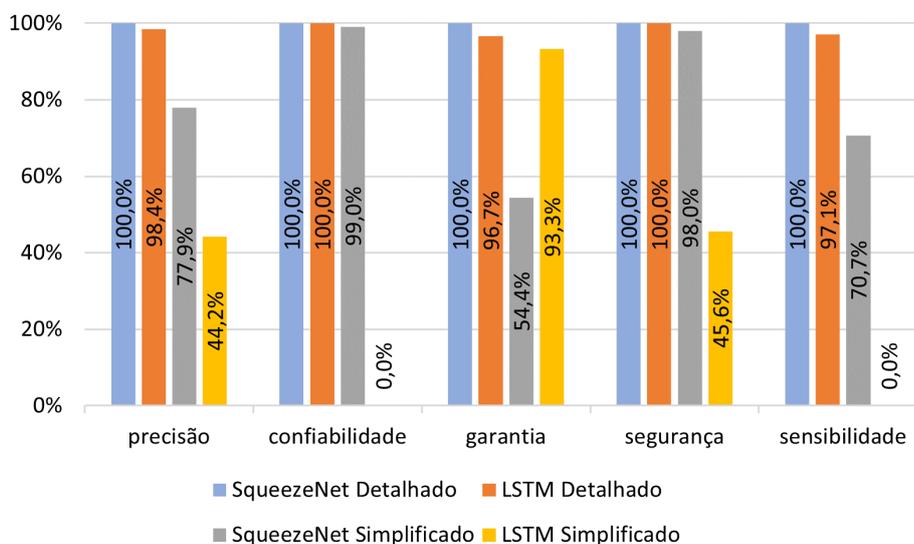


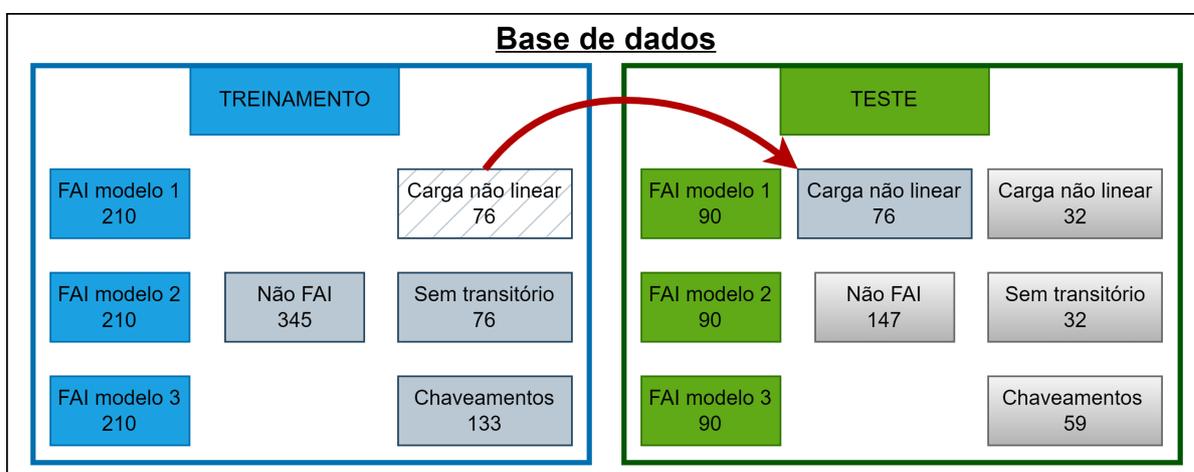
Figura 50 – Índices de desempenho para o teste 1 da FAI modelo 3.



5.4 CARGA NÃO LINEAR

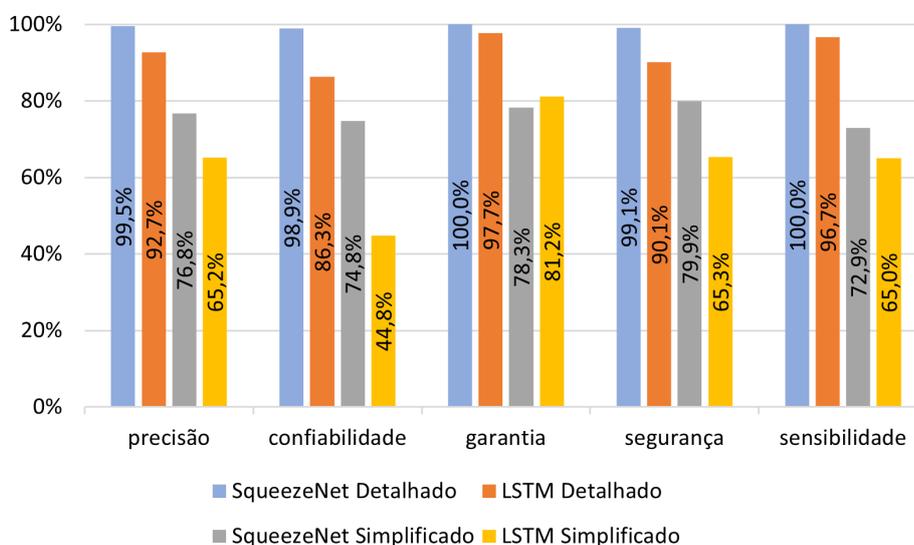
As cargas não lineares foram mencionadas anteriormente na seção 4.2.2 como tendo características semelhantes às FAI. Como estes transientes só aparecem nos dados de testes, os classificadores utilizados neste teste não foram treinados com eles. No teste com a base de dados completa, haviam 76 casos de chaveamento de carga não linear para treinamento e 32 para testes, mas agora todos foram incluídos apenas no conjunto de testes, destacado na Figura 51.

Figura 51 – Base de dados para treinamento e teste utilizada no teste para carga não linear.



O desempenho dos dois classificadores detalhados foi muito semelhante ao primeiro teste, como observado na Figura 52. Assim, é possível confirmar que o chaveamento de carga não linear não resulta em classificação errada, apesar de compartilhar características com a FAI. Os classificadores simples obtiveram resultados ligeiramente melhores em comparação com o primeiro teste. Mesmo assim, devido ao seu baixo desempenho, não é viável utilizá-los em aplicações reais.

Figura 52 – Índices de desempenho para o teste da carga não linear.

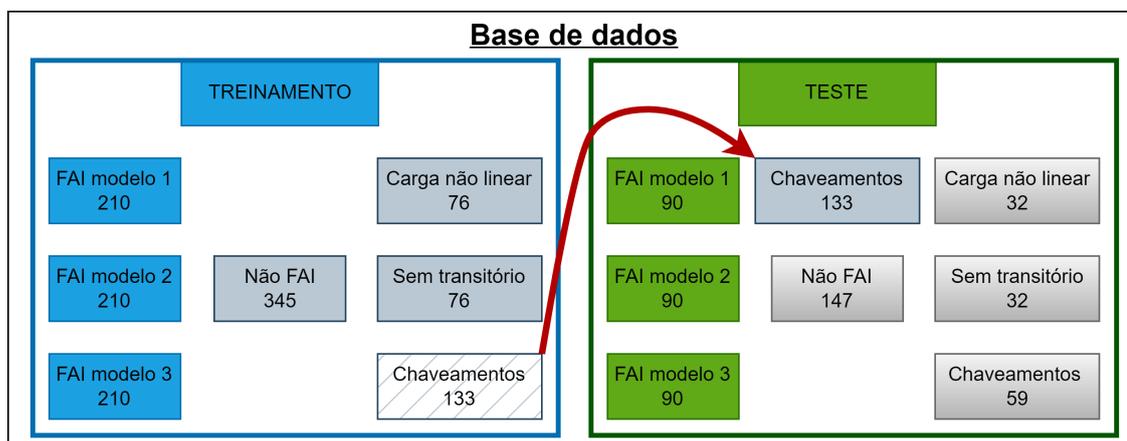


5.5 CHAVEAMENTO DE LINHAS DE DISTRIBUIÇÃO

O objetivo deste teste é verificar se a mudança dos arranjos da MR, após o fechamento ou abertura das chaves seccionadoras S2 e S3, causam erros de classificação. Muitas técnicas de detecção de FAI consideram sistemas de distribuição radial, e portanto, não levam em conta este tipo de cenário.

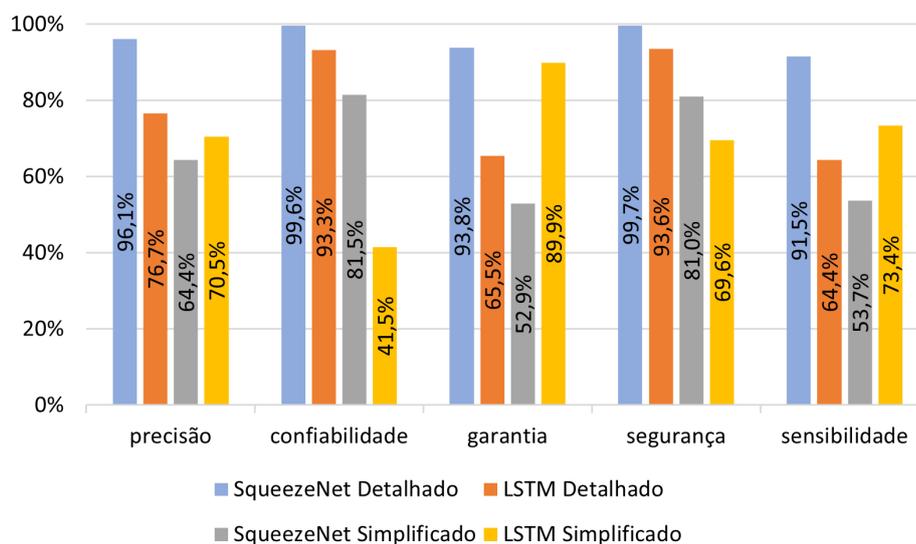
Na Figura 53 é apresentada a composição deste banco de dados. São 1027 casos (630 FAI 397 não FAI) e para testes são 570 casos (270 FAI 403 não FAI). Os dados da simulação de comutação de linha de transmissão foram todos incluídos no conjunto de teste e removidos do conjunto de treinamento.

Figura 53 – Base de dados para treinamento e teste utilizada no teste de chaveamento das linhas da MR.



Os índices avaliados produziram as notas mais baixas para o classificador detalhado *SqueezeNet* mostrado na Figura 54. Estes índices, entretanto, superam o melhor desempenho que o classificador LSTM (VEERASAMY *et al.*, 2021) conseguiu atingir.

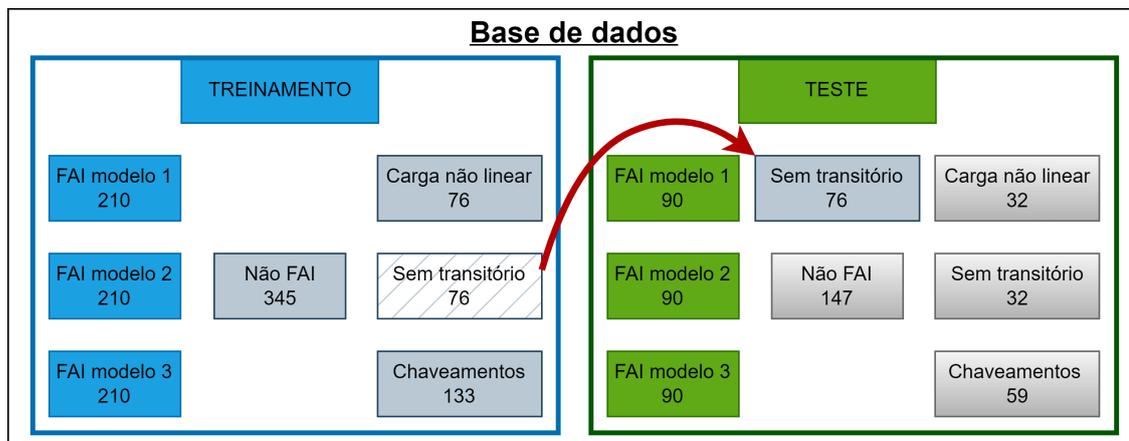
Figura 54 – Índices de desempenho para o teste de chaveamento das linhas da MR.



5.6 SIMULAÇÕES SEM TRANSITÓRIOS

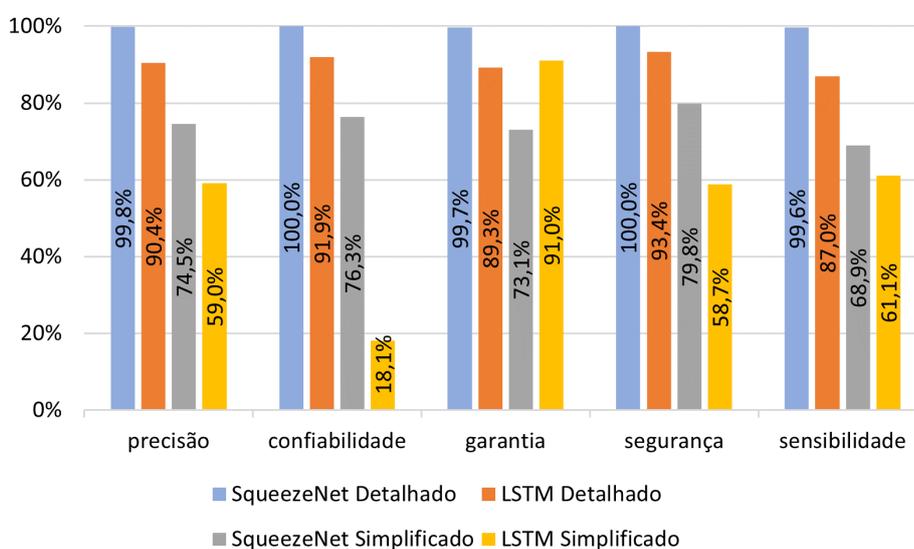
Uma MR nem sempre apresenta transitórios evidentes ou distúrbios visíveis. Portanto, testar o método em cenários sem transitórios é relevante, não apenas em casos ideais ou onde transitórios são frequentes dada a natureza das FAIs. Este teste tem como objetivo avaliar se o método proposto apresenta alguma degradação na sua performance se a base de dados de treinamento não apresentar casos sem transitórios, conforme Figura 55, dado que quando o método identifica uma FAI que não existe, há uma interrupção desnecessária do suprimento de energia elétrica.

Figura 55 – Base de dados para treinamento e teste utilizada no teste sem transitório.



As métricas de desempenho do teste onde o classificador SqueezeNet não utiliza cenários sem transitórios para treinamento estão na Figura 56. Houve uma ligeira degradação em relação ao classificador SqueezeNet treinado com a base de dados completa, pois a garantia diminuiu (99,7% em vez de 100%), o que significa classificação de casos incorretamente como FAI. Assim como em todos os testes anteriores, o classificador LSTM (VEERASAMY *et al.*, 2021) detalhado apresenta um desempenho inferior ao método proposto. No entanto, o classificador LSTM detalhado tem desempenho consideravelmente melhor relação ao classificador SqueezeNet Simplificado. Isto reforça a necessidade de modelos detalhados e realistas de simulação na construção de métodos de detecção de FAI.

Figura 56 – Índices de desempenho para o teste sem transitório.

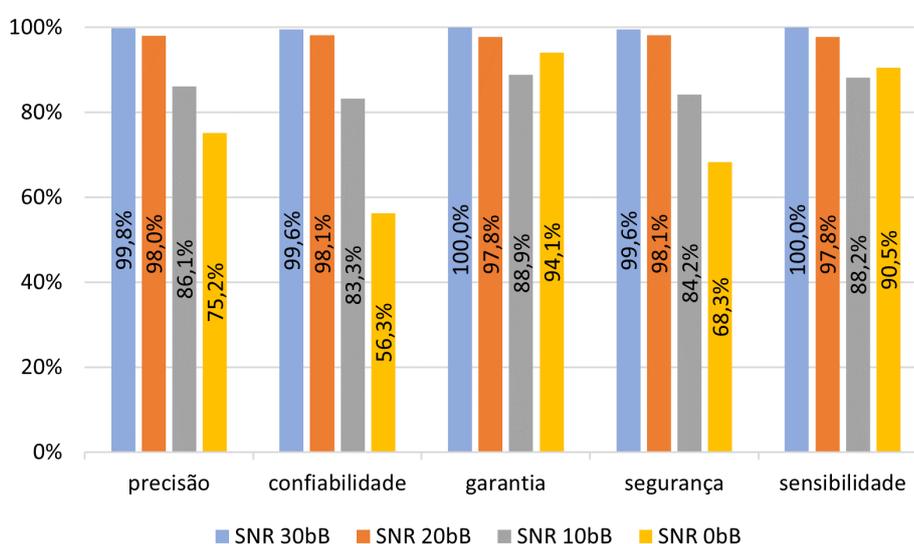


5.7 SIMULAÇÕES COM ADIÇÃO DE RUÍDO NAS MEDIDAS

Neste teste os casos simulados tiveram as medidas distorcidas por ruído branco gaussiano para avaliar o método proposto em ambiente ruidoso. O ruído branco é um sinal aleatório com igual potência em todas as frequências (BARRETO *et al.*, 2021).

Foi utilizada a função *awgn*, disponível no *software* MatLab, para adicionar aos sinais de corrente ruídos com a relação SNR de 0 dB, 10 dB, 20 dB e 30 dB. No primeiro teste o classificador detalhado *SqueezeNet*, treinado com a base de dados completa sem ruído, realiza a classificação na base de dados completa para teste com a presença de ruído, apresentado na Figura 57,

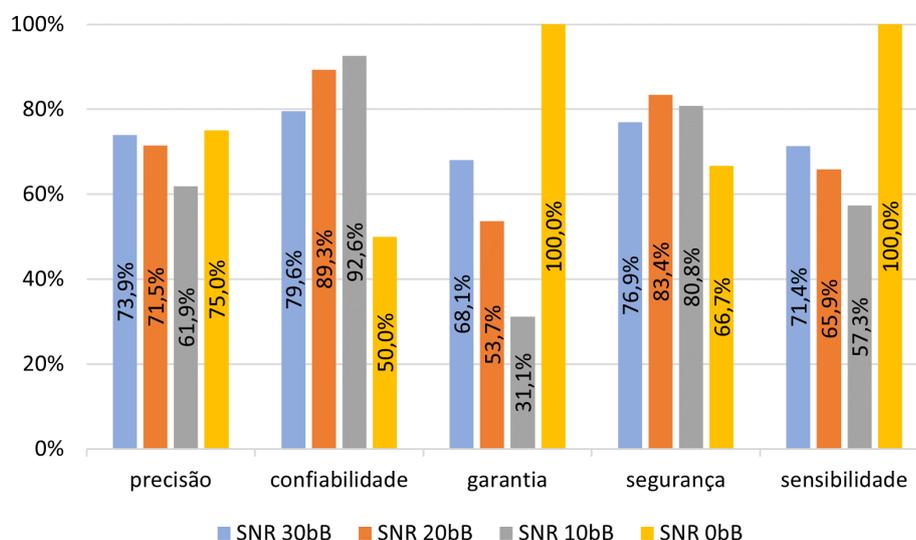
Figura 57 – Índices de desempenho do modelo detalhado para resiliência a ruído.



O método de classificação mostra pouca degradação no desempenho para uma relação SNR de 30 dB e 20 dB. Para este nível de ruído, o método apresenta um desempenho, robustez e confiabilidade consistentes com as aplicações reais.

A Figura 58 apresenta os resultados do teste SNR do classificador *SqueezeNet* simplificado. É possível observar que a elevação do ruído não foi causador de grande degradação no desempenho em relação ao classificador treinado. Estes resultados corroboram a tese aqui defendida, que mesmo em aplicações com um nível aceitáveis de ruído, o seu desempenho não prejudicado.

Figura 58 – Índices de desempenho do modelo simplificado para resiliência a ruído.



5.8 AVALIAÇÃO COMPARATIVA DE DESEMPENHO

Os índices para avaliação de desempenho, apresentados na seção 4.5.1, são utilizados na comparação dos resultados para abordagens de detecção de FAI de última geração, apresentadas na Tabela 10. As taxas da abordagem Proposta foram ligeiramente inferiores às da (RAMESHRAO *et al.*, 2022), embora este método exija sete pontos de medição de corrente.

As abordagens (AHMADI *et al.*, 2022; LIMA *et al.*, 2021; VEERASAMY *et al.*, 2021) empregam apenas um ponto com medição de corrente, semelhante ao método Proposto, mas para (MUMTAZ *et al.*, 2022), foram necessários dez pontos de medição de tensão e corrente, conforme apresentado na Tabela 11.

Tabela 10 – Avaliação comparativa com os índices de desempenho.

item	Método	Precisão	Confiabilidade	Garantia	Segurança	Sensibilidade
1	(AHMADI <i>et al.</i> , 2022)	99,23%	99,17%	100%	90,91%	100%
2	(MUMTAZ <i>et al.</i> , 2022)	91,60%	-	-	-	-
3	(RAMESHRAO <i>et al.</i> , 2022)	99,66%	99,73%	99,29%	-	-
4	(LIMA <i>et al.</i> , 2021)	99,35%	99,35%	100%	89,55%	100%
5	(VEERASAMY <i>et al.</i> , 2021)	91,21%	92,42%	90,63%	95,87%	83,56%
6	(SANGEETH; VINOD, 2023)	94,33%	95,36%	93,29%	95,21%	93,51%
7	(RAI <i>et al.</i> , 2022)	100,00%	-	-	-	-
8	(CHANDRA <i>et al.</i> , 2023)	98,89%	99,20%	98,70%	99,53%	97,81%
9	(MISHRA; ROUT, 2017)	96,39%	100,00%	-	-	-
10	Proposto Detalhado	99,65%	99,30%	100,00%	99,30%	100,00%

O modo de operação em ilha do sistema de teste não foi considerado em (MUMTAZ *et al.*, 2022; RAMESHRAO *et al.*, 2022; VEERASAMY *et al.*, 2021), e (AHMADI

et al., 2022; LIMA *et al.*, 2021) não levam em consideração o ruído. Os conjuntos de dados de teste também apresentam um desequilíbrio significativo de classes, com amostras em (AHMADI *et al.*, 2022) consistindo de 120 FAI e 10 não FAI, em (LIMA *et al.*, 2021) consistindo de 928 FAI e 54 não FAI, e em (VEERASAMY *et al.*, 2021) consistindo de 66 FAI e 128 não FAI, conforme mostrado na Tabela 11. Visto que os índices de avaliação para as abordagens comparadas têm valores bastante similares, todos os fatores mencionados acima devem ser levados em consideração.

Os detalhes referentes ao tipo de dados de entrada e ao tamanho das amostras para os conjuntos de dados de treinamento e teste podem ser encontrados na Tabela 11. Em (MUMTAZ *et al.*, 2022), o número de amostras para testes não é apresentado.

Tabela 11 – Informação das base de dados.

item	Método	Teste - FAI/nãoFAI	Treinamento - FAI/nãoFAI	Quantidade e tipo de medição
1	(AHMADI <i>et al.</i> , 2022)	120 / 10	- / -	1 Corrente
2	(MUMTAZ <i>et al.</i> , 2022)	- / -	- / -	10 Correntes e tensão
3	(RAMESHRAO <i>et al.</i> , 2022)	14.817/15.805	34.575/36.879	7 Correntes
4	(LIMA <i>et al.</i> , 2021)	928/54	97/6	1 Corrente
5	(VEERASAMY <i>et al.</i> , 2021)	66/128	706/264	1 Corrente
6	(SANGEETH; VINOD, 2023)	30	270	1 Corrente
7	(RAI <i>et al.</i> , 2022)	1098/218	274/54	1 Corrente
8	(CHANDRA <i>et al.</i> , 2023)	2.250/3.850	- / -	33 Correntes
9	(MISHRA; ROUT, 2017)	132/215	1050/1720	15 Correntes
10	Proposto	270/270	900/360	1 Corrente

6 CONCLUSÕES E TRABALHOS FUTUROS

Um método de detecção de FAI baseado na representação de imagem bidimensionais do tipo RGB e rede neural convolucional com aprendizagem por transferência são utilizados nesse trabalho para solução do problema específico em MR. Uma ênfase é dada ao impacto da modelagem de simulação das FAIs e dos GDs no desempenho da classificação quando se considera as distorções harmônicas causadas pelos GDs baseados em VSC. Esta integração de recursos energéticos distribuídos, com interface via dispositivos de eletrônica de potência, já é um cenário presente nos SDE atuais e tende a se intensificar rapidamente nos próximos anos.

As simulações consideram modelos detalhados de GD e três modelos diferentes de FAI. Medidas de corrente trifásica são agrupadas formando uma única série temporal aplicando o cálculo da corrente residual. Os eventos transitórios testados foram classificados em FAI ou não FAI por um algoritmo de reconhecimento de padrões computacionalmente sofisticado empregando imagens bidimensionais do tipo RGB, que representam as propriedades de frequência temporal do sinal da corrente medida. Cinco índices de avaliação, que representam um conjunto mais abrangente de critérios de avaliação, são empregados para mostrar o resultado da classificação.

Os resultados indicam que para obter um melhor desempenho dos métodos de detecção FAI em MR, eles precisam levar em conta modelos de simulação detalhados. Um modelo de simulação livre de componentes harmônicos não é uma suposição realista para MR com GDs baseados em VSC. Adicionalmente, o modelo FAI deve reproduzir este fenômeno da forma mais precisa possível, a fim de obter um bom desempenho em aplicações reais. Assim, os resultados demonstram a necessidade de modelos de simulação mais precisos a fim de se obter uma melhor detecção de FAI.

Três modelos FAI diferentes e transitórios não FAI foram usados em uma série de sete testes. Para todas as condições avaliadas, o classificador proposto superou uma metodologia recente de detecção de FAI, demonstrando sua eficiência. Os resultados demonstraram a robustez da metodologia proposta, indicando que nem o *overfitting* ou *underfitting* ocorreram durante a detecção de FAI de modelos para os quais ela não foi treinada.

A RNP SqueezeNet pré-treinada no banco de imagens ImageNet, tem tamanho reduzido em comparação às outras disponíveis e, mesmo assim, apresentou bom desempenho. Isto permite desenvolver soluções de baixo custo, embarcando o modelo em dispositivos do tipo *edge devices* que tem menor potência, espaço de memória e poder de processamento. A SqueezeNet foi desenvolvida especificamente para mitigar essas restrições de capacidade.

6.1 PROPOSTA PARA TRABALHOS FUTUROS

Trabalhos futuros podem explorar a integração de medidas em mais de um ponto da MR. Essas medidas podem ser do tipo sincronizadas com a utilização de PMUs (CUI; WENG, 2020; DELA TORRE; PEDRASA, 2020; KANTRA *et al.*, 2016). A combinação de medidas de corrente com tensão também pode ser analisada, levando-se em conta as características do sistema. Entretanto, é preciso avaliar se um possível aumento no desempenho de detecção é compensado por uma maior quantidade de dados a serem processados. Este aumento de recursos, maior quantidade de pontos de medição e capacidade de processamento, pode ser contornada se, além da detecção de FAI, a técnica agregar a capacidade de localização desta falta dentro da MR.

Na literatura existem muitos modelos para simulação de FAI, com diferentes graus de complexidade e empirismo. A ampliação de modelos avaliados e aplicados auxilia na ampliação e variedade da base de dados para técnicas que se baseiam em IA. A utilização de dados oscilográficos reais de FAI em redes de distribuição ou de ensaios em laboratório não estão facilmente disponíveis. Mas a sua utilização seria extremamente benéfica uma vez que este tipo de estudo é raro na literatura. Normalmente, trabalhos que utilizam dados reais se propõem prioritariamente a desenvolver modelos de FAI com alguma técnica de detecção como contribuição secundária.

Ampliar a quantidade de variedade de modelos de GD utilizados também é uma oportunidade. Os modelos utilizados neste trabalho se comportam como fontes de corrente, quando a MR está operando em modo ilhado e conectado. Avaliar um método de detecção FAI em uma MR ou SDE constituídos predominantemente, ou exclusivamente, geradores do tipo VSC é algo que não foi testado neste trabalho tão pouco encontrado na literatura. O sistema teste também pode levar em consideração operação com desequilíbrio entre as fases e também alguns ramais de distribuição monofásica.

REFERÊNCIAS

ABIODUN, O. I. *et al.* Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition. **IEEE Access**, v. 7, p. 158820–158846, out. 2019. ISSN 2169-3536. DOI: 10.1109/ACCESS.2019.2945545.

ABOUL-ZAHAB, E. M.; TAG ELDIN, E. S.; IBRAHIM, D. k.; SALEH, S. M. High impedance fault detection in mutually coupled double-ended transmission lines using high frequency disturbances, p. 412–419, 2008. DOI: 10.1109/MEPCON.2008.4562362.

ACKERMANN, Thomas; ANDERSSON, Göran; SÖDER, Lennart. Distributed generation: a definition. **Electric Power Systems Research**, v. 57, n. 3, p. 195–204, 2001. ISSN 0378-7796. DOI: [https://doi.org/10.1016/S0378-7796\(01\)00101-8](https://doi.org/10.1016/S0378-7796(01)00101-8).

AHMADI, Ali; AGHAJARI, Ebrahim; ZANGENEH, Mehdi. High-impedance fault detection in power distribution grid systems based on support vector machine approach. **Electrical Engineering**, Springer, p. 1–14, mai. 2022. DOI: <https://doi.org/10.1007/s00202-022-01544-1>.

ALI, Mohd Syukri; ABU BAKAR, Ab Halim; MOKHLIS, Hazlie; AROF, Hamzah; AZIL ILLIAS, Hazlee. High-impedance fault location using matching technique and wavelet transform for underground cable distribution network. **IEEJ Transactions on Electrical and Electronic Engineering**, Wiley Online Library, v. 9, n. 2, p. 176–182, 2014. DOI: 10.1002/tee.21953.

ALMALKI, Mishari Metab. A Proposed Fault Detection Using Continues Wavelet Transform and Transfer Learning via AlexNet. *In*: 2022 IEEE 13th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON). [S.l.: s.n.], out. 2022. P. 0124–0131. DOI: 10.1109/UEMCON54665.2022.9965725.

ANEEL, Agência Nacional de Energia Elétrica. **Módulo 1 – Glossário de Termos Técnicos do PRODIST**. [S.l.: s.n.], jan. 2022a. Disponível em: https://www2.aneel.gov.br/cedoc/aren2021956_2.pdf.

ANEEL, Agência Nacional de Energia Elétrica. **Módulo 8 – Qualidade do Fornecimento de Energia Elétrica**. [S.l.: s.n.], jan. 2022b. Disponível em: https://www2.aneel.gov.br/cedoc/aren2021956_2_7.pdf.

- ANEEL, Agência Nacional de Energia Elétrica. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST**. [S.l.: s.n.], jan. 2022c. Disponível em: <https://www2.aneel.gov.br/cedoc/ren2021956.html>.
- AUCOIN, B. M.; JONES, R. H. High impedance fault detection implementation issues. **IEEE Transactions on Power Delivery**, v. 11, n. 1, p. 139–148, 1996. DOI: 10.1109/61.484010.
- AUCOIN, B. M.; RUSSELL, B. D. Distribution High Impedance Fault Detection Utilizing High Frequency Current Components. **IEEE Transactions on Power Apparatus and Systems**, PAS-101, n. 6, p. 1596–1606, 1982. DOI: 10.1109/TPAS.1982.317209.
- AUCOIN, M.; ZEIGLER, J.; RUSSELL, B. D. Feeder Protection and Monitoring System, Part I: Design, Implementation and Testing. **IEEE Transactions on Power Apparatus and Systems**, PAS-104, n. 4, p. 873–880, 1985a. DOI: 10.1109/TPAS.1985.319088.
- AUCOIN, M.; ZEIGLER, J.; RUSSELL, B. D. Feeder Protection and Monitoring System, Part II: Staged Fault Test Demonstration. **IEEE Transactions on Power Apparatus and Systems**, PAS-104, n. 6, p. 1455–1462, 1985b. DOI: 10.1109/TPAS.1985.319160.
- AUCOIN, Mike. Status of High Impedance Fault Detection. **IEEE Transactions on Power Apparatus and Systems**, PAS-104, n. 3, p. 637–644, 1985. DOI: 10.1109/TPAS.1985.318999.
- AZIM, Riyasat; LI, Fangxing; XUE, Yaosuo; STARKE, Michael; WANG, Honggang. An islanding detection methodology combining decision trees and Sandia frequency shift for inverter-based distributed generations. **IET Generation, Transmission & Distribution**, v. 11, n. 16, p. 4104–4113, 2017. DOI: <https://doi.org/10.1049/iet-gtd.2016.1617>.
- AZIZ, M. S. Abdel; HASSAN, M. A. Moustafa; ZAHAB, E. A. High-impedance Faults Analysis in Distribution Networks Using an Adaptive Neuro Fuzzy Inference System. **Electric Power Components and Systems**, Taylor & Francis, v. 40, n. 11, p. 1300–1318, 2012. DOI: 10.1080/15325008.2012.689418.
- BAKAR, Ab Halim Abu; ALI, MS; TAN, ChiaKwang; MOKHLIS, Hazlie; AROF, Hamzah; ILLIAS, HA. High impedance fault location in 11 kV underground distribution systems using wavelet transforms. **International Journal of Electrical Power & Energy**

Systems, Elsevier, v. 55, p. 723–730, fev. 2014. ISSN 0142-0615. DOI:

<https://doi.org/10.1016/j.ijepes.2013.10.003>.

BANEJAD, M.; IJADI, H. High impedance fault detection: Discrete wavelet transform and fuzzy function approximation. **Journal of AI and Data Mining**, Shahrood University of Technology, v. 2, n. 2, p. 149–158, 2014. ISSN 2322-5211. DOI: 10.22044/jadm.2014.306.

BARRETO, Nathan Elias Maruch; RODRIGUES, Rafael; SCHUMACHER, Ricardo; AOKI, Alexandre Rasi; LAMBERT-TORRES, Germano. Artificial Neural Network Approach for Fault Detection and Identification in Power Systems with Wide Area Measurement Systems. **Journal of Control, Automation and Electrical Systems**, v. 32, n. 6, p. 1617–1626, 2021. ISSN 2195-3899. DOI: 10.1007/s40313-021-00785-y.

BEHESHTAEIN, Siavash; CUZNER, Robert; SAVAGHEBI, Mehdi; GUERRERO, Josep M. Review on microgrids protection. **IET Generation, Transmission & Distribution**, v. 13, n. 6, p. 743–759, 2019. DOI: <https://doi.org/10.1049/iet-gtd.2018.5212>.

BELLIDO, Marlon Max Huamaní. **Microrredes elétricas: uma proposta de implementação no Brasil**. Mar. 2018. Tese (Doutorado) – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia(COPPE). Disponível em: <http://hdl.handle.net/11422/12277>.

BENYAHIA, Zakaria; HEFNAWI, Mostafa; ABOULFATAH, Mohamed; ABDELMOUNIM, Elhassane; GADI, Taoufiq. SqueezeNet-Based Range, Angle, and Doppler Estimation for Automotive MIMO Radar Systems. *In: 2022 International Conference on Intelligent Systems and Computer Vision (ISCV)*. [S.l.: s.n.], 2022. P. 1–5. DOI: 10.1109/ISCV54655.2022.9806088.

BOUCKAERT, Stéphanie; PALES, Araceli Fernandez; MCGLADE, Christophe; REMME, Uwe; WANNER, Brent; VARRO, Laszlo; D'AMBROSIO, Davide; SPENCER, Thomas. Net zero by 2050: A roadmap for the global energy sector. **International Energy Agency**, p. 224, set. 2021. Disponível em: <https://iea.blob.core.windows.net/assets/063ae08a-7114-4b58-a34e-39db2112d0a2/NetZeroBy2050-ARoadmapfortheGlobalEnergySector.pdf>.

C6.04.02, Barsali S.; CIGRE TF. Benchmark systems for network integration of renewable and distributed energy resources. **CIGRE Technical Brochure 575**, 2014.

- CALHOUN, H.; BISHOP, M. T.; EICHLER, C. H.; LEE, R. E. Development and Testing of an Electro-Mechanical Relay to Detect Fallen Distribution Conductors. **IEEE Transactions on Power Apparatus and Systems**, PAS-101, n. 6, p. 1643–1650, 1982. DOI: 10.1109/TPAS.1982.317214.
- CARPENTER, M.; HOAD, R. R.; BRUTON, T. D.; DAS, R.; KUNSMAN, S. A.; PETERSON, J. M. Staged-fault testing for high impedance fault data collection, p. 9–17, abr. 2005. DOI: 10.1109/CPRE.2005.1430417.
- CARR, J. Detection of High Impedance Faults on Multi-Grounded Primary Distribution Systems. **IEEE Transactions on Power Apparatus and Systems**, PAS-100, n. 4, p. 2008–2016, 1981. DOI: 10.1109/TPAS.1981.316556.
- CHAITANYA, Bokka Krishna; YADAV, Anamika; PAZOKI, Mohammad. An Intelligent Detection of High-Impedance Faults for Distribution Lines Integrated With Distributed Generators. **IEEE Systems Journal**, v. 14, n. 1, p. 870–879, 2020. DOI: 10.1109/JSYST.2019.2911529.
- CHANDRA, Ankan; SINGH, Girish Kumar; PANT, Vinay. A Novel High Impedance Fault Detection Strategy for Microgrid Based on Differential Energy Signal of Current Signatures and Entropy Estimation. **Electric Power Components and Systems**, Taylor & Francis, p. 1–23, 2023.
- CHEN, J. C.; PHUNG, B. T.; ZHANG, D.; BLACKBURN, T. R.; AMBIKAI RAJAH, E. Arcing current features extraction using wavelet transform, p. 221–224, 2014. DOI: 10.1109/ISEIM.2014.6870758.
- CHOWDHURY, S; CROSSLEY, P. **Microgrids and active distribution networks**. Stevenage: The Institution of Engineering e Technology, 2009. ISBN 9781849191029. Disponível em: <http://cds.cern.ch/record/1608519>.
- CHOWDHURY, S.; CHOWDHURY, S. P.; CROSSLEY, P. **Microgrids and Active Distribution Networks**. [S.l.]: Institution of Engineering e Technology, 2009. (Energy Engineering). ISBN 9781849190145. DOI: 10.1049/PBRN006E.
- COMMISSION, Communication from the *et al.* Delivering the internal electricity market and making the most of public intervention. **Brussels**, v. 5, p. 16, nov. 2013. Disponível em: https://ec.europa.eu/energy/sites/ener/files/documents/com_2013_public_intervention_en_0.pdf.

- COUTO, Vitor Fernando; MORETO, Miguel. High Impedance Fault Detection on Microgrids Considering the Impact of VSC Based Generation. **IEEE Access**, p. 1–1, 2023. DOI: 10.1109/ACCESS.2023.3305958.
- CUI, Qiushi; EL-ARROUDI, Khalil; JOOS, Geza. An effective feature extraction method in pattern recognition based high impedance fault detection. *In: 2017 19th International Conference on Intelligent System Application to Power Systems (ISAP)*. [S.l.: s.n.], set. 2017. P. 1–6. DOI: 10.1109/ISAP.2017.8071380.
- CUI, Qiushi; EL-ARROUDI, Khalil; WENG, Yang. A Feature Selection Method for High Impedance Fault Detection. **IEEE Transactions on Power Delivery**, v. 34, n. 3, p. 1203–1215, 2019. DOI: 10.1109/TPWRD.2019.2901634.
- CUI, Qiushi; WENG, Yang. Enhance High Impedance Fault Detection and Location Accuracy via μ -PMUs. **IEEE Transactions on Smart Grid**, v. 11, n. 1, p. 797–809, jan. 2020. ISSN 1949-3061. DOI: 10.1109/TSG.2019.2926668.
- DAQING HOU. Detection of high-impedance faults in power distribution systems, p. 85–95, 2007. DOI: 10.1109/PSAMP.2007.4740902.
- DE ARAÚJO, Antônio EA; NEVES, Washington LA. **Cálculos de transitórios eletromagnéticos em sistemas de energia**. 1. ed. [S.l.]: Editora UFMG, 2005. ISBN 85-7041-448-x.
- DE LA REE, J.; CENTENO, V.; THORP, J. S.; PHADKE, A. G. Synchronized Phasor Measurement Applications in Power Systems. **IEEE Transactions on Smart Grid**, v. 1, n. 1, p. 20–27, 2010. DOI: 10.1109/TSG.2010.2044815.
- DELA TORRE, Lady Joelle C.; PEDRASA, Michael Angelo A. Differentiation of High Impedance Faults from Other Distribution Network Events Using Microsynchronphasor Measurements. *In: SHAHNIA, Farhad; DEILAMI, Sara (Ed.)*. **ICPES 2019**. Singapore: Springer Singapore, 2020. P. 123–131.
- DENG, Jia; DONG, Wei; SOCHER, Richard; LI, Li-Jia; LI, Kai; FEI-FEI, Li. ImageNet: A large-scale hierarchical image database. *In: 2009 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2009. P. 248–255. DOI: 10.1109/CVPR.2009.5206848.

EISSA, M. M.; SOWILAM, G. M. A.; SHARAF, A. M. A New Protection Detection Technique for High Impedance Fault Using Neural Network, p. 146–151, 2006. DOI: 10.1109/LESCPE.2006.280378.

EMANUEL, A.E.; CYGANSKI, D.; ORR, J.A.; SHILLER, S.; GULACHENSKI, E.M. High impedance fault arcing on sandy soil in 15 kV distribution feeders: contributions to the evaluation of the low frequency spectrum. **IEEE Transactions on Power Delivery**, v. 5, n. 2, p. 676–686, abr. 1990. ISSN 1937-4208. DOI: 10.1109/61.53070.

EPE, Empresa de Pesquisa Energética. **Plano Decenal de Expansão de Energia 2030**. [S.l.], 2021. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-2030>.

ESLAMI, Mostafa; JANNATI, Mohsen; TABATABAEI, S. Sepehr. An improved protection strategy based on PCC-SVM algorithm for identification of high impedance arcing fault in smart microgrids in the presence of distributed generation.

Measurement, v. 175, p. 109149, 2021. ISSN 0263-2241. DOI:

<https://doi.org/10.1016/j.measurement.2021.109149>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0263224121001731>.

ETEMADI, AH; SANAYE-PASAND, M. High-impedance fault detection using multi-resolution signal decomposition and adaptive neural fuzzy inference system. **IET generation, transmission & distribution**, IET, v. 2, n. 1, p. 110–118, jan. 2008. ISSN 1751-8695. DOI: 10.1049/iet-gtd:20070120.

FAHIMI, B.; KWASINSKI, A.; DAVOUDI, A.; BALOG, R. S.; KIANI, M. Charge It! **IEEE Power and Energy Magazine**, v. 9, n. 4, p. 54–64, jul. 2011. ISSN 1540-7977. DOI: 10.1109/MPE.2011.941321.

FAN, Rui; YIN, Tianzhixi. Convolutional Neural Network and Transfer Learning for High Impedance Fault Detection. **arXiv: Signal Processing**, 2019.

FARHOUMANDI, Matin; ZHOU, Quan; SHAHIDEHPOUR, Mohammad. A review of machine learning applications in IoT-integrated modern power systems. **The Electricity Journal**, v. 34, n. 1, p. 106879, 2021. Special Issue: Machine Learning Applications To Power System Planning And Operation. ISSN 1040-6190. DOI: <https://doi.org/10.1016/j.tej.2020.106879>.

GAGNON, Richard. **Wind Farm - DFIG Detailed Model**. [S.l.: s.n.], set. 2022.

Disponível em: <https://www.mathworks.com/help/physmod/sps/ug/wind-farm-dfig-detailed-model.html>.

GASHTEROODKHANI, O.A.; MAJIDI, M.; ETEZADI-AMOLI, M. Fire hazard mitigation in distribution systems through high impedance fault detection. **Electric Power Systems Research**, v. 192, p. 106928, 2021. ISSN 0378-7796. DOI:

<https://doi.org/10.1016/j.epsr.2020.106928>.

GAUTAM, Suresh; BRAHMA, Sukumar M. Detection of High Impedance Fault in Power Distribution Systems Using Mathematical Morphology. **IEEE Transactions on Power Systems**, v. 28, n. 2, p. 1226–1234, mai. 2013. ISSN 1558-0679. DOI:

[10.1109/TPWRS.2012.2215630](https://doi.org/10.1109/TPWRS.2012.2215630).

GHADERI, A.; MOHAMMADPOUR, H. A.; GINN, H. L.; SHIN, Y. J. High-Impedance Fault Detection in the Distribution Network Using the Time-Frequency-Based Algorithm. **IEEE Transactions on Power Delivery**, v. 30, n. 3, p. 1260–1268, jun. 2015. ISSN 0885-8977. DOI:

[10.1109/TPWRD.2014.2361207](https://doi.org/10.1109/TPWRD.2014.2361207).

GHADERI, Amin; GINN, Herbert L.; MOHAMMADPOUR, Hossein Ali. High impedance fault detection: A review. **Electric Power Systems Research**, v. 143, p. 376–388, 2017. ISSN 0378-7796. DOI:

<https://doi.org/10.1016/j.epsr.2016.10.021>.

GIRGIS, A. A.; CHANG, W.; MAKRAM, E. B. Analysis of high-impedance fault generated signals using a Kalman filtering approach. **IEEE Transactions on Power Delivery**, v. 5, n. 4, p. 1714–1724, 1990. DOI:

[10.1109/61.103666](https://doi.org/10.1109/61.103666).

GIROUX, Pierre; SYBILLE, Gilbert; OSORIO, Carlos; CHANDRACHOOD, Shripad. **Detailed Model of a 100-kW Grid-Connected PV Array**. [S.l.: s.n.], set. 2022.

Disponível em: <https://www.mathworks.com/help/sps/ug/detailed-model-of-a-100-kw-grid-connected-pv-array.html>.

GOMES, Douglas P. S.; OZANSOY, Cagil; ULHAQ, Anwaar. High-frequency spectral analysis of high impedance vegetation faults on a three-wire system. *In*: 2017

Australasian Universities Power Engineering Conference (AUPEC). [S.l.: s.n.], 2017.

P. 1–5. DOI: [10.1109/AUPEC.2017.8282456](https://doi.org/10.1109/AUPEC.2017.8282456).

GOMES, Douglas P. S.; OZANSOY, Cagil; ULHAQ, Anwaar. High-Sensitivity Vegetation High-Impedance Fault Detection Based on Signal's High-Frequency

Contents. **IEEE Transactions on Power Delivery**, v. 33, n. 3, p. 1398–1407, 2018. DOI: 10.1109/TPWRD.2018.2791986.

GOMES, Douglas P.S.; OZANSOY, Cagil; ULHAQ, Anwaar; DE MELO VIEIRA JÚNIOR, José Carlos. The effectiveness of different sampling rates in vegetation high-impedance fault classification. **Electric Power Systems Research**, v. 174, p. 105872, 2019. ISSN 0378-7796. DOI:

<https://doi.org/10.1016/j.epsr.2019.105872>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0378779619301853>.

GOMES, Douglas Pinto Sampaio; OZANSOY, Cagil. VeHIF: An Accessible Vegetation High-Impedance Fault Data Set Format. **IEEE Transactions on Power Delivery**, v. 37, n. 6, p. 5473–5475, 2022. DOI: 10.1109/TPWRD.2022.3195002.

GONZÁLEZ, Pedro; ROMERO, Enrique; MIÑAMBRES, Victor M; GUERRERO, Miguel A. Experimental tests of High Impedance Faults in MV rural distribution network, p. 1–10, 2014. DOI: 10.1109/OPTIM.2014.6851019.

GU, Jyh-Cherng; HUANG, Zih-Jhe; WANG, Jing-Min; HSU, Lin-Chen; YANG, Ming-Ta. High Impedance Fault Detection in Overhead Distribution Feeders Using a DSP-Based Feeder Terminal Unit. **IEEE Transactions on Industry Applications**, v. 57, n. 1, p. 179–186, 2021. DOI: 10.1109/TIA.2020.3029760.

GURURAJAPATHY, SS; MOKHLIS, Hazlie; ILLIAS, Hazlee Azil. Fault location and detection techniques in power distribution systems with distributed generation: A review. **Renewable and sustainable energy reviews**, Elsevier, v. 74, p. 949–958, 2017. ISSN 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2017.03.021>.

HAMANAHA, Waleed M.; HOSSAIN, Md Ismail; SHAFIULLAH, Md; ABIDO, M. A. AC Microgrid Protection Schemes: A Comprehensive Review. **IEEE Access**, v. 11, p. 76842–76868, 2023. DOI: 10.1109/ACCESS.2023.3298306.

HASSAN, Mohammed A.; BAYOUMI, Abdel-Moez E.; SHIN, Yong-June. Quadratic-Nonlinearity Index Based on Bicoherence and its Application in Condition Monitoring of Drive-Train Components. **IEEE Transactions on Instrumentation and Measurement**, v. 63, n. 3, p. 719–728, mar. 2014. ISSN 1557-9662. DOI: 10.1109/TIM.2013.2280488.

HEMAPALA, KTM Udayanga; PERERA, MK. **Smart Microgrid Systems: Advanced Technologies**. 1. ed. [S.l.]: CRC Press, 2022. ISBN 978- 1- 003- 21629- 2. DOI: 10.1201/9781003216292.

HEN-GEUL YEY; DUC HOAI TRAN; YINGER, R. High impedance fault detection using orthogonal transforms, p. 67–72, 2014. DOI: 10.1109/IGESC.2014.7018642.

HONG, Ying-Yi; HUANG, Wei-Shun. Locating High-Impedance Fault Section in Electric Power Systems Using Wavelet Transform, K-Means, Genetic Algorithms, and Support Vector Machine. **Mathematical Problems in Engineering**, Hindawi, v. 2015, p. 9, out. 2015. DOI: <https://doi.org/10.1155/2015/823720>.

HOU, D.; FISCHER, N. Deterministic High-Impedance Fault Detection and Phase Selection on Ungrounded Distribution Systems, p. 112–122, 2006. DOI: 10.1109/PSAMP.2006.285380.

IANDOLA, Forrest N.; MOSKEWICZ, Matthew W.; ASHRAF, Khalid; HAN, Song; DALLY, William J.; KEUTZER, Kurt. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. **CoRR**, abs/1602.07360, 2016. Disponível em: <http://arxiv.org/abs/1602.07360>.

IBRAHIM, Muhammad Sohail; DONG, Wei; YANG, Qiang. Machine learning driven smart electric power systems: Current trends and new perspectives. **Applied Energy**, v. 272, p. 115237, 2020. ISSN 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2020.115237>.

IEA. **World Energy Outlook 2022**. License: CC BY 4.0 (report); CC BY NC SA 4.0 (Annex A). IEA. 2022. Disponível em: <https://www.iea.org/reports/world-energy-outlook-2022>.

IEEE Draft Guide for the Design of Microgrid Protection Systems. **IEEE P2030.12/D1.4, June 2022**, p. 1–80, 2022.

IRENA, Renewable Energy Statistics. The international renewable energy agency, abu dhabi. **Renewable Power Generation Costs in 2022**, 2023.

JEERINGS, D.I.; LINDERS, J.R. Ground resistance-revisited. **IEEE Transactions on Power Delivery**, v. 4, n. 2, p. 949–956, abr. 1989. ISSN 1937-4208. DOI: 10.1109/61.25575.

- JIAO, Licheng; ZHAO, Jin. A Survey on the New Generation of Deep Learning in Image Processing. **IEEE Access**, v. 7, p. 172231–172263, 2019. ISSN 2169-3536. DOI: 10.1109/ACCESS.2019.2956508.
- JOTA, F.G.; JOTA, P.R.S. High-impedance fault identification using a fuzzy reasoning system. **IEE Proceedings - Generation, Transmission and Distribution**, v. 145, n. 6, 656–662(6), 6 nov. 1998. DOI: 10.1049/ip-gtd:19982358.
- JOTA, Patricia R.S.; JOTA, Fábio G. Fuzzy detection of high impedance faults in radial distribution feeders. **Electric Power Systems Research**, v. 49, n. 3, p. 169–174, 1999. ISSN 0378-7796. DOI: [https://doi.org/10.1016/S0378-7796\(98\)00116-3](https://doi.org/10.1016/S0378-7796(98)00116-3).
- JÚNIOR, Luiz Cera Zanetta. **Transitórios Eletromagnéticos em Sistemas de Potência Vol. 52**. [S.l.]: EdUSP, 2003. v. 52. ISBN 85-314-0755-9.
- KANTRA, Sean; ABDELSALAM, Hany A.; MAKRAM, Elham B. Application of PMU to detect high impedance fault using statistical analysis. *In: 2016 IEEE Power and Energy Society General Meeting (PESGM)*. [S.l.: s.n.], jul. 2016. P. 1–5. DOI: 10.1109/PESGM.2016.7741454.
- KAR, Susmita; SAMANTARAY, S. R.; ZADEH, M. Dadash. Data-Mining Model Based Intelligent Differential Microgrid Protection Scheme. **IEEE Systems Journal**, v. 11, n. 2, p. 1161–1169, 2017. DOI: 10.1109/JSYST.2014.2380432.
- KAR, Susmita; SAMANTARAY, SR. High impedance fault detection in microgrid using maximal overlapping discrete wavelet transform and decision tree, p. 258–263, 2016. DOI: 10.1109/ICEPES.2016.7915940.
- KAR, Susmita; SAMANTARAY, Subhransu Rajan. Time-frequency transform-based differential scheme for microgrid protection. **IET Generation, Transmission & Distribution**, v. 8, n. 2, p. 310–320, 2014. DOI: <https://doi.org/10.1049/iet-gtd.2013.0180>.
- KAUFMANN, R. H.; PAGE, J. C. Arcing Fault Protection for Low-Voltage Power Distribution System - Nature of the Problem. **Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems**, IEEE, v. 79, n. 3, p. 160–165, 1960. DOI: 10.1109/AIEEPAS.1960.4500717.

KAVOUSHI-FARD, Abdollah; NIKKHAH, Saeed; POURBEHZADI, Motahareh; DABBAGHJAMANESH, Morteza; FARUGHIAN, Amir. IoT-based data-driven fault allocation in microgrids using advanced μ PMUs. **Ad Hoc Networks**, v. 119, p. 102520, 2021. ISSN 1570-8705. DOI: <https://doi.org/10.1016/j.adhoc.2021.102520>.

KEYHANI, R.; DERICHE, M.; PALMER, E. A high impedance fault detector using a neural network and subband decomposition. v. 2, 458–461 vol.2, 2001. DOI: 10.1109/ISSPA.2001.950179.

KHANDARE, PM; DEOKAR, SA. Protection of Microgrid From High Impedance Fault Using Differential Relay. **International journal of innovations in engineering research and technology**, v. 2, set. 2015. ISSN 2394-3696.

KHODAYAR, M.; LIU, G.; WANG, J.; KHODAYAR, M. E. Deep learning in power systems research: A review. **CSEE Journal of Power and Energy Systems**, v. 7, n. 2, p. 209–220, mar. 2021. ISSN 2096-0042. DOI: 10.17775/CSEEJPES.2020.02700.

KIM, C.J.; RUSSELL, B.D. Analysis of distribution disturbances and arcing faults using the crest factor. **Electric Power Systems Research**, v. 35, n. 2, p. 141–148, 1995. ISSN 0378-7796. DOI: [https://doi.org/10.1016/0378-7796\(96\)84602-5](https://doi.org/10.1016/0378-7796(96)84602-5).

KOUSKY, Carolyn; GREIG, Katherine; LINGLE, Brett; KUNREUTHER, K. Wildfire cost in California: The role of electric utilities. **Changes**, v. 114, p. 4582–4590, 2018.

LAAKSONEN, H.; HOVILA, P. Enhanced MV microgrid protection scheme for detecting high-impedance faults, p. 1–6, jun. 2017. DOI: 10.1109/PTC.2017.7980899.

LAI, T.M.; SNIDER, L.A.; LO, E.; SUTANTO, D. High-impedance fault detection using discrete wavelet transform and frequency range and RMS conversion. **IEEE Transactions on Power Delivery**, v. 20, n. 1, p. 397–407, jan. 2005. ISSN 1937-4208. DOI: 10.1109/TPWRD.2004.837836.

LASSETER, R. H. MicroGrids. v. 1, 305–308 vol.1, 2002. DOI: 10.1109/PESW.2002.985003.

LASSETER, Robert; AKHIL, Abbas; MARNAY, Chris; STEPHENS, John; DAGLE, Jeff; GUTTROMSOM, Ross; MELIOPOULOUS, A Sakis; YINGER, Robert; ETO, Joe. Integration of distributed energy resources. The CERTS Microgrid Concept, abr. 2002. DOI: 10.2172/799644. Disponível em: <https://www.osti.gov/biblio/799644>.

LAVANYA, S; PRABAKARAN, S; KUMAR, N Ashok. A deep learning technique for detecting high impedance faults in medium voltage distribution networks. **Engineering, Technology & Applied Science Research**, v. 12, n. 6, p. 9477–9482, 2022. DOI: <https://doi.org/10.48084/etasr.5288>.

LAZKANO, A.; RUIZ, J.; ARAMENDI, E.; LETURIONDO, L. A.; GONZALEZ, J. A. Study of high impedance fault detection in Levante area in Spain. v. 3, 1011–1016 vol.3, 2000. DOI: 10.1109/ICHQP.2000.896867.

LAZKANO, Andoni; RUIZ, Jesus; ARAMENDI, Elisabete; LETURIONDO, Luis A. Evaluation of a new proposal for an arcing fault detection method based on wavelet packet analysis. **European transactions on electrical power**, Wiley Online Library, v. 14, n. 3, p. 161–174, 2004. DOI: 10.1002/etep.13.

LEÃO, A. P.; TOSTES, M. E. L.; VIEIRA, J. P. A.; BEZERRA, Ubiratan H.; HERINGER, W. R.; SOUSA, A. L.; CORDEIRO, M. A. M.; PAYE, J. C. H.; SANTOS, M. C. Characteristics of High Impedance Faults in Overhead Distribution Networks in Bamboo Branches. *In: 2020 IEEE PES Transmission & Distribution Conference and Exhibition - Latin America (T&D LA)*. [S.l.: s.n.], 2020. P. 1–6. DOI: 10.1109/TDLA47668.2020.9326100.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015. ISSN 1476-4687. DOI: 10.1038/nature14539. Disponível em: <https://doi.org/10.1038/nature14539>.

LEI, Xusheng; SUI, Zhehao. Intelligent fault detection of high voltage line based on the Faster R-CNN. **Measurement**, Elsevier, v. 138, p. 379–385, jan. 2019. ISSN 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2019.01.072>.

LIMA, Érica Mangureira; ALMEIDA COELHO, Rodrigo de; BRITO, Núbia Silva Dantas; SOUZA, Benemar Alencar de. High impedance fault detection method for distribution networks under non-linear conditions. **International Journal of Electrical Power & Energy Systems**, v. 131, p. 107041, 2021. ISSN 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2021.107041>.

LIMA, Érica Mangureira; BRITO, Núbia Silva Dantas; SOUZA, Benemar Alencar de. High impedance fault detection based on Stockwell transform and third harmonic current phase angle. **Electric Power Systems Research**, v. 175, p. 105931, 2019. ISSN 0378-7796. DOI: <https://doi.org/10.1016/j.epsr.2019.105931>.

LOPES, Gabriela Nunes; LACERDA, Vinicius Albernaz; VIEIRA, Jose Carlos Melo; COURY, Denis Vinicius. Analysis of Signal Processing Techniques for High Impedance Fault Detection in Distribution Systems. **IEEE Transactions on Power Delivery**, v. 36, n. 6, p. 3438–3447, 2021. DOI: 10.1109/TPWRD.2020.3042734.

MARRO, Alessandro; MATHEUS, Alyson; SOUZA, Carvalho; DE, Everton; CAVALCANTE, Sousa; GIULIANA, Silva; BEZERRA, Rômulo; DE, Oliveira; NUNES. Lógica Fuzzy: Conceitos e aplicações. **Natal: Universidade Federal do Rio Grande do Norte (UFRN)**, jan. 2010.

MATLAB. **400-kW Grid-Connected PV Farm (Average Model)**. [S.l.: s.n.], set. 2022a. Disponível em: <https://www.mathworks.com/help/sps/ug/400-kw-grid-connected-pv-farm-average-model.html>.

MATLAB. **Pretrained Deep Neural Networks**. [S.l.: s.n.], set. 2022b. Disponível em: <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>.

MATLAB. **software Simulink**. 9.10.0.1602886 (R2021a). Natick, Massachusetts: The MathWorks Inc., fev. 2021.

MATLAB. **Three-Phase Source**. [S.l.: s.n.], set. 2022c. Disponível em: <https://www.mathworks.com/help/sps/powersys/ref/threephasesource.html>.

MATLAB. **Thyristor Rectifiers example**. [S.l.: s.n.], set. 2022d. Disponível em: <https://www.mathworks.com/help/sps/ug/thyristor-rectifiers.html>.

MATLAB. **What Is a Convolutional Neural Network?** [S.l.: s.n.], set. 2023. Disponível em: <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>.

MCCULLOUGH, Malcolm. **Downtime on the microgrid: Architecture, electricity, and smart city islands**. [S.l.]: MIT Press, 2020. ISBN 9780262357005. DOI: <https://doi.org/10.7551/mitpress/11953.001.0001>.

MEMON, Aushiq Ali; KAUHANIEMI, Kimmo. A critical review of AC Microgrid protection issues and available solutions. **Electric Power Systems Research**, Elsevier, v. 129, p. 23–31, dez. 2015. DOI: <https://doi.org/10.1016/j.epsr.2015.07.006>.

- MILIOUDIS, A. N.; ANDREOU, G. T.; LABRIDIS, D. P. Enhanced Protection Scheme for Smart Grids Using Power Line Communications Techniques—Part I: Detection of High Impedance Fault Occurrence. **IEEE Transactions on Smart Grid**, v. 3, n. 4, p. 1621–1630, 2012a. DOI: [10.1109/TSG.2012.2208987](https://doi.org/10.1109/TSG.2012.2208987).
- MILIOUDIS, A. N.; ANDREOU, G. T.; LABRIDIS, D. P. Enhanced Protection Scheme for Smart Grids Using Power Line Communications Techniques—Part II: Location of High Impedance Fault Position. **IEEE Transactions on Smart Grid**, v. 3, n. 4, p. 1631–1640, 2012b. DOI: [10.1109/TSG.2012.2208988](https://doi.org/10.1109/TSG.2012.2208988).
- MISHRA, Manohar; PANIGRAHI, Rasmi Ranjan. Taxonomy of high impedance fault detection algorithm. **Measurement**, v. 148, p. 106955, 2019. ISSN 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2019.106955>.
- MISHRA, Manohar; ROUT, Pravat Kumar. Detection and classification of micro-grid faults based on HHT and machine learning techniques. **IET Generation, Transmission & Distribution**, IET, v. 12, n. 2, p. 388–397, 2017.
- MISHRA, Manohar; ROUT, Pravat Kumar. Detection and classification of micro-grid faults based on HHT and machine learning techniques. **IET Generation, Transmission & Distribution**, Wiley Online Library, v. 12, n. 2, p. 388–397, 2018. DOI: <https://doi.org/10.1049/iet-gtd.2017.0502>.
- MOHAMMADNIAN, Youness; AMRAEE, Turaj; SOROUDI, Alireza. Fault detection in distribution networks in presence of distributed generations using a data mining–driven wavelet transform. **IET Smart Grid**, v. 2, n. 2, p. 163–171, 2019. DOI: <https://doi.org/10.1049/iet-stg.2018.0158>.
- MORAVEJ, Zahra; MORTAZAVI, Seyed Hamid; SHAHRTASH, Seyed Mohammad. DT-CWT based event feature extraction for high impedance faults detection in distribution system. **International Transactions on Electrical Energy Systems**, v. 25, n. 12, p. 3288–3303, 2015. DOI: <https://doi.org/10.1002/etep.2035>.
- MORETO, Miguel; KURSANCEW KHAIRALLA, Igor. A Voltage Based High Impedance Fault Detection Scheme for Distribution Feeders Using Park and Wavelet Transform. *In*: 2018 Power Systems Computation Conference (PSCC). [S.l.: s.n.], jun. 2018. P. 1–6. DOI: [10.23919/PSCC.2018.8442520](https://doi.org/10.23919/PSCC.2018.8442520).

MORETTO, Evandro Mateus; GOMES, Carina Sernaglia;
ROQUETTI, Daniel Rondinelli; JORDÃO, Carolina de Oliveira. Histórico, tendências e perspectivas no planejamento espacial de usinas hidrelétricas brasileiras: a antiga e atual fronteira Amazônica. pt. **Ambiente & Sociedade**, scielo, v. 15, p. 141–164, dez. 2012. ISSN 1414-753X. DOI: <https://doi.org/10.1590/S1414-753X2012000300009>.

MUMTAZ, Faisal; IMRAN, Kashif; BUKHARI, Syed Basit Ali;
MEHMOOD, Khawaja Khalid; ABUSORRAH, Abdullah; SHAH, Maqsood Ahmad;
KAZMI, Syed Ali Abbas. A Kalman Filter-Based Protection Strategy for Microgrids. **IEEE Access**, v. 10, p. 73243–73256, 2022. DOI: 10.1109/ACCESS.2022.3190078.

MUTH, J; SMITH, E. 45% by 2030, Towards a truly sustainable energy system in the EU. **EREC ARTICLE**, p. 30, mai. 2011.

NAKAGOMI, Renato Mikio. **Proposição de um sistema para simulação de faltas de alta impedância em redes de distribuição**. Out. 2006. Dissertação (Mestrado em Sistemas de Potência) – Universidade de São Paulo. DOI: 10.11606/D.3.2006.tde-15122006-103128.

NAM, S. R.; PARK, J. K.; KANG, Y. C.; KIM, T. H. A modeling method of a high impedance fault in a distribution system using two series time-varying resistances in EMTP. v. 2, 1175–1180 vol.2, jul. 2001. DOI: 10.1109/PESS.2001.970231.

NAYAK, P. K.; SARWAGYA, K.; BISWAL, T. A novel high impedance fault detection technique in distribution systems with distributed generators, p. 1–6, dez. 2016. DOI: 10.1109/NPSC.2016.7858855.

NAZARI-HERIS, Morteza; ASADI, Somayeh; MOHAMMADI-IVATLOO, Behnam; ABDAR, Moloud; JEBELLI, Houtan; SADAT-MOHAMMADI, Milad. **Application of machine learning and deep learning methods to power system problems**. 1. ed. [S.l.]: Springer, 20 out. 2021. ISBN 978-3-030-77696-1. DOI: <https://doi.org/10.1007/978-3-030-77696-1>.

NETO, Giovani Zanetti; COSTA, Wagner Teixeira da;
VASCONCELOS, Vinicius Belmuds. A resolução normativa no 482/2012 da aneel: possibilidades e entraves para a microgeração distribuída. **Revista Brasileira de Energia Solar**, v. 5, n. 2, 2014.

ORTIZ, Leony; ORIZONDO, Rogelio; ÁGUILA, Alexander; GONZÁLEZ, Jorge W; LÓPEZ, Gabriel J; ISAAC, Idi. Hybrid AC/DC microgrid test system simulation: grid-connected mode. **Heliyon**, Elsevier, v. 5, n. 12, 2019.

ORTMAN, MS; ANDRETA, André Gutierrez; CAMURÇA, LJ e; SILVA, VL. Arquitetura e componentes de uma microrrede inteligente experimental, 2015. DOI: 10.13140/RG.2.1.1104.1361.

PAN, Sinno Jialin; YANG, Qiang. A Survey on Transfer Learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p. 1345–1359, 2010. DOI: 10.1109/TKDE.2009.191.

PARHIZI, S.; LOTFI, H.; KHODAEI, A.; BAHRAMIRAD, S. State of the Art in Research on Microgrids: A Review. **IEEE Access**, v. 3, p. 890–925, 2015. ISSN 2169-3536. DOI: 10.1109/ACCESS.2015.2443119.

PARHIZI, Sina; LOTFI, Hossein; KHODAEI, Amin; BAHRAMIRAD, Shay. State of the Art in Research on Microgrids: A Review. **IEEE Access**, v. 3, p. 890–925, 2015. ISSN 2169-3536. DOI: 10.1109/ACCESS.2015.2443119.

PENIDO, Débora Rosana Ribeiro; ARAUJO, Leandro Ramos de; RODRIGUES, Victor T. S.; NASCIMENTO, Kelvin Bryan do. An Analytical Zero Sequence Method to Locate Fault in Distribution Systems Rich in DG. **IEEE Transactions on Smart Grid**, v. 13, n. 3, p. 1849–1859, 2022. DOI: 10.1109/TSG.2022.3141207.

PESQUISA ENERGÉTICA, Empresa de. **Plano Decenal de Expansão de Energia 2027. Empresa de Pesquisa Energética, Ministerio de Minas e Energia., Brasilia, Brazil.** [S.l.]: MME/EPE Brasilia, 2018. Disponível em: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/Documents/PDE%202027_aprovado_OFICIAL.pdf.

POC, Summer Ferreira; BAGGU, Murali; BENT, Russell; LAWRENCE, Miguel Heleno; KING, Tom; SCHNEIDER, Kevin; SINGH, Ravindra; DONDE, Vaibhav. DOE OE 2021 Strategy White Papers on Microgrids: Program Vision, Objectives, and R&D Targets in 5 and 10 years–Topic Area, p. 31, abr. 2021. Disponível em: <https://www.energy.gov/sites/default/files/2022-12/Topic1%20Report.pdf>.

PRADEEP, Kathirgamaraja; KAMALAVASAN, Kamalakkannan; NATHEESAN, Ratnasegar; PASQUAL, Ajith. EdgeNet: SqueezeNet like Convolution Neural Network on Embedded FPGA. *In: 2018 25th IEEE International Conference on Electronics, Circuits and Systems (ICECS)*. [S.l.: s.n.], 2018. P. 81–84. DOI: 10.1109/ICECS.2018.8617876.

RAI, Khushwant; HOJATPANA, Farnam; AJAEI, Firouz Badrkhani; GUERRERO, Josep M; GROLINGER, Katarina. Deep learning for high-impedance fault detection and classification: transformer-CNN. **Neural Computing and Applications**, Springer, v. 34, n. 16, p. 14067–14084, 2022. DOI: <https://doi.org/10.1007/s00521-022-07219-z>.

RAI, Khushwant; HOJATPANA, Farnam; BADRKHANI AJAEI, Firouz; GROLINGER, Katarina. Deep learning for high-impedance fault detection: Convolutional autoencoders. **Energies**, MDPI, v. 14, n. 12, p. 3623, jun. 2021. DOI: <https://doi.org/10.3390/en14123623>.

RAMESHRAO, Awagan Goyal; KOLEY, Ebha; GHOSH, Subhojit. A LSTM-based approach for detection of high impedance faults in hybrid microgrid with immunity against weather intermittency and N-1 contingency. **Renewable Energy**, v. 198, p. 75–90, 2022. ISSN 0960-1481. DOI: <https://doi.org/10.1016/j.renene.2022.08.028>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148122011946>.

RAO, TS Madhava. **Digital/Numerical Relays**. [S.l.]: Tata McGraw-Hill Education, 2005. ISBN 0070588554.

RIBEIRO, Paulo Fernando; DUQUE, Carlos Augusto; RIBEIRO, Paulo Marcio; CERQUEIRA, Augusto Santiago. **Power systems signal processing for smart grids**. [S.l.]: John Wiley & Sons, set. 2014. ISBN 978-1-118-63923-8.

RODRIGUES, Israel Resende A; DE CONTI, Alberto. Desafios na Proteção de Microrredes. **VI Simpósio Brasileiro de Sistemas Elétricos**, p. 22–25, jan. 2016. DOI: 10.20906/CPS/SBSE2016-0095.

RUSSAKOVSKY, Olga *et al.* Imagenet large scale visual recognition challenge. **International journal of computer vision**, Springer, v. 115, n. 3, p. 211–252, 2015.

SAHOO, S.; BARAN, M. E. A method to detect high impedance faults in distribution feeders, p. 1–6, 2014. DOI: 10.1109/TDC.2014.6863531.

SAMANTARAY, S. R.; DASH, P. K. High impedance fault detection in distribution feeders using extended kalman filter and support vector machine. **European Transactions on Electrical Power**, v. 20, n. 3, p. 382–393, 2010. DOI: <https://doi.org/10.1002/etep.321>.

SAMANTARAY, S. R.; JOOS, G.; KAMWA, I. Differential energy based microgrid protection against fault conditions, p. 1–7, jan. 2012. DOI: 10.1109/ISGT.2012.6175532.

SAMANTARAY, S.R. Ensemble decision trees for high impedance fault detection in power distribution network. **International Journal of Electrical Power & Energy Systems**, v. 43, n. 1, p. 1048–1055, 2012. ISSN 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2012.06.006>.

SAMANTARAY, S.R.; DASH, P.K.; UPADHYAY, S.K. Adaptive Kalman filter and neural network based high impedance fault detection in power distribution networks. **International Journal of Electrical Power & Energy Systems**, v. 31, n. 4, p. 167–172, 2009. ISSN 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2009.01.001>.

SANGEETH, Balu K.; VINOD, V. High Impedance Fault Detection Using Multi-Domain Feature with Artificial Neural Network. **Electric Power Components and Systems**, v. 51, n. 4, p. 366–379, 2023. DOI: 10.1080/15325008.2023.2172091.

SANTOS, Wellinsílvia Costa. **Uma revisão de modelos clássicos de faltas de alta impedância para efeito de melhoramento**. Set. 2011. Diss. (Mestrado) – UNIVERSIDADE FEDERAL DE CAMPINA GRANDE CENTRO. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/11061>.

SANTOS, Wellinsilvia Costa dos; SOUZA, Benemar Alencar de; BRITO, Núbia Silva Dantas; COSTA, Flávio Bezerra; PAES, Marcelo Renato Cerqueira. High impedance faults: From field tests to modeling. **Journal of Control, Automation and Electrical Systems**, Springer, v. 24, p. 885–896, 2013. DOI: <https://doi.org/10.1007/s40313-013-0072-8>.

SANZ, JF; MATUTE, G; FERNÁNDEZ, G; ALONSO, MA; SANZ, M. Analysis of European policies and incentives for microgrids. *Renewable Energy e Power Quality Journal*, Cordoba, Spain, v. 12, abr. 2014.

SARANGI, Swetalina; SAHU, Binod Kumar; ROUT, Pravat Kumar. High-impedance fault identification and location by using mode decomposition integrated adaptive multi-kernel extreme learning machine technique for distributed generator-based microgrid. **Electrical Engineering**, Springer, p. 1–24, nov. 2022. DOI: <https://doi.org/10.1007/s00202-022-01658-6>.

SARANGI, Swetalina; SAHU, Binod Kumar; ROUT, Pravat Kumar. Review of distributed generator integrated AC microgrid protection: issues, strategies, and future trends. **International Journal of Energy Research**, v. 45, n. 10, p. 14117–14144, 2021. DOI: <https://doi.org/10.1002/er.6689>.

SARLAK, M; SHAHRTASH, SM. High impedance fault detection using combination of multi-layer perceptron neural networks based on multi-resolution morphological gradient features of current waveform. **IET generation, transmission & distribution**, IET, v. 5, n. 5, p. 588–595, 2011a. DOI: [10.1049/iet-gtd.2010.0702](https://doi.org/10.1049/iet-gtd.2010.0702).

SARLAK, M; SHAHRTASH, SM. SVM-based method for high-impedance faults detection in distribution networks. **COMPEL-The international journal for computation and mathematics in electrical and electronic engineering**, Emerald Group Publishing Limited, v. 30, n. 2, p. 431–450, mar. 2011b. ISSN 0332-1649. DOI: [10.1108/033216411111101014](https://doi.org/10.1108/033216411111101014).

SARLAK, M.; SHAHRTASH, S. M. High impedance fault detection in distribution networks using support vector machines based on wavelet transform, p. 1–6, out. 2008. DOI: [10.1109/EPC.2008.4763380](https://doi.org/10.1109/EPC.2008.4763380).

SARLAK, M.; SHAHRTASH, S. M. High-Impedance Faulted Branch Identification Using Magnetic-Field Signature Analysis. **IEEE Transactions on Power Delivery**, v. 28, n. 1, p. 67–74, 2013. DOI: [10.1109/TPWRD.2012.2222056](https://doi.org/10.1109/TPWRD.2012.2222056).

SARLAK, Mostafa; SHAHRTASH, S Mohammad; KHABURI, D Arab. Design and implementation of a systematically tunable high impedance fault relay. **ISA transactions**, Elsevier, v. 49, n. 3, p. 358–368, jul. 2010. DOI: <https://doi.org/10.1016/j.isatra.2010.03.011>.

SEDIGHI, A. R.; HAGHIFAM, M. R. Simulation of high impedance ground fault In electrical power distribution systems, p. 1–7, 2010. DOI: 10.1109/POWERCON.2010.5666061.

SEDIGHI, A.-R.; HAGHIFAM, M.-R.; MALIK, O.P. Soft computing applications in high impedance fault detection in distribution systems. **Electric Power Systems Research**, v. 76, n. 1, p. 136–144, 2005. ISSN 0378-7796. DOI: <https://doi.org/10.1016/j.epsr.2005.05.004>.

SEDIGHIZADEH, M; REZAZADEH, A; ELKALASHY, Nagy I. Approaches in high impedance fault detection a chronological review. **Advances in Electrical and Computer Engineering**, Stefan cel Mare University of Suceava, v. 10, n. 3, p. 114–128, 2010. DOI: 10.4316/AECE.2010.03019.

SEKAR, Kavaskar; MOHANTY, Nalin Kant; SAHOO, Ashwin Kumar. High impedance fault detection using wavelet transform. *In: 2018 Technologies for Smart-City Energy Security and Power (ICSESP)*. [S.l.: s.n.], mar. 2018. P. 1–6. DOI: 10.1109/ICSESP.2018.8376740.

SHAFIEE, Shahriar; TOPAL, Erkan. When will fossil fuel reserves be diminished? **Energy Policy**, Elsevier, v. 37, n. 1, p. 181–189, 2009. ISSN 0301-4215. DOI: <https://doi.org/10.1016/j.enpol.2008.08.016>.

SHAHRTASH, S. M.; SARLAK, M. High Impedance Fault Detection Using Harmonics Energy Decision Tree Algorithm, p. 1–5, 2006. DOI: 10.1109/ICPST.2006.321441.

SHARAF, A. M.; EL-SHARKAWY, R. M.; AL-FATIH, R.; AL-KETBI, M. High impedance fault detection on radial distribution and utilization systems. v. 2, 1012–1015 vol.2, 1996. DOI: 10.1109/CCECE.1996.548326.

SHARAF, A. M.; SNIDER, L. A.; DEBNATH, K. A neural network based relaying scheme for distribution system high impedance fault detection, p. 321–324, 1993. DOI: 10.1109/ANNES.1993.323013.

SHARAF, A. M.; WANG, Guosheng. High impedance fault detection using feature-pattern based relaying. v. 1, 222–226 vol.1, set. 2003. DOI: 10.1109/TDC.2003.1335218.

- SHARAT, A.M.; SNIDER, L.A.; DEBNATH, K. A neural network based back error propagation relay algorithm for distribution system high impedance fault detection, 613–620 vol.2, 1993. ISSN 0-85296-569-9.
- SHENG, Yong; ROVNYAK, S.M. Decision tree-based methodology for high impedance fault detection. **IEEE Transactions on Power Delivery**, v. 19, n. 2, p. 533–536, 2004. DOI: 10.1109/TPWRD.2003.820418.
- SHIHABUDHEEN, K.V.; KUNJU, Bijuna; AHAMMED, Imthias; GURUVARURAPPAN, Akshay; JOSE, Jibin; KEERTHANA, D.; REVATHI, P.B. Detection of High Impedance Fault using Machine Learning Techniques. *In*: TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON). [S.l.: s.n.], 2019. P. 2117–2122. DOI: 10.1109/TENCON.2019.8929365.
- SHU, Hongchun; DENG, Yaqi; DONG, Jun; CAO, Pulin; YANG, Bo; BO, Zhiqian. A detection method of high impedance arcing fault for distribution network with distributed generation based on CEEMDAN and TEO algorithm. **International Transactions on Electrical Energy Systems**, v. 31, n. 8, e12926, 2021. DOI: <https://doi.org/10.1002/2050-7038.12926>.
- SHUAI, Zhikang. **Transient Characteristics, Modelling and Stability Analysis of Microgrid**. 1. ed. [S.l.]: Springer, out. 2021. ISBN 978-981-15-8403-9. DOI: <https://doi.org/10.1007/978-981-15-8403-9>.
- SIADATAN, A.; KAREGAR, H. Kazemi; NAJMI, V. New high impedance fault detection, p. 573–576, 2010. DOI: 10.1109/PECON.2010.5697647.
- SIKSNELYTE-BUTKIENE, Indre; KARPAVICIUS, Tomas; STREIMIKIENE, Dalia; BALEZENTIS, Tomas. The Achievements of Climate Change and Energy Policy in the European Union. **Energies**, v. 15, n. 14, 2022. DOI: 10.3390/en15145128.
- SIROJAN, Tharmakulasingam; LU, Shibo; PHUNG, B.T.; ZHANG, Daming; AMBIKAIRAJAH, Eliathamby. Sustainable Deep Learning at Grid Edge for Real-Time High Impedance Fault Detection. **IEEE Transactions on Sustainable Computing**, v. 7, n. 2, p. 346–357, 2022. DOI: 10.1109/TSUSC.2018.2879960.
- SISTEMA ELÉTRICO, Operador Nacional do. **Programa Mensal de Operação PMO**. [S.l.: s.n.], out. 2023. Disponível em: <https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>.

- SOARES, Renan Moreira; OLIVEIRA, Marcelo Escobar. Microrredes: o conceito através da história, incentivos e o mercado brasileiro. **Simpósio Brasileiro de Sistemas Elétricos**, Universidade Federal de Santa Maria, 2022. Disponível em: <http://repositorio.ifg.edu.br:8080/handle/prefix/1229>.
- SOHEILI, Adel; SADEH, Javad; BAKHSHI, Reza. Modified FFT based high impedance fault detection technique considering distribution non-linear loads: Simulation and experimental data analysis. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 94, p. 124–140, 2018. ISSN 0142-0615. DOI: 10.1016/j.ijepes.2017.06.035.
- SORTOMME, E.; VENKATA, S. S.; MITRA, J. Microgrid Protection Using Communication-Assisted Digital Relays. **IEEE Transactions on Power Delivery**, v. 25, n. 4, p. 2789–2796, out. 2010. ISSN 0885-8977. DOI: 10.1109/TPWRD.2009.2035810.
- SULTAN, A. F.; SWIFT, G. W.; FEDIRCHUK, D. J. Detecting arcing downed-wires using fault current flicker and half-cycle asymmetry. **IEEE Transactions on Power Delivery**, v. 9, n. 1, p. 461–470, 1994. DOI: 10.1109/61.277718.
- SULTAN, A. F.; SWIFT, G. W.; FEDIRCHUK, D. J. Detection of high impedance arcing faults using a multi-layer perceptron. **IEEE Transactions on Power Delivery**, v. 7, n. 4, p. 1871–1877, 1992. DOI: 10.1109/61.156989.
- SULTAN, A.F.; SWIFT, G.W. Security testing of high impedance fault detectors. *In*: [PROCEEDINGS] WESCANEX '91. [S.l.: s.n.], 1991. P. 191–197. DOI: 10.1109/WESCAN.1991.160545.
- TENFEN, D; LEMOS, FAB; FERNANDES, RC; DECKER, IC. Microgrids and microgeneration in Brazilian energy market: A discussion of regulatory and commercial aspects, 2013.
- TENGDIN, John; WESTFALL, Ron; STEPHAN, Kevin *et al.* High Impedance Fault Detection Technology: ARTICLE of PSRC Working Group D15. **Power System Relaying and Control Committee**, p. 13, 1996. Disponível em: <http://grouper.ieee.org/groups/td/dist/documents/highz.pdf>.
- THERON, J C Jacobus; PAL, Amit; VARGHESE, Abraham. Tutorial on high impedance fault detection. *In*: 2018 71st Annual Conference for Protective Relay Engineers (CPRE). [S.l.: s.n.], mar. 2018. P. 1–23. DOI: 10.1109/CPRE.2018.8349833.

- THOMAS, Mini Shaji; BHASKAR, Namrata; PRAKASH, Anupama. Voltage based detection method for high impedance fault in a distribution system. **Journal of The Institution of Engineers (India): Series B**, Springer, v. 97, n. 3, p. 413–423, 2016. DOI: <https://doi.org/10.1007/s40031-015-0203-7>.
- TON, Dan T; SMITH, Merrill A. The US department of energy's microgrid initiative. **The Electricity Journal**, Elsevier, v. 25, n. 8, p. 84–94, 2012. DOI: <https://doi.org/10.1016/j.tej.2012.09.013>.
- TONELLI-NETO, Mauro S.; DECANINI, José Guilherme M.S.; LOTUFO, Anna Diva P.; MINUSSI, Carlos Roberto. Fuzzy based methodologies comparison for high-impedance fault diagnosis in radial distribution feeders. **IET Generation, Transmission & Distribution**, v. 11, n. 6, p. 1557–1565. DOI: <https://doi.org/10.1049/iet-gtd.2016.1409>.
- TORRES, V.; GUARDADO, J.L.; RUIZ, H.F.; MAXIMOV, S. Modeling and detection of high impedance faults. **International Journal of Electrical Power & Energy Systems**, v. 61, p. 163–172, 2014. ISSN 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2014.03.046>.
- TRONDOLI, L.H.P.C.; LOPES, G.N.; VIEIRA, J.C.M. Configurable stochastic model for high impedance faults simulations in electrical distribution systems. **Electric Power Systems Research**, v. 205, p. 107686, 2022. ISSN 0378-7796. DOI: <https://doi.org/10.1016/j.epsr.2021.107686>.
- USTUN, T. S.; OZANSOY, C.; ZAYEGH, A. Modeling of a Centralized Microgrid Protection System and Distributed Energy Resources According to IEC 61850-7-420. **IEEE Transactions on Power Systems**, v. 27, n. 3, p. 1560–1567, 2012. DOI: [10.1109/TPWRS.2012.2185072](https://doi.org/10.1109/TPWRS.2012.2185072).
- VAISH, Rachna; DWIVEDI, U.D.; TEWARI, Saurabh; TRIPATHI, S.M. Machine learning applications in power system fault diagnosis: Research advancements and perspectives. **Engineering Applications of Artificial Intelligence**, v. 106, p. 104504, 2021. ISSN 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2021.104504>.
- VASQUEZ-ARROYOA, Eveline; SILVAB, Fábio da; SANTOSC, Alberto; CORDEIROD, Deborah; MARENGOE, José Antônio; LUCENAF, André FP. Impactos climáticos na segurança energética no Brasil: análise de eventos observados e

opções de adaptação. v. 11, n. 3, p. 177–196. ISSN 2179-9067. DOI: 10.18472/SustDeb.v11n3.2020.33838.

VEERASAMY, Veerapandiyan; ABDUL WAHAB, Noor Izzri; VINAYAGAM, Arangarajan; OTHMAN, Mohammad Lutfi; RAMACHANDRAN, Rajeswari; INBAMANI, Abinaya; HIZAM, Hashim. A novel discrete wavelet transform-based graphical language classifier for identification of high-impedance fault in distribution power system. **International Transactions on Electrical Energy Systems**, v. 30, n. 6, e12378, 2020. DOI: <https://doi.org/10.1002/2050-7038.12378>.

VEERASAMY, Veerapandiyan; WAHAB, Noor Izzri Abdul; OTHMAN, Mohammad Lutfi; PADMANABAN, Sanjeevikumar; SEKAR, Kavaskar; RAMACHANDRAN, Rajeswari; HIZAM, Hashim; VINAYAGAM, Arangarajan; ISLAM, Mohammad Zohrul. LSTM Recurrent Neural Network Classifier for High Impedance Fault Detection in Solar PV Integrated Power System. **IEEE Access**, v. 9, p. 32672–32687, 2021. DOI: 10.1109/ACCESS.2021.3060800.

VENKATA, S; RENO, Matthew J; BOWER, Ward; MANSON, Scott; REILLY, James; SEY JR, George W. Microgrid protection: Advancing the state of the art. **Sandia National Laboratories, SAND2019-3167, Albuquerque**, 2019.

WANG, Aili; WANG, Minhui; JIANG, Kaiyuan; CAO, Mengqing; IWAHORI, Yuji. A Dual Neural Architecture Combined SqueezeNet with OctConv for LiDAR Data Classification. **Sensors**, v. 19, n. 22, 2019. ISSN 1424-8220. DOI: 10.3390/s19224927.

WANG, Xiaowei; GAO, Jie; WEI, Xiangxiang; SONG, Guobing; WU, Lei; LIU, Jingwei; ZENG, Zhihui; KHESHTI, Mostafa. High Impedance Fault Detection Method Based on Variational Mode Decomposition and Teager–Kaiser Energy Operators for Distribution Network. **IEEE Transactions on Smart Grid**, v. 10, n. 6, p. 6041–6054, nov. 2019. ISSN 1949-3061. DOI: 10.1109/TSG.2019.2895634.

WANG, Xiaowei; WEI, Xiangxiang; GAO, Jie; SONG, Guobing; KHESHTI, Mostafa; GUO, Liang. High-Impedance Fault Detection Method Based on Stochastic Resonance For a Distribution Network With Strong Background Noise. **IEEE Transactions on Power Delivery**, v. 37, n. 2, p. 1004–1016, abr. 2022. ISSN 1937-4208. DOI: 10.1109/TPWRD.2021.3075472.

- YANG, Hanyu; LIU, Xubin; ZHANG, Di; CHEN, Tao; LI, Canbing; HUANG, Wentao. Machine learning for power system protection and control. **The Electricity Journal**, v. 34, n. 1, p. 106881, 2021. Special Issue: Machine Learning Applications To Power System Planning And Operation. ISSN 1040-6190. DOI: <https://doi.org/10.1016/j.tej.2020.106881>.
- YU, DC; KHAN, Shoukat H. An adaptive high and low impedance fault detection method. **IEEE transactions on power delivery**, IEEE, v. 9, n. 4, p. 1812–1821, 1994. DOI: 10.1109/61.329514.
- ZADEH, Hassan Khorashadi. An ANN-based high impedance fault detection scheme: design and implementation. **International Journal of Emerging Electric Power Systems**, De Gruyter, v. 4, n. 2, dez. 2005. ISSN 1553-779X. DOI: <https://doi.org/10.2202/1553-779X.1046>.
- ZAMANAN, N.; SYKULSKI, J.K.; AL-OTHMAN, A.K. Arcing High Impedance Fault Detection Using Real Coded Genetic Algorithm, p. 35–39, 2007. Event Dates: 2-4 April 2007. Disponível em: <https://eprints.soton.ac.uk/263904/>.
- ZAMANAN, Naser; SYKULSKI, Jan K. Modelling arcing high impedances faults in relation to the physical processes in the electric arc. **WSEAS Transactions on power systems**, v. 1, n. 8, p. 1507–1512, ago. 2006. Disponível em: <http://eprints.soton.ac.uk/id/eprint/263150>.
- ZAMANI, M. A.; YAZDANI, A.; SIDHU, T. S. Investigations into the operation of an existing medium-voltage distribution feeder as a microgrid, p. 1–7, set. 2011. DOI: 10.1049/cp.2011.0115.
- ZANJANI, M. G. M.; KARGAR, H. K.; ZANJANI, M. G. M. High impedance fault detection of distribution network by phasor measurement units. IEEE, p. 1–5, mai. 2012. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6254586>.
- ZHANG, Yongjie; WANG, Xiaojun; HE, Jinghan; XU, Yin; ZHANG, Fang; LUO, Yiping. A Transfer Learning-Based High Impedance Fault Detection Method Under a Cloud-Edge Collaboration Framework. **IEEE Access**, v. 8, p. 165099–165110, 2020a. DOI: 10.1109/ACCESS.2020.3022639.
- ZHANG, Yongjie; WANG, Xiaojun; LUO, Yiping; XU, Yin; HE, Jinghan; WU, Guohong. A CNN Based Transfer Learning Method for High Impedance Fault Detection. *In*: 2020

IEEE Power & Energy Society General Meeting (PESGM). [S.l.: s.n.], 2020b. P. 1–5. DOI: 10.1109/PESGM41954.2020.9281671.

ZHENG, Dehua; ZHANG, Wei; NETSANET, Solomon; WANG, Ping; BITEW, Girmaw Teshager; WEI, Dan; YUE, Jun. **Microgrid Protection and Control**. Edição: Chris Hockaday. 1. ed. [S.l.]: Academic Press, jun. 2021. ISBN 9780128211892.

ZHOU, Ying; HUANG, Qinyuan; YANG, Tian; LI, Qiang. Internal Defect Identification of Arc Magnets Based on a Deep Residual Network Combined with GRU and SqueezeNet. *In*: 2021 4th International Conference on Pattern Recognition and Artificial Intelligence (PRAI). [S.l.: s.n.], 2021. P. 487–493. DOI: 10.1109/PRAI53619.2021.9551041.

ZHUANG, Fuzhen; QI, Zhiyuan; DUAN, Keyu; XI, Dongbo; ZHU, Yongchun; ZHU, Hengshu; XIONG, Hui; HE, Qing. A Comprehensive Survey on Transfer Learning. **Proceedings of the IEEE**, v. 109, n. 1, p. 43–76, 2021. DOI: 10.1109/JPROC.2020.3004555.

Apêndices

APÊNDICE A – TESTES PARA SINAIS DE ENTRADA DO CLASSIFICADOR

Aqui são apresentados os resultados dos testes realizados para escolha do sinal de entrada para o método de detecção desenvolvido. Outros parâmetros e características de sinais apresentadas nos trabalhos (PENIDO *et al.*, 2022; CUI *et al.*, 2017, 2019) foram avaliadas, como tensão de sequência negativa e diferença angular dos componentes de sequência. Mas foram rejeitadas sem a realização de todo o processo de treinamento e teste com o método de classificação, pois apresentaram baixa correlação com as FAI nas simulações realizadas.

Os três parâmetros aqui apresentados são proporção entre corrente de sequência negativa e positiva (I_N/I_P), proporção entre corrente de sequência zero e positiva (I_0/I_P) e a tensão residual ($V_R = V_a + V_b + V_c$). Esses três parâmetros tem a característica de agregar informações sobre as três fases do sistema em apenas um sinal.

A utilização da soma das tensões trifásicas em uma abordagem similar ao que foi sugerido por (LAAKSONEN; HOVILA, 2017), mas no artigo o parâmetro utilizado é a média móvel da magnitude dessa tensão de neutro por um período de 100 milissegundos. Os autores propõem este parâmetro para proteção de uma MR com GD baseada em VSC, mas no artigo não está claro se os modelos utilizados reproduzem de alguma forma as distorções harmônicas casadas por esses equipamentos.

A relação entre corrente de sequência negativa e positiva (I_N/I_P) foi apresentada por engenheiros da empresa *General Electric* como uma técnica disponível para ser implementada na detecção das FAI (THERON *et al.*, 2018). Esta é uma técnica de fácil utilização uma vez que a maioria dos relés digitais de proteção em SDE possuem alguma solução para detecção de condutores rompidos baseada em corrente de sequência negativa (I_N). Essa relação é utilizada porque apenas a componente de sequência negativa de corrente não é suficiente para indicar a presença de uma FAI, uma vez que sua magnitude depende do carregamento do sistema e da possibilidade de carregamento desbalanceado. Na prática a relação I_N/I_P torna a detecção menos sensível ao nível de carregamento.

Na ocorrência de FAI em SDE com apenas um ponto de aterramento a componente de sequência zero é baixa, o que torna a relação I_N/I_P próximo de 100%. Para sistemas multi-aterrados esta relação I_N/I_P será 50%.

A sensibilidade deste tipo de detecção de FAI deve se pautar por um estudo do sistema ou por medições durante o comissionamento da proteção. Deve ser levado em conta o máximo carregamento do SDE, de modo a contabilizar todas cargas monofásicas. Para uma relação de I_N/I_P de 10% para máxima carga sugere-se um ajuste de 20% para detecção de FAI, além disso recomenda-se um longo período de temporização (60 segundos) para coordenação com outros dispositivos e lógicas de proteção (THERON *et al.*, 2018). A seguir são apresentados os resultados para simulação no

sistema teste utilizando este critério de detecção.

Essas mesmas vantagens observadas na utilização da relação I_N/I_P foi explorada para avaliar a corrente de sequência zero. Assim, foram realizados o treinamento e teste com RNC SqueezeNet para a relação I_Z/I_P . A corrente de sequência zero também pode ser utilizada para localização de faltas (PENIDO *et al.*, 2022), como também detecção de FAI em (SHU *et al.*, 2021)

As figuras a seguir apresentam os resultados na forma de gráfico e tabela. Na primeira coluna estão os índices de desempenho, já apresentados na seção 4.5.1, para a relação entre I_N/I_P para o Classificador Detalhado chamado *Inp Detalhado*. A segunda coluna tem os resultados para o Classificador Detalhado com a relação I_Z/I_P , que é nomeado *Izp Detalhado*. Na terceira coluna é apresentado o resultado do Classificador Detalhado que utilizou a tensão residual V_R , com o nome de *Vr Detalhado*. As três demais colunas apresentam os resultados para o Classificador Simplificado, sendo *Inp Simplificado*, *Izp Simplificado* e *Vr Simplificado* a quarta, quinta e sexta coluna respectivamente.

Os resultados não são avaliados caso a caso. Estes parâmetros aqui apresentados apresentaram resultados gerais inferiores aos obtidos pela corrente residual ($I_R = I_a + I_b + I_c$). Para o teste com a base de dados completa os índices de desempenho são satisfatórios para os Classificadores Detalhados, principalmente para os testes com as FAIs os índices são degradados.

Figura 59 – Avaliação de características no teste com a base de dados completa.

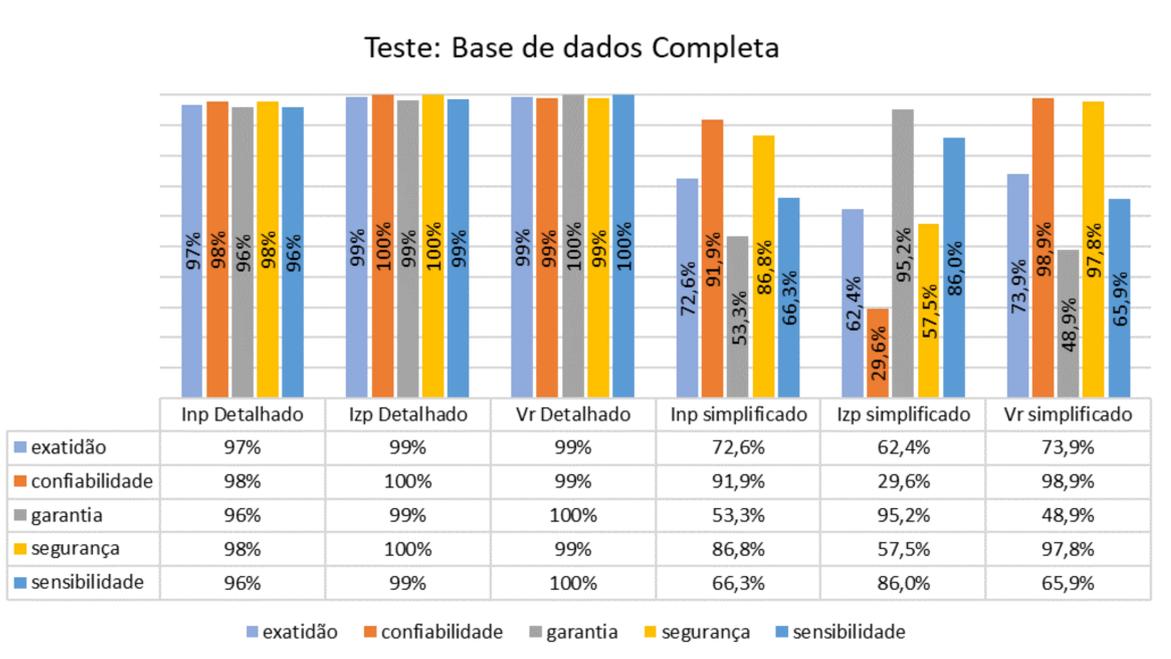


Figura 60 – Avaliação de características no teste 1 com FAI Modelo 2.

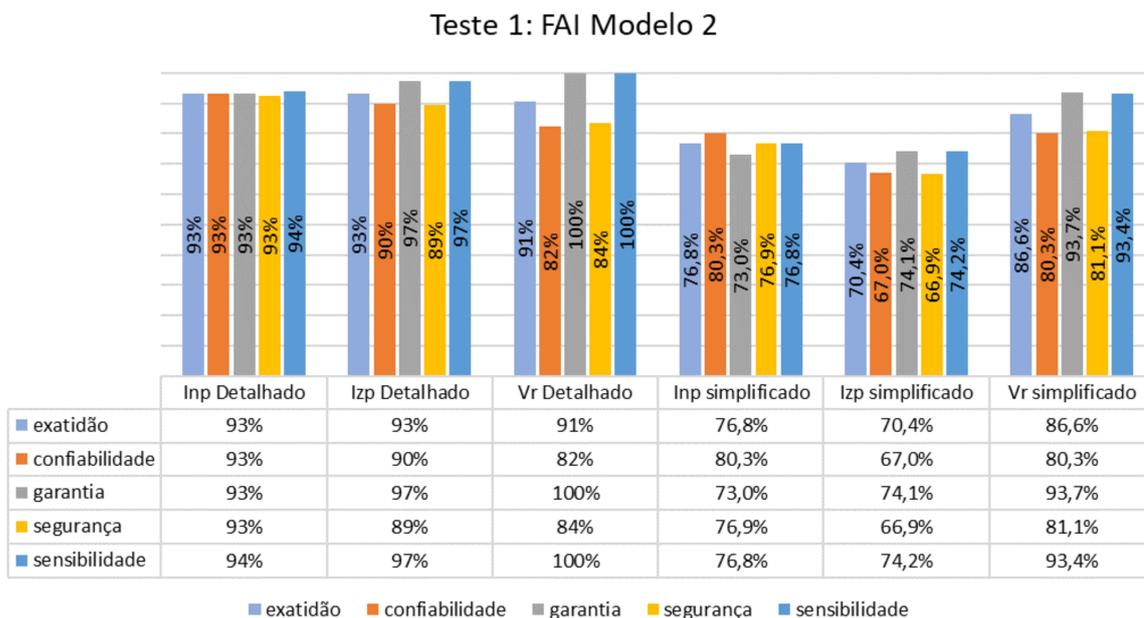


Figura 61 – Avaliação de características no teste 2 com FAI Modelo 2.

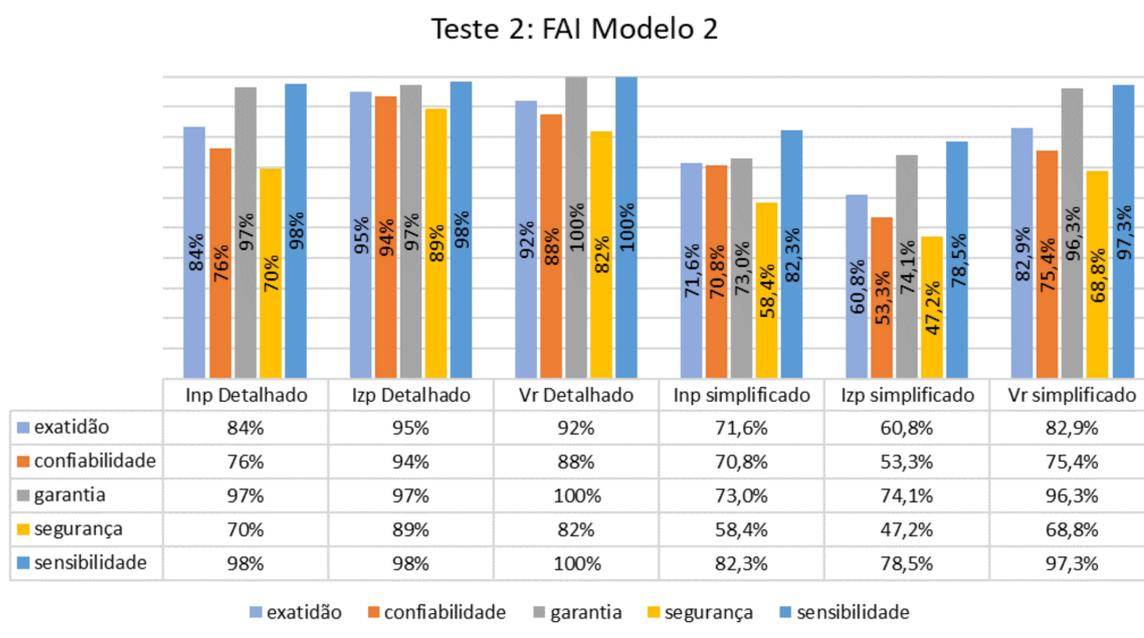


Figura 62 – Avaliação de características no teste 1 com FAI Modelo 3.

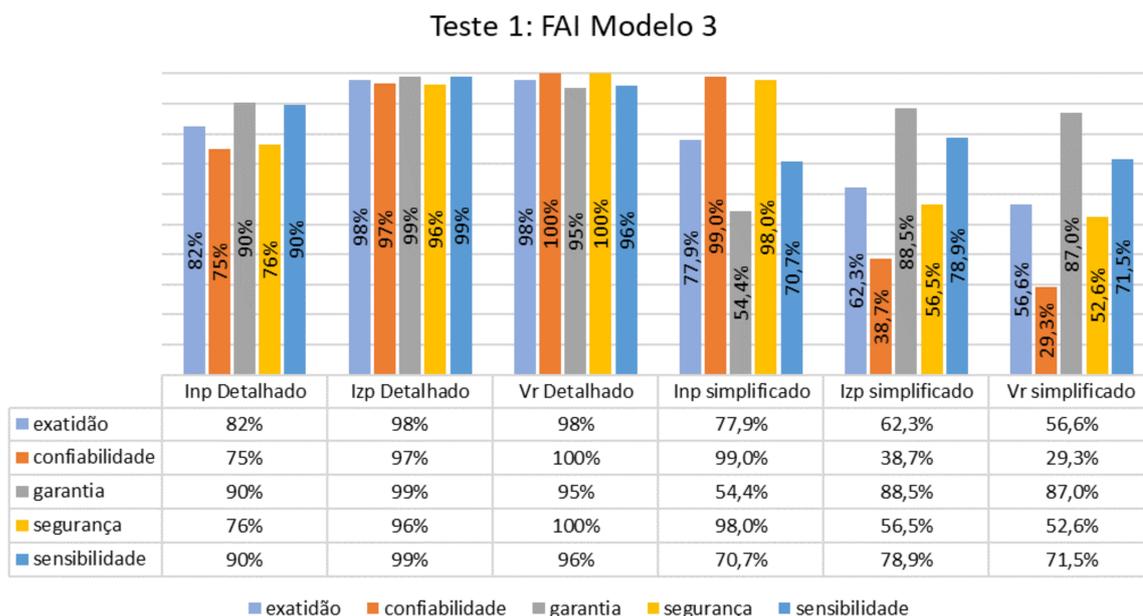


Figura 63 – Avaliação de características no teste 2 com FAI Modelo 3.

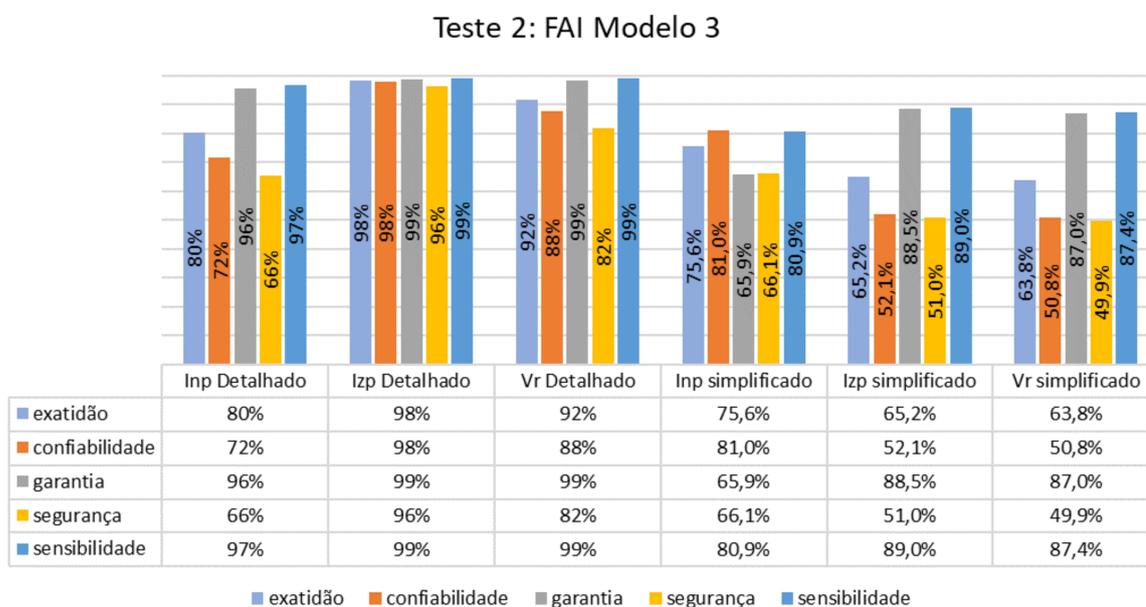


Figura 64 – Avaliação de características no teste com carga não linear.

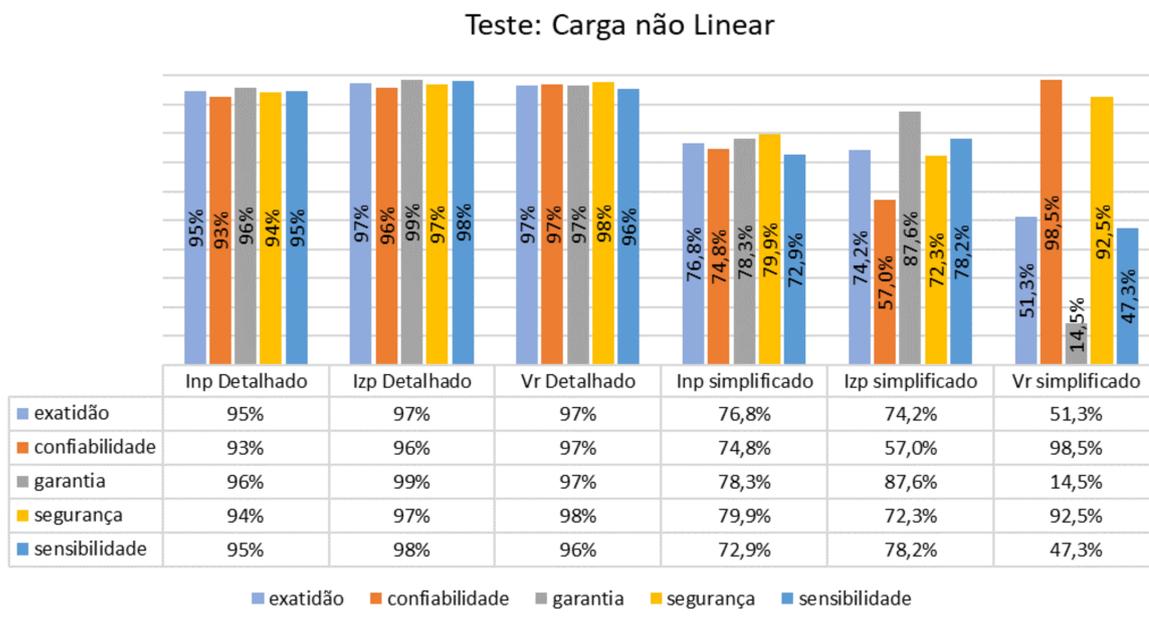


Figura 65 – Avaliação de características no teste de chaveamento de linhas.

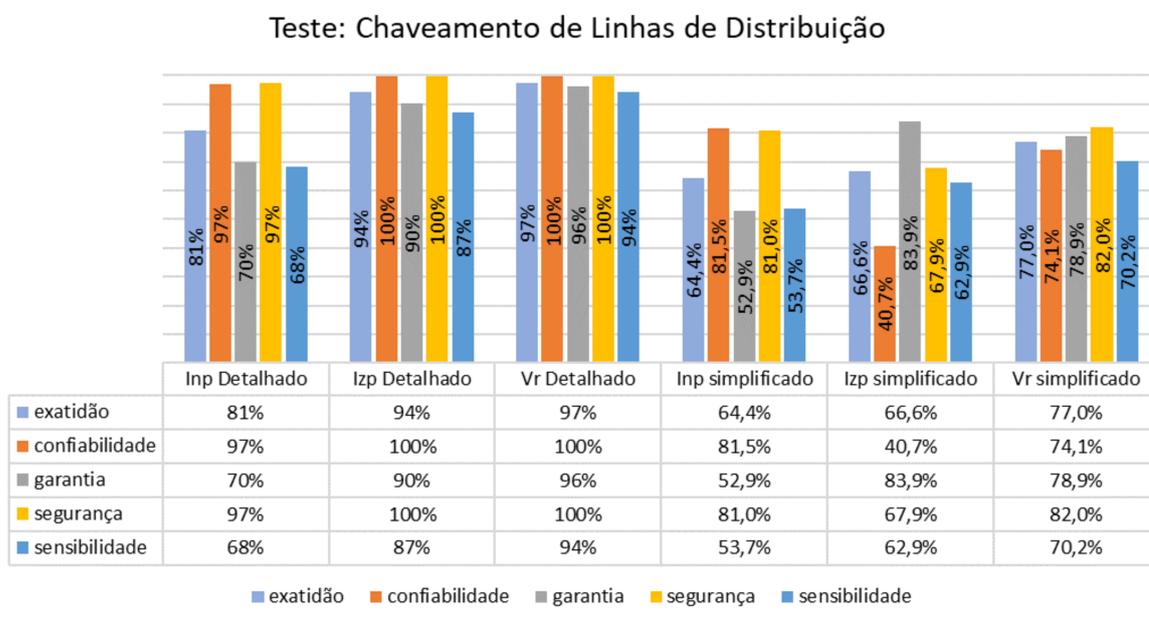


Figura 66 – Avaliação de características no teste para simulações sem transitórios.

