Fábbio Anderson Silva Borges

**Método Híbrido Baseado no Algoritmo
k-means e Regras de Decisão para
Localização das Fontes de Variações
de Tensões de Curta Duração no
Contexto de *Smart Grid***

São Carlos

2017

Fábbio Anderson Silva Borges

**Método Híbrido Baseado no Algoritmo
k-means e Regras de Decisão para
Localização das Fontes de Variações
de Tensões de Curta Duração no
contexto de *Smart Grid***

Tese apresentada ao Programa de
Engenharia Elétrica da Escola de Engenharia
de São Carlos, da Universidade de São
Paulo, para a obtenção do título de Doutor em
Ciências, Programa de Engenharia Elétrica

Área de Concentração: Sistemas Dinâmicos

Orientador: Prof. Dr. Ivan Nunes da Silva

São Carlos

2017

Trata-se da versão corrigida da tese. A versão original se encontra disponível na EEESC/USP que aloja o Program de Pós-Graduação de Engenharia Elétrica

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

B732m Borges, Fábio Anderson Silva
 Método Híbrido Baseado no Algoritmo k-means e
Regras de Decisão para Localização das Fontes de
Variações de Tensões de Curta Duração no Contexto de
Smart Grid / Fábio Anderson Silva Borges; orientador
Ivan Nunes da Silva. São Carlos, 2017.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Elétrica e Área de Concentração em Sistemas
Dinâmicos -- Escola de Engenharia de São Carlos da
Universidade de São Paulo, 2017.

1. Aprendizado de Máquina. 2. Classificação dos
Distúrbios de Variação de Tensão de Curta Duração. 3.
Localização das Fontes Causadoras de Variação de Tensão
de Curta Duração. 4. Qualidade de Energia Elétrica. 5.
Sistema operacional de Tempo Real. 6. Smart Grid. 7.
Smart Meter. 8. Variação de Tensão de Curta Duração. I.
Título.

FOLHA DE JULGAMENTO

Candidato: **FÁBBIO ANDERSON SILVA BORGES**

Título da tese: "Método híbrido baseado no algoritmo *k-means* e regras de decisão para localização das fontes de variações de tensões de curta duração no contexto de *smart grid*"

Data da defesa: 07/07/2017

Comissão Julgadora:

Resultado:

Prof. Associado **Ivan Nunes da Silva**
(Orientador)
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Titular **Zhao Liang**
(Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto/FFCLRP-USP)

Aprovado

Prof. Dr. **Ricardo Augusto Souza Fernandes**
(Universidade Federal de São Carlos/UFSCar)

Aprovado

Prof. Dr. **Ricardo de Andrade Lira Rabêlo**
(Universidade Federal do Piauí/UFPI)

APROVADO

Prof. Associado **Rogério Andrade Flauzino**
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Luis Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

Dedico esse trabalho aos meus pais Lídia e Humberto que sempre batalharam para me oferecer o melhor. À minha noiva e amiga Thayz pelo incentivo e compreensão ao longo de todo período de desenvolvimento desta pesquisa.

AGRADECIMENTOS

A realização dessa pesquisa foi uma árdua jornada na qual tive a colaboração, estímulo e empenho de diversas pessoas.

Primeiramente gostaria de agradecer a Deus pelo dom da vida e pela força nos momentos difíceis, não me deixando desistir.

Aos meus pais, Antônio Humberto e Maria Lídia por todo amor, pela criação e pelas oportunidades oferecidas, bem como os conselhos, que com certeza me tornaram uma pessoa melhor. Obrigado por muitas vezes terem aberto mão dos sonhos de vocês para que os meus pudessem ser concretizados. Vocês são meus maiores exemplos e a cada passo que dou penso em vocês. Amo vocês.

À minha noiva Thayz agradeço pelo amor e por estar o tempo todo ao meu lado, seu carinho, incentivo e apoio foram fundamentais para finalização desse trabalho. Sou grato por cada gesto de amor, carinho, pelos sorrisos e por vibrar juntos em cada conquista e, principalmente, por estar do meu lado nos momentos de desânimos, falta de estímulo. Agradeço a você por ter me tornado uma pessoa melhor. Te amo. Estendo também meus agradecimentos a sua família, seus pais Ildenê e Valdeci pela torcida desde o primeiro momento.

À minha irmã Carla por acreditar sempre no meu sucesso e me oferecer palavras de conforto nos momentos de luta.

À toda minha família em especial aos meus avós, Francisca, Déa e Nonato que mesmo de longe sempre torceram para conclusão desse trabalho, obrigado pelo carinho.

Ao meu orientador Prof. Dr. Ivan Nunes da Silva pela oportunidade, pelos ensinamentos que contribuíram para conclusão desse trabalho.

Aos professores que contribuíram para minha formação em destaque ao Prof. Dr. Ricardo Augusto Souza Fernandes que sempre se mostrou disposto a tirar as minhas dúvidas e pela orientação que desde o início ajudou no desenvolvimento do projeto e ao Prof. Dr. Ricardo de Andrade Lira Rabelo o qual me orientou nas minhas primeiras atividades e me encorajou na escolha da carreira acadêmica, talvez se não fosse isso, hoje não estaria finalizando esse trabalho.

À todos os amigos do laboratório (LAIPS) Marcelo Suetake, Danilo Hernane Spatti, Silas Alves, Rene Takao e Marcel obrigado pelas contribuições e pelas conversas que ajudaram a fugir um pouco do stress do dia-dia e também aos amigos

que fiz durante meu período como pesquisador no departamento de Engenharia Elétrica.

Aos amigos de Teresina que torceram distante e aos amigos que fiz durante os seis anos que morei em São Carlos, os quais pude compartilhar vários momentos. Destacar os amigos de república RGEM (Dudu, Alexandre, Marcelo, Renan, Rafael, Elian, Ailton e Patrick) por todas as conversas “jogadas fora” e pelos churrascos dos finais de semana que ajudaram a diminuir a saudade de casa. Agradeço também ao apoio de Thamyres, Jéssica, Raissa, Viviane e Cecilia.

Manifesto também os meus agradecimentos a todos os funcionários da USP, em especial aos que trabalham na secretaria da pós-graduação que deram suporte a realização desse trabalho.

Registro também agradecimento a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento concedido para a realização dessa pesquisa por meio do processo nº 2013/16778-0.

RESUMO

BORGES, Fábio Anderson Silva. **Método Híbrido Baseado no Algoritmo k-means e Regras de Decisão para Localização das Fontes de Variações de Tensões de Curta Duração no Contexto de Smart Grid**, 2017 Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

No contexto de *Smart Grids*, determinar a correta localização das fontes causadoras de Variação de Tensão de Curta Duração (VTCD) não é uma tarefa simples, devido à curta duração destes eventos e também, por sua rápida propagação nas redes de distribuição de energia elétrica. Neste sentido, esse trabalho apresentou um método híbrido recursivo baseado em ferramentas da área de aprendizado de máquinas (algoritmo de agrupamento e base de regras), o qual é capaz de localizar as fontes de VTCD, a partir da análise das características dos distúrbios disponibilizadas pelos smart meters instalados no sistema. Assim, o trabalho destinou-se ao desenvolvimento de uma plataforma em hardware para aquisição, detecção e classificação dos distúrbios, através de um Sistema Operacional de Tempo Real. Em seguida o algoritmo de agrupamento (*k-means*) agrupou os dados dos medidores de forma a definir dois clusters, onde um deles correspondeu aos medidores que estão longe da região que ocorreu o distúrbio e o outro, correspondeu aos medidores que estavam localizados próximos da região de ocorrência do distúrbio. Na segunda etapa, um sistema baseado em regras determinou qual dos clusters abrangeu o nó de origem. No entanto, quando o algoritmo determinou uma região muito grande, essa região é introduzida recursivamente, como entrada da metodologia desenvolvida, para refinar a região de localização. O sistema resultante foi capaz de estimar a região de localização com uma taxa de acerto acima de 90%. Assim, o método teve sua concepção adequada ao empregado nos centros de controle e operações de concessionárias de energia elétrica, visando apoiar a decisão do corpo técnico para que ações corretivas fossem estabelecidas de forma assertiva.

Palavras Chave: Aprendizado de Máquina; Classificação dos Distúrbios de VTCDs; Localização das Fontes Causadoras de VTCDs; Qualidade de Energia Elétrica; Smart Grid; Smart Meter; Variação de Tensão de Curta Duração.

ABSTRACT

BORGES, Fábio Anderson Silva. **Hybrid Method Based on k-means Algorithm and Decision Rules for Short-Duration Voltages Source Location in the Context of Smart Grid**. 2017. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

In the Smart Grids context, the correct location of short-duration voltage variations sources is not a trivial task, because of the short duration of these events and for rapid propagation in the distribution feeder. In this sense, aiming to develop a recursive hybrid method based on machine learning area tools (clustering algorithm and rule base) that is able to locate the sources of short-duration voltage variations, it was used data from smart meters installed along the distribution feeder. The recursive hybrid method, as input, received the disturbance characteristics provided by the meters installed in the system. Thus, this thesis aimed to development of a measurement hardware for signal acquisition, detection, classification through a real-time operating system. Then, k-means clustering algorithm grouped the meters data in order to define two clusters, where one of them corresponded to the meters that were distant from the region that occurred the disturbance and the other one corresponded to the meters, which were located near to the disturbance occurrence region. In a second step, a rule-based system determined which of the clusters corresponded to the source node. When the algorithm determined a very large region, that region was recursively introduced as input of the developed methodology to decrease its size. The resulting system was able to estimate the location region with a accuracy above 90%. Therefore, this method showed a suitable design for employment by operation control centers of power sector concessionaires, aiming to support technical staff decision to stablish assertive corrective actions.

Keywords: Electric Power Quality; Classification of Disturbances, Machine Learning, Power Quality Disturbances Classification; Smart Grid; Smart Meter; Sag Source Location; Short-Duration Voltage Variations;

Lista De Figuras

Figura 1.1 – Curva de sensibilidade para equipamentos eletrônicos CBEMA.....	26
Figura 3.1 – Diagrama do Sistema IEEE 34 <i>Node Test Feeder</i>	46
Figura 3.2 – Representação do esquema curto-circuito modelado.	49
Figura 3.3 – Afundamento de Tensão ocasionado a partir de um curto-circuito trifásico.....	50
Figura 3.4 – Afundamento de Tensão ocasionado a partir de um curto-circuito monofásico, envolvendo a fase C.	50
Figura 3.5 – Afundamento de Tensão ocasionado a partir de um curto-circuito fase-fase-terra, envolvendo a fase C e fase B.	51
Figura 3.6 – Interrupção de Tensão ocasionada pela operação do sistema de proteção.....	53
Figura 3.7 – Elevação de Tensão ocasionada pela conexão de um banco de capacitores.....	55
Figura 3.8 – Comparação dos valores RMS, Valor de Pico, Fator de Pico e Valor Médio extraídos do evento de Afundamento de Tensão(a) e Elevação de Tensão (b).....	58
Figura 4.1 – Distribuição com Assimetria: (a) negativa, (b) nula e (c) positiva.	66
Figura 4.2 – Distribuição com Curtose: (a) leptocúrtica, (b) normal e (c) platicúrtica.....	66
Figura 4.3 – Matriz de cor resultante da simulação curto-circuito trifásico envolvendo o nó 802.....	68
Figura 4.4– Matriz de cor agregada para característica RMS extraída das simulações de curto-circuito trifásicos de 10 Ω	69
Figura 4.5 – Gráfico de linhas que confronta a média das características RMS obtidas das simulações de curto-circuito trifásico com resistência de 10 Ω (azul) e 50 Ω (vermelho).	70
Figura 4.6- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica RMS, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.	76
Figura 4.7- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Valor de Pico, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.....	77

Figura 4.8 – Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Fator de Pico, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.	78
Figura 4.9 – Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Valor Médio, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.	79
Figura 4.10 – Matriz de cores da Característica RMS resultante das simulações de curtos-circuitos trifásicos de 1 Ω (a) 10 Ω (b), 20 Ω (c), 30 Ω (d), 40 Ω (e) e 50 Ω (f) com ângulo de incidência 0°.	81
Figura 4.11 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica RMS extraídas das simulações de curto-circuito trifásico com resistência de 1 Ω ,10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω com ângulo de incidência 0°.	82
Figura 4.12 – Matriz de Cores da Característica Fator de Pico resultante das simulações de curtos-circuitos trifásicos de 1 Ω (a) 10 Ω (b), 20 Ω (c), 30 Ω (d), 40 Ω (e) e 50 Ω (f) com ângulo de incidência 0°.	83
Figura 4.13 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da Característica Fator de Pico extraída das simulações de curto-circuito trifásico com resistência de 1 Ω ,10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω com ângulo de incidência 0°.	84
Figura 4.14 – Matriz de Cores da Característica Valor Médio resultante das simulações de curtos-circuitos trifásicos de 1 Ω (a), 10 Ω (b), 20 Ω (c), 30 Ω (d), 40 Ω (e) e 50 Ω (f) com ângulo de incidência 0°.	85
Figura 4.15 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da Característica Valor Médio extraída das simulações de curto-circuito trifásico com resistência de 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω com ângulo de incidência 0°.	86
Figura 4.16 – Matriz de cor para característica RMS para simulações de curtos-circuitos trifásicos de 10 Ω com ângulo de fase de 0°(a), 90°(b).....	87
Figura 4.17 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica RMS extraídas das simulações de curto-circuito trifásico com resistência de 10 Ω e ângulo de fase 0° e 90°.....	88
Figura 4.18 – Matriz de cor para característica Fator de Pico para simulações de curtos-circuitos trifásicos de 10 Ω com ângulo de fase de 0°(a) e 90°(b).....	88

Figura 4.19 – Matriz de cor para característica Valor Médio para simulações de curtos-circuitos trifásicos de 10 Ω com ângulo de fase de 0°(a) e 90°(b).	89
Figura 4.20 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica Fator de Pico extraídas das simulações de curto-circuito trifásico com resistência de 10 Ω e ângulo de fase 0° e 90°	90
Figura 4.21 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica Valor Médio extraídas das simulações de curto-circuito trifásico com resistência de 10 Ω e ângulo de fase 0° e 90°	90
Figura 4.22 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da característica RMS das simulações de curto-circuito trifásico, bifásicos e monofásico com resistência de 10 Ω e ângulo de fase 0°.	91
Figura 4.23 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da característica Fator de Pico das simulações de curto-circuito trifásico, bifásicos e monofásico com resistência de 10 Ω e ângulo de fase 0°	92
Figura 4.24 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da característica Valor médio das simulações de curto-circuito trifásico, bifásicos e monofásico com resistência de 10 Ω e ângulo de fase 0°.	92
Figura 4.25- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica RMS, extraídas das simulações que modelam chaveamento de banco de capacitor.	96
Figura 4.26- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Fator de Pico, extraídas das simulações que modelam chaveamento de banco de capacitor.....	97
Figura 4.27- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Valor Médio, extraídas das simulações que modelam chaveamento de banco de capacitor.....	97
Figura 5.1 – Hardware para detecção e classificação dos distúrbios de VTCDs. ...	104
Figura 5.2 – Esquema da bancada que foi utilizado para os testes de aquisição do sinal de entrada.	107
Figura 5.3– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal normal.....	108

Figura 5.4– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal com ruído.....	109
Figura 5.5– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal contendo afundamento de tensão.....	110
Figura 5.6 – Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal contendo elevação de tensão.	111
Figura 5.7– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal contendo interrupção de tensão.....	112
Figura 5.8 – Escalonamento das tarefas para a execução do programa implementado utilizando um RTOS.....	114
Figura 5.9 – Escalonamento das threads utilizadas pelo TI-RRTOS.....	116
Figura 5.10 – Diagrama esquemático dos passos do algoritmo embarcado.	117
Figura 5.11 – Escalonamento das interrupções de aquisição e detecção.	121
Figura 5.12 – Escalonamento de execução das rotinas IHW e ISW.....	124
Figura 5.13 – Rotina de detecção para uma taxa de amostragem de 128 pontos/ciclo	125
Figura 6.1 – Dados de entrada (a) e Padrões descobertos de acordo com a forma, tamanho e densidade (b)	135
Figura 6.2 – Comparação da saída obtida de diversos algoritmos de <i>clusterização</i> a partir de diferentes entradas.....	137
Figura 6.3 - Ilustração do algoritmo <i>K-means</i> . (a) Dados de entrada bidimensionais com dois pontos iniciais que definem os centróides; (b) definição dos objetos que compõem cada <i>cluster</i> ; (c) atualização dos centróides; (d)—(h) iterações intermediárias atualizando rótulos de <i>cluster</i> e seus centros; (i) agrupamento final	139
Figura 6.4 – Gráfico Dispersão e Distribuição das características RMS e Valor Médio extraídas a partir de um curto-circuito trifásico no nó 802.	143
Figura 6.5 – Gráfico Dispersão e Distribuição das características RMS e Valor Médio calculados a partir de um curto-circuito trifásico no nó 850.....	144
Figura 6.6 – Gráfico Dispersão e Distribuição das características RMS e Fator de Pico extraídas a partir de um curto-circuito trifásico no nó 852.....	144

Figura 6.7 – Gráfico Dispersão e Distribuição das características RMS e Fator de Pico extraídas a partir de um curto-circuito trifásico no nó 846.....	145
Figura 6.8 – Estrutura geral da metodologia empregada para localização da origem dos distúrbios de VTCDs.	147
Figura 6.9 – Diagrama de blocos do sistema de localização Híbrido Recursivo baseado no algoritmo <i>K-means</i> e Regras de decisão.	155
Figura 7.1 – Desempenho do método de detecção para as janelas de transição sintéticas adquiridas sobre uma taxa de amostragem de 64 amostras/ciclo.	165
Figura 7.2 – Desempenho do método de detecção para as janelas de transição obtidas em laboratório adquiridas sobre uma taxa de amostragem de 64 amostras/ciclo.	167
Figura 7.3 – Árvore de Decisão obtida pelo WEKA.....	168
Figura 7.4 – Diagrama de blocos que representa a rotina Implementada para testes.	171
Figura 7.5 – Comparação dos valores de Distâncias estimadas com a distância esperada para curto-circuito trifásico.	180
Figura 7.6 – Comparação dos valores de Distâncias estimadas com a distância esperada para curto-circuito monofásico na Fase A (a), Fase B(b) e Fase C(c).	181
Figura 7.7– Comparação dos valores de Distâncias estimadas com a distância esperada para curto-circuito Bifásico na Fase AB (a), Fase AC(b) e Fase BC(c).	182

Lista de Tabelas

Tabela 3.1 - Tensão por fase para cada elemento do sistema IEEE 34 barras.	47
Tabela 3.2 – Parâmetros Variáveis nas Simulações que ocasionam Afundamento de Tensão.	52
Tabela 3.3 – Parâmetros Variáveis nas Simulações que ocasionam Interrupção de Tensão.	54
Tabela 4.1 – Matriz dos vetores agregados da Simulação de um Curto-circuito Trifásico no nó 802 com resistência de 10 Ω e ângulo de incidência igual a 0°.	64
Tabela 4.2 – Quadro do conjunto de Característica RMS resultantes das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.	73
Tabela 4.3 - Quadro do conjunto de Característica Valor de Pico resultantes das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.	73
Tabela 4.4 - Quadro do conjunto de Característica Fator de Pico resultantes das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.	73
Tabela 4.5 - Quadro do conjunto de Característica Valor Médio resultante das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.	74
Tabela 4.6 – Quadro do conjunto de Característica RMS resultantes das simulações que modelam chaveamento de banco de capacitor.	94
Tabela 4.7 – Quadro do conjunto de Característica Valor de Pico resultante das simulações que modelam chaveamento de banco de capacitor.	94
Tabela 4.8 – Quadro do conjunto de Característica Fator de Pico resultante das simulações que modelam chaveamento de banco de capacitor.	94
Tabela 4.9 – Quadro do conjunto de Característica Valor Médio resultantes das simulações que modelam chaveamento de banco de capacitor.	95
Tabela 5.1- Equações sintéticas que modelam os distúrbios de VTCDs.	106
Tabela 5.2 – Velocidade do método de detecção de acordo com a taxa de amostragem.	123
Tabela 6.1 – Dados resultantes dos pontos de medição para simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicado no nó 852.	150
Tabela 6.2 – Dados resultantes após etapa de agregação de Fase para simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicando no nó 852.	151

Tabela 6.3 – Região de Interesse obtida a partir da simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicando no nó 852.....	153
Tabela 6.4 – Representação dos dados resultantes da simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicando no nó 852 após os passos de remoção, agregação e normalização.....	154
Tabela 6.5 – Vetor das características analisadas para induzir o conjunto de Regras de Decisão.....	158
Tabela 7.1 - Resultado da Detecção para janelas adquiridas com taxa de amostragem de 64 amostras/ciclo.....	164
Tabela 7.2 - Resultado do método de Classificação para distúrbios sintéticos.	169
Tabela 7.3 – Resultado do método de Classificação para distúrbios obtidos em laboratório.	169
Tabela 7.4 – Casos de simulação errôneas detectados na fase de agregação.	174
Tabela 7.5 –Comparação entre a taxa de acerto e número de regras para Rotina#1 e Rotina#2.....	175
Tabela 7.6 – Desempenho da Regra de Decisão para simulação de afundamento de tensão em relação ao parâmetro <i>minNumObj</i> utilizando 80% dos casos para treinamento.	177
Tabela 7.7 –Base de Regras para localização dos distúrbios de Afundamento de Tensão induzida a partir dos parâmetros definidos no Teste#16.....	178
Tabela 7.8 – Casos de simulação com erro.....	180
Tabela 7.9 –Base de Regras induzida para localização dos distúrbios de Interrupção de Tensão.	183
Tabela 7.10 – Desempenho da Regra de Decisão de acordo com o valor do parâmetro <i>minNumObj</i> e <i>ConfidenceFactor</i> para localização dos eventos de Elevação de Tensão.....	185
Tabela 7.11 –Base de Regras induzida no Teste#3.....	185
Tabela 7.12 – Instancias errôneas para localização dos eventos de Elevação de Tensão.	186

Lista de Siglas

CBEMA	<i>Computer Business Equipment Manufacturers Association</i>
FAT	<i>File Allocation Table</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IHW	Interrupção de Hardware
ISW	Interrupção de Software
ITIC	<i>Information Technology Industry Council</i>
QEE	Qualidade de Energia Elétrica
RMS	Root Mean Square
RTOS	<i>Real Time System Operation</i>
SVM	<i>Suport Vector Machine</i>
TCP/IP	<i>Transmission Control Protocol/Internet Protocol</i>
VTCD	Variação de Tensão de Curta Duração

SUMÁRIO

1	Introdução.....	25
1.1	Motivação e Justificativa do Tema da Pesquisa.....	28
1.2	Objetivos do Projeto de Doutorado	31
1.3	Principais Contribuições.....	32
1.4	Organização	33
2	Estado da Arte	35
2.1	Classificação dos distúrbios de QEE.....	36
2.2	Identificação dos locais de origem dos distúrbios de QEE	36
2.3	Smart grid e Smart Meter	41
2.4	Considerações Finais do Capítulo.....	43
3	Modelagem e Simulação dos Eventos de VTCDs.....	45
3.1	Modelagem do Sistema IEEE 34-nós.....	46
3.2	Modelagem dos Distúrbios de Variação de Tensão de Curta Duração....	48
3.2.1	<i>Modelagem do Distúrbio de Afundamento de Tensão e Interrupção de Tensão</i>	<i>48</i>
3.2.2	<i>Modelagem do Distúrbio de Elevação de Tensão</i>	<i>54</i>
3.3	Características Analisadas no Sinal de Tensão	56
3.4	Considerações Finais do Capítulo.....	58
4	Análise das Simulações.....	61
4.1	Ferramentas Utilizadas para Análise do Padrão de Propagação dos Distúrbios de VTCDs.....	62
4.1.1	<i>Métricas Estatísticas.....</i>	<i>63</i>
4.1.2	<i>Visualização de Dados</i>	<i>67</i>
4.2	Análise de Simulações que Ocasionalmente Distúrbios de VTCDs.....	71
4.2.1	<i>Análise das Simulações que Modelam Curto-Circuito</i>	<i>71</i>
4.2.2	<i>Análise de Simulações Ocasionalmente pelo Chaveamento de Banco de Capacitores</i>	<i>93</i>
4.3	Conclusões sobre o Estudo Referente à Distribuição dos Valores de Características	98
4.4	Considerações Finais do Capítulo.....	101
5	Hardware Desenvolvido.....	103
5.1	Aspectos do Hardware	104
5.2	Aspectos da Implementação do Sistema de Monitoramento de VTCDs.....	113
5.3	Algoritmo Embarcado.....	117
5.3.1	<i>Algoritmo de Detecção</i>	<i>119</i>
5.3.2	<i>Classificação dos Distúrbios de VTCDs</i>	<i>126</i>
5.4	Considerações Finais do Capítulo.....	128
6	Método de Localização Das Fontes Causadoras De VTCDs.....	131
6.1	Aprendizagem de Máquina	132
6.2	Algoritmo de Agrupamento k-means.....	134

6.3	Aplicação do k-means para Análise das Características dos Distúrbios de VTCDs.	141
6.4	Metodologia proposta	147
6.4.1	<i>Tratamento e Agregação dos Dados</i>	148
6.4.2	<i>Algoritmo Híbrido Recursivo Baseado no Algoritmo K-means Combinado com Regras de Decisão</i>	154
6.5	Considerações Finais do Capítulo.	160
7	Resultados	163
7.1	Resultados do Método de Detecção.....	164
7.2	Resultados do Método de Classificação.....	167
7.3	Rotina de Testes Implementada para Validar o Método de Localização de Origem de VTCDs.	170
7.4	Resultados da Abordagem Proposta para Localização dos Distúrbios de Variações de Tensões de Curta Duração.....	172
7.4.1	<i>Resultados Fase Agregação</i>	173
7.4.2	<i>Resultados do Método de Localização dos Distúrbios para Eventos de Afundamento de Tensão</i>	175
7.4.3	<i>Resultados do Método de Localização dos Distúrbios para Eventos de Interrupção de Tensão</i>	183
7.4.4	<i>Resultados do Método de Localização dos Distúrbios para Eventos de Elevação de Tensão</i>	184
7.5	Considerações Finais do Capítulo	186
8	Considerações Finais	189
8.1	Conclusões.....	189
8.2	Trabalhos Futuros.....	192
	Referências	193

1 Introdução

Um evento de Qualidade da Energia Elétrica (QEE) corresponde como qualquer evento que altere as características de tensão, corrente ou frequência do sistema elétrico e que resultam no funcionamento inadequado dos equipamentos conectados na rede elétrica [1]. Esta área tem sido alvo de diversas pesquisas, principalmente, no que diz respeito aos distúrbios que afetam a tensão e/ou corrente do sistema.

Com relação à necessidade de melhorar a QEE, o IEEE determina por meio da recomendação IEEE Std. 1159-2009 [2], técnicas para medir, quantificar e interpretar estes eventos. Já no Brasil, os Procedimentos de Distribuição de Energia Elétrica do Sistema Elétrico Nacional (PRODIST) [3], em seu 8º módulo, é responsável pela padronização da QEE.

De acordo com [2] os distúrbios que afetam os padrões estabelecidos pela QEE podem ser categorizados como: variação de tensão de curta duração, variação de tensão de longa duração, transitórios e distorções na forma de onda, variação de frequências e desequilíbrio de tensão.

As Variações de Tensão de Curta Duração (VTCDs) se destacam por corresponder aos eventos mais comuns de QEE [1], [2], sendo que sua ocorrência pode acarretar grandes prejuízos para o consumidor. A norma IEEE Std 1159-2009 [2] define as VTCDs como sendo desvios no valor eficaz da tensão em curtos intervalos de tempo com duração entre 1 ciclo e 1 minuto, sendo classificadas de acordo com a duração de ocorrência e amplitude do sinal.

Com relação à duração, elas são especificadas como: variação instantânea (superior a 0,5 e inferior a 30 ciclos), variação momentânea (superior a 30 ciclos e inferior a 3 segundos) e variação temporária (superior a 3 segundos e inferior a 1 minuto). Com relação à amplitude, as VTCDs são classificadas como: interrupção de tensão, afundamento de tensão e elevação de tensão.

O distúrbio de interrupção corresponde a uma variação da tensão abaixo de 0,1 p.u. do valor eficaz da tensão nominal e são resultados de curtos-circuitos no

sistema de energia. Já o afundamento corresponde a uma redução da amplitude da tensão, entre 0,9 e 0,1 p.u. do valor eficaz da tensão nominal. Esse distúrbio destaca-se por ser o evento que mais se manifesta nas redes elétricas [4], sendo ocasionados por curtos-circuitos ocorridos nas redes de distribuição de energia, energização de grandes cargas e magnetização de transformadores [2].

Sinais que apresentam uma variação de acima de 1,1 p.u. são denominados como elevações de tensão. A elevação está associada às abruptas falhas no sistema ou decréscimo na absorção de correntes por cargas indutivas, assim como, chaveamento de grandes bancos de capacitores.

Esses três tipos de distúrbios podem ser refletidos nas concessionárias, nos consumidores próximos à fonte causadora, bem como no próprio estabelecimento gerador. De forma geral, as ocorrências destes distúrbios podem ocasionar prejuízo aos consumidores, uma vez que as cargas conectadas na rede possuem restrita tolerância em relação à tensão de alimentação. Assim, caso não haja meios específicos de controle, qualquer sistema estará vulnerável a estes problemas.

A sensibilidade e susceptibilidade das cargas em função da amplitude e duração do sinal de tensão pode ser descrita por meio das curvas CBEMA (*Computer Business Equipment Manufacturers Association*) [5] e curva ITIC (*Information Technology Industry Council*) [6], sendo que esta última corresponde a uma modificação da curva CBEMA para melhor caracterizar a sensibilidade dos computadores. A Figura 1.1 ilustra o gráfico da curva ITIC.

Figura 1.1 – Curva de sensibilidade para equipamentos eletrônicos CBEMA

Fonte: Adaptado de [6]

O gráfico apresentado na Figura 1.1 pode ser dividido em três regiões distintas. A região “A” corresponde à operação normal, onde a ocorrência de eventos dentro dos valores estabelecidos nessa área não representa problemas aos equipamentos. A área “B” destaca a região de susceptibilidade, nessa situação ocorrem os eventos de elevação de tensão que provocam danos aos equipamentos. Por sua vez, o espaço “C” é denominado de região de sensibilidade e destaca a ocorrência de afundamentos e interrupções, os quais podem ocasionar a parada da operação dos equipamentos.

A partir dessa breve introdução a respeito dos distúrbios de variação de tensão de curta duração, verifica-se que estes distúrbios acarretam em perdas consideráveis aos equipamentos conectados à rede. Por esta razão, é de extrema importância a identificação e localização do distúrbio de VTCD, pois, somente assim, ações corretivas poderão ser tomadas para mitigar ou até mesmo extinguir o distúrbio.

A tarefa de detecção e identificação corresponde em analisar o sinal de tensão com intuito de detectar anomalias na forma de onda senoidal que configurem afundamento de tensão, elevação de tensão e interrupção de tensão. Por outro lado, a localização destes eventos consiste em apontar, no sistema de distribuição, o nó onde ele foi originado. Ambas as tarefas são de fundamental importância para melhoria dos índices de QEE.

Por esse motivo existe uma grande quantidade de pesquisas sendo executadas com o objetivo de propor métodos que auxiliem na detecção, identificação e localização dos distúrbios de VTCDs, para fim de melhorar os índices de QEE. Porém, considerando as técnicas encontradas na literatura, é pertinente avaliar que não existe um consentimento sobre uma abordagem a ser utilizada para a localização dos distúrbios de VTCDs, principalmente um método que se adeque as características de monitoramento em tempo real, disponibilizados nas redes de distribuição modernas, denominadas *smart grids*.

Esse monitoramento tem um papel fundamental, pois é por meio da análise dos dados medidos no sistema de energia que será possível compreender e localizar o problema na rede e com isso propor métodos que melhorem a entrega do serviço.

Nesse contexto, esta tese pretende desenvolver uma nova metodologia, que determine o local de origem do distúrbio de VTCD, por meio da análise das características extraídas dos distúrbios detectados em vários pontos do sistema

durante a ocorrência do evento, as quais podem vir a serem fornecidas a partir da infraestrutura de medição provenientes das *smart grids*.

Após uma breve introdução à temática dessa tese (localização das fontes causadoras de VTCDs no contexto de *Smart grids*), serão apresentados a seguir a motivação e justificativa de tal pesquisa (Seção 1.1), os objetivos a serem atingidos (Seção 1.2), as principais contribuições advindas desta pesquisa (Seção 1.3) e, por fim, a organização do texto (Seção 1.4).

1.1 Motivação e Justificativa do Tema da Pesquisa

As tarefas de detecção, identificação e localização dos distúrbios de VTCDs não são triviais, visto que os distúrbios de VTCDs ocorrem em um curto intervalo de tempo e se propagam ao longo de todo sistema.

Os primeiros métodos desenvolvidos, para finalidade de localização [7] [8], determinam se o distúrbio de afundamento de tensão foi originado a jusante ou a montante do medidor. Para um resultado mais preciso, esses métodos devem utilizar informações em vários pontos de monitoramento em conjunto.

Porém, em sua maioria os medidores instalados no sistema de distribuição estão localizados na subestação de energia, dificultando o monitoramento em tempo real das grandezas elétricas.

No processo de desenvolvimento de uma rede elétrica mais eficiente, emergiu o conceito das chamadas *smart grids* (redes inteligentes). A *smart grid* é uma rede elétrica que faz uso de tecnologia da informação para conectar a geração de energia, transmissão, distribuição e consumidores usando tecnologias de comunicação de informação e ela preconiza fornecer energia com altos índices de confiabilidade, continuidade e segurança. [9], [10].

Para isto, tais redes propõem vários paradigmas para modernizar a rede de energia elétrica, dentre eles destacam-se a implementação de uma tecnologia de comunicação moderna e segura, que incluem medidores inteligentes (*smart meters*), canais de comunicação e dispositivos de controle. Consequentemente, a partir dessa infraestrutura, será possível integrar os componentes da rede de energia para fim de viabilizar serviços e informações em tempo real tanto para os consumidores como para as concessionárias de energia [9]–[12].

A análise destes dados fornecidos pela infraestrutura de medição poderia auxiliar no desenvolvimento de uma série de aplicações [9], [10], [13]. Partindo-se desta infraestrutura de medição, torna-se possível o uso de dados disponíveis por *smart meters* para aprimorar as análises em termos da Qualidade da Energia Elétrica que é entregue aos consumidores.

Dessa forma, os dados advindos do sistema de monitoramento distribuído, disponibilizados pela *smart grid*, poderiam ser utilizados para auxiliar na localização destes distúrbios.

O monitoramento, a fim de diagnosticar e localizar as fontes dos distúrbios de VTCDs corresponde à primeira etapa para que por meio da análise dos dados seja possível apontar o tipo de distúrbio presente na rede e o local de origem. Assim, as possíveis causas do problema podem ser determinadas e, a partir disso, medidas corretivas são aplicadas.

Diante dessa realidade, é de extrema importância propor métodos que alcance uma boa localização a partir de características extraídas do sinal de tensão e corrente que possam a vir a ser fornecidas por estes sistemas, diminuindo o custo computacional dos medidores e consequentemente o custo de instalação e operação do sistema de monitoramento.

Na literatura existem alguns trabalhos que são apresentados no Capítulo 2 que utilizam a análise coordenada de vários medidores. Porém, estes métodos apesar de empregarem técnicas contemporâneas necessitam de algumas informações detalhadas do sistema, o que acarreta um aumento no tráfego de dados desta rede, aumentando o custo para implementação dos métodos. Adicionalmente, conforme mencionado em [14], os medidores eletrônicos comercializados até o momento não fornecem meios para disponibilizar informações detalhadas dos distúrbios de VTCDs.

Nesse contexto, a principal motivação desta tese consiste no desenvolvimento de uma metodologia acessível que possa ser utilizada sobre o contexto de *smart grid*, a qual tem como objetivo principal localizar a região, no sistema de distribuição, onde o distúrbio de VTCD foi originado.

De acordo com [2], no momento em que ocorre um distúrbio, as formas de onda de tensão e corrente serão alteradas e, desta forma, o distúrbio originado em um determinado ponto do sistema de distribuição é disseminado ao longo dos nós que compõem a rede elétrica com diferentes características. Sendo assim, o confronto

entre as características extraídas desse distúrbio detectado em diferentes pontos fornece informações que podem viabilizar a identificação do local de origem.

Para isto, justifica-se o desenvolvimento de um método baseado em algoritmo de aprendizagem de máquinas que correlaciona técnica de aprendizado não-supervisionado com uma técnica de aprendizado supervisionado. O algoritmo desenvolvido será encarregado por analisar de forma automática características extraídas dos distúrbios de VTCDs disseminados na rede e detectados em vários pontos do sistema, e inferindo sobre o padrão de propagação do evento e, por conseguinte determinando, a região de origem.

A propagação do evento em relação à sua origem depende de vários fatores como: topologia da rede, intensidade do distúrbio e localização da fonte causadora em relação à subestação, sendo que a cada nova configuração um novo padrão é evidenciado.

No contexto de localização das fontes geradoras de eventos de VTCDs, as técnicas de aprendizagem de máquinas não supervisionada têm a capacidade de inferir a cada novo padrão de características fornecidas pelos *smart meters* de modo a correlacionar as entradas de acordo com o grau de similaridade. Isso significa agrupá-los em *clusters* para que estes pareçam mais simples ou mais organizados, facilitando na descoberta do local de origem do distúrbio. Por fim, um sistema baseado em regra de decisão é proposto para apontar qual grupo abrange o ponto de origem.

Com isto, almeja-se que o método alcance uma boa precisão, garantindo uma mitigação mais rápida. Adicionalmente, o agrupamento é realizado de acordo com o estado atual do sistema, portanto não sofre influências de outras topologias ou condições de operação.

Por conseguinte, os dados de entrada devem ser formados por características que descrevem o distúrbio e, portanto, devem ser simples para que possam ser facilmente fornecidas e implementadas pelos medidores inteligentes. Assim, em vez de enviar a forma de onda da tensão para o centro de controle, somente a informação sobre o evento detectado em um determinado instante será fornecido, reduzindo o tráfego de dados.

Logo, a metodologia proposta nesta tese se baseia no processamento e extração de características dos sinais de tensão provenientes dos medidores eletrônicos. De modo complementar, as características mais relevantes extraídas do

sinal de tensão seriam obtidas de forma que houvesse baixo custo computacional para que a metodologia possa ser implementada em hardwares de baixo custo.

Fundamentado nesses fatores a relevância dessa pesquisa de doutorado não se resume apenas à localização e identificação dos barramentos causadores de VTCDs, mas também, torna-se de extrema importância determinar um conjunto de características que possibilitem evidenciar o padrão de propagação do distúrbio na rede de distribuição.

Em consequência disso essa tese pretende também avaliar a viabilidade da construção de uma arquitetura de hardware, a qual possa vir a ser empregada para detectar e classificar os distúrbios de VTCDs, disponibilizando informações a respeito das características extraídas do distúrbio detectado a partir de um canal de comunicação.

A abordagem embarcada em hardware será concebida a partir da utilização de um sistema operacional de tempo real (*Real Time Operating System* - RTOS), o qual será encarregado de monitorar as múltiplas tarefas realizadas pelo hardware garantindo um tempo de resposta rápido e condizente com a identificação do distúrbio de VTCD.

Logo, a completa investigação de todas as abordagens torna este trabalho de doutorado original e inovador sob o ponto de vista científico.

1.2 Objetivos do Projeto de Doutorado

O objetivo geral desta pesquisa consiste em desenvolver uma metodologia para localização automática das fontes que originam distúrbios de variações de tensão de curta duração em sistemas de distribuição, por meio da análise das características dos distúrbios detectados por *smart meters*.

O algoritmo desenvolvido será capaz de interpretar estes dados, para então, estimar o trecho, o local, ou à distância (relativa à subestação) em que ocorreu o defeito. Para este efeito será necessário detectar, classificar e extrair características dos distúrbios de VTCDs medidos nos *smart meters*.

A tecnologia desenvolvida para localização tratará de forma integrada tanto as técnicas convencionais para pré-processamento de sinais de tensão, bem como os algoritmos de aprendizagem de máquinas, principalmente algoritmos de agrupamento

de dados. Dessa forma, os objetivos dessa pesquisa podem ser pontuados da seguinte maneira:

- Obtenção de heurísticas a respeito de fatores que comumente afetam o problema abordado como, natureza e características da fonte que origina os distúrbios de VTCDs; a posição da fonte em relação à subestação; a variabilidade da estrutura do sistema; incorporando tais informações adquiridas ao método desenvolvido, para fim de mitigar seus impactos.
- Análise de um conjunto de características simples e compactas das formas de onda de tensão que permitam inferir como ocorre a propagação do evento presente no sistema e que preservem as informações úteis dos dados originais, permitindo assim, diminuir o esforço desempenhado na obtenção dos atributos.
- Projetar e disponibilizar uma plataforma em hardware responsável por detectar e classificar os distúrbios de VTCDs e também transmitir as características necessárias por meio de um canal de comunicação.
- Investigar um método baseado em algoritmos de aprendizagem de máquina capaz de estimar a localização da fonte geradora de distúrbios de VTCD, em um sistema de distribuição, a partir da gestão dos dados que são enviados pelo *smart meter*.
- Permitir que a tecnologia de detecção, classificação e localização de fontes causadoras de VTCDs possam ser testadas e validadas sobre diferentes situações.

Dessa forma, pretende-se contribuir de maneira expressiva na linha de pesquisa sobre localização de VTCDs nas *smart grids*, tanto pela proposição de novos estudos e métodos a serem utilizados em *smart grids* como pela análise da robustez dos métodos de localização dos distúrbios de VTCDs.

1.3 Principais Contribuições

Esta tese de doutorado pretende fornecer as seguintes contribuições:

- Exposição de um estudo a respeito de como ocorre a propagação dos distúrbios de VTCDs, considerando variáveis extraídas dos distúrbios que foram caracterizados na rede.

- Proposta de implementação em hardware de um sistema capaz de detectar e classificar os distúrbios de VTCDs, onde se emprega um sistema operacional de tempo real para garantir um tempo de resposta adequado para as tarefas a serem implementadas pelos *smart meter*.
- Desenvolvimento de uma ferramenta que possibilite a localização mais precisa das fontes causadoras de variações de tensão de curta duração, a qual leve em considerações os dados advindos dos *smart meters*.
- Disponibilizar um banco de informações com dados a respeito das simulações que ocasionam eventos de VTCDs e que poderão ser utilizados em diversas outras pesquisas.

1.4 Organização

O trabalho está organizado em oito capítulos principais. Desta forma, o Capítulo 1 foi direcionado a introduzir o tema desta pesquisa, bem como apresentar as motivações e justificativas que levaram à realização da pesquisa.

O Capítulo 2 destina-se ao estado da arte, assim como serão analisadas em detalhes as publicações mais recentes relacionadas com a proposta desta tese.

O Capítulo 3 apresenta as características do sistema de distribuição estudado, bem como os aspectos da modelagem que ocasionam os eventos de afundamento de tensão, elevação de tensão e interrupção. Por fim, destacam-se as características que serão extraídas do sinal de tensão durante a ocorrência do distúrbio.

O Capítulo 4 explana em detalhes o estudo responsável por averiguar se o conjunto das características extraídas dos distúrbios possuem a capacidade de evidenciar seu padrão de propagação no sistema de distribuição. Para isto, o conjunto de características é analisado por meio de métricas estatísticas e ferramentas de visualização de dados.

O Capítulo 5 destaca a arquitetura de hardware concebida para detecção e classificação dos distúrbios de VTCD. O método foi embarcado em hardware a partir de um Sistema Operacional em Tempo Real.

No Capítulo 6 será descrita a metodologia proposta para a localização e identificação dos distúrbios de qualidade de energia elétrica. Assim, serão

apresentados todos os passos do algoritmo proposto destacando, principalmente, o método de agrupamento de dados.

No Capítulo 7, serão apresentados os resultados que validam a eficácia do hardware desenvolvido e também serão discutidos os resultados que comprovam a eficácia do algoritmo de localização dos distúrbios de VTCDs.

Por fim, cabe ao Capítulo 8 fornecer as conclusões sobre todo o trabalho e as perspectivas de trabalhos futuros.

2 Estado da Arte

As pesquisas relacionadas ao monitoramento dos distúrbios de qualidade de energia elétrica podem ser divididas em duas áreas principais: a primeira área destina-se a desenvolver métodos para detecção e classificação dos distúrbios de QEE. Dessa forma, a segunda é responsável por identificar os locais de origem dos distúrbios de QEE. Com relação à identificação dos locais de origem dos distúrbios de qualidade de energia que ocorrem no sistema elétrico, há um progresso limitado, devido a vários desafios técnicos [15], os quais incluem:

- 1) Distúrbios ocasionados por faltas não são fáceis de detectar durante sua propagação ao longo da rede elétrica;
- 2) Medidores de QEE apresentam um alto custo;
- 3) Os melhores locais de medição não são fáceis de determinar.

Devido a estas dificuldades é que se faz necessário encontrar um método seguro e eficaz de se determinar os locais de origem do distúrbio no sistema. Grandes avanços podem ser alcançados a partir da aplicação de *smart meter*, os quais consistem em um medidor utilizado na rede *smart grid*. Eles possuem a capacidade de disponibilizar as informações necessárias sobre o sistema de energia para o centro de controle e operação, auxiliando a realização das tarefas de classificação e localização de fontes causadoras de distúrbios de QEE.

Neste contexto, a seguir são apresentadas as publicações mais recentes e promissoras envolvendo a temática desta pesquisa. Dessa maneira, são explanados de maneira sucinta os trabalhos sobre classificação dos distúrbios de QEE; em seguida é apresentada uma revisão detalhada sobre os trabalhos que envolvem a identificação dos locais de origem dos distúrbios de VTCDs. Por fim, são abordados os conceitos básicos relacionados às redes *smart grid* e aos *smart meters*, descrevendo as características que viabilizem sua aplicação no sistema de distribuição.

2.1 Classificação dos distúrbios de QEE

Nas pesquisas relacionadas aos distúrbios de QEE podem ser destacadas as tarefas de detecção e análise de distúrbios [16]–[24], os quais na sua maioria utilizam técnicas para extração de características relevantes do sinal, utilizando ferramentas de processamento de sinais como a Transformada de *Fourier*, a Transformada *Wavelet* e a Transformada-S. As características extraídas do sinal são então utilizadas como entradas para um método de classificação de padrões, de modo a relacionar estas características com o tipo de distúrbio. Dentre os métodos mais utilizados se destacam a lógica *fuzzy*, rede neurais Artificiais, *Support Vector Machine* (SVM) e árvore de decisão.

De acordo com a literatura supracitada pode-se verificar que os algoritmos até então idealizados dificilmente poderiam ser embarcados em um hardware de baixo custo a ser utilizado em *smart grid*, pois demandariam uma alta velocidade de processamento e necessidade de um volume de memória acima do que se tem disponível.

Outro fator importante a ser considerado na tarefa de detecção e/ou classificação de distúrbios por meio de sistemas embarcados corresponde à dificuldade para identificar os distúrbios que possuem uma rápida ocorrência. Assim, é desenvolvido nessa tese de doutorado um método a ser embarcado em hardware que objetiva equilibrar o custo computacional do sistema embarcado, a velocidade de processamento, a utilização de memória, a taxa de amostragem e o acesso à interface de comunicação.

2.2 Identificação dos locais de origem dos distúrbios de QEE

Os métodos de localização dos distúrbios de qualidade de energia elétrica têm como finalidade indicar o local no sistema de distribuição que está conectada a fonte que originou o distúrbio. A correta localização da fonte e a detecção do tipo de distúrbio é o primeiro passo para se diagnosticar o problema. Como resultado, medidas de controle podem ser executadas de modo a aumentar a qualidade de energia. De modo suplementar, a detecção do local desempenha também um papel

fundamental nas decisões a serem tomadas a respeito dos responsáveis pela ocorrência do evento na rede.

Deste modo, a localização precisa das fontes de distúrbios de QEE é muito importante e vem sendo alvos de pesquisas. Os trabalhos mais relevantes serão apresentados a seguir. Importante destacar que esses trabalhos têm como foco principalmente a localização dos eventos de afundamento de tensão, isto ocorre devido ao fato de que tal distúrbio ocorre com mais frequência na rede [2].

De um modo geral, as primeiras pesquisas para localizar as fontes de distúrbios de qualidade de energia foram desenvolvidas baseadas em um único medidor, sendo encarregadas em determinar se a origem do distúrbio está localizada em uma posição a montante ou jusante do medidor de referência.

As pesquisas mais recentes são baseadas na utilização de vários medidores e explora o uso de sistemas de monitoramento em conjunto com sistemas de telecomunicações, onde os dados capturados por eles são processados e servem de base para determinar a localização do evento [25].

Na primeira linha o trabalho proposto em [7] destaca-se por ser um dos pioneiros, em que os autores demonstram que, a partir de amostras de sinais de tensão e corrente capturadas por um medidor, é possível determinar-se o transitório ou afundamento de tensão ocorre à jusante ou à montante de um dispositivo de medição. A localização da origem do distúrbio é identificada de acordo com a análise do fluxo de energia e da potência instantânea de pico durante o período do distúrbio. A partir destes parâmetros, é então encontrada ao final do evento a energia do distúrbio e, caso seu valor seja maior que 80% do pico de energia durante a ocorrência do evento, a origem do distúrbio estará localizada após o medidor. Do contrário, a direção do evento é determinada examinando a polaridade do pico inicial do distúrbio. Para o propósito da localização, os autores ressaltam que, se vários medidores forem instalados na rede, leituras simultâneas podem ser utilizadas para localizar a fonte do distúrbio, no entanto, quando o medidor está localizado no barramento defeituoso, este método não é capaz de localizar o distúrbio.

Com base em [7], outros trabalhos tem o objetivo de determinar se a fonte que ocasiona o distúrbio está localizada a montante ou a jusante do dispositivo de medição, para isto, utilizaram técnicas de processamento de sinal que extraem características a respeito da corrente, tensão e impedância, antes, durante e depois que o evento ocorre na rede.

Em [26] é proposto um método para determinar a direção do fluxo do afundamento de tensão, de acordo com a inclinação da reta obtida pelo método dos mínimos quadrados. Essa linha é ajustada em função de dois parâmetros; sendo que o primeiro consiste no produto entre a amplitude do distúrbio e o fator de potência, ao passo que o segundo parâmetro corresponde à amplitude da corrente. Tais parâmetros são medidos durante a presença do distúrbio na rede. A estratégia adotada pelos autores baseia-se no fato de que falhas originadas em locais distintos irão produzir diferentes sinais de inclinação da reta. Portanto, esta inclinação indica a direção da fonte do afundamento de tensão, ou seja, localizado à jusante caso a inclinação seja positiva, ou então, à montante caso a inclinação seja negativa. O método é simples e de fácil implementação, uma vez que depende apenas do sinal da reta e não há necessidade de calcular outros parâmetros adicionais.

Em [27] a localização do afundamento de tensão é determinada pela análise do ângulo de fase da tensão e da corrente no início do distúrbio. O ângulo medido é multiplicado pelo cosseno do ângulo do fator de potência e caso o valor obtido seja positivo, a fonte que originou o evento está localizada a jusante, caso contrário, ela estará localizada a montante.

Em [28], a localização é determinada de acordo com o sinal da parte real da impedância equivalente, que é estimada utilizando as variações de tensões e correntes provocadas pela perturbação. A dificuldade deste método está na escolha do período de medição, antes e depois do distúrbio, que pode afetar a exatidão do resultado.

Já em [29] utiliza-se a magnitude e o ângulo de impedância para indicar de que lado do medidor o evento se origina. A informação da impedância é obtida por meio das estimativas dos relés de distâncias, os quais são utilizados para proteção. As limitações deste método residem quando a falha ocorre entre o relé de distância, pois dessa forma não haverá mudança na impedância impedindo a localização correta do distúrbio.

Em [30] é apresentado um método que compara a queda da tensão no lado primário e secundário do transformador em nível de transmissão. A queda de tensão é maior no lado onde ocorre a falta. Em [8] a localização da fonte do distúrbio é determinada de acordo com a diferença do ângulo da componente de corrente de sequência positiva antes e durante a ocorrência do distúrbio; se a diferença for positiva

a fonte de afundamento de tensão está à jusante, caso contrário ela estará localizada à montante do medidor.

Pode-se notar que os métodos correlatos são baseados no uso de medidores individuais e determinam se a origem dos distúrbios de QEE está localizada à montante ou à jusante do equipamento de medição, não sendo capaz de determinar a localização exata do distúrbio. Assim, métodos de localização a partir da utilização de vários medidores de energia, têm sido propostos de modo a suprir este problema. Normalmente, os dados recolhidos a partir dos medidores de energia são armazenados numa base de dados e depois são processados para determinar a localização do evento.

Em [31], [32], a localização do afundamento de tensão é realizada utilizando vários medidores, em que cada um é capaz de determinar se o fluxo do evento está a montante ou a jusante. Cada medidor tenta identificar a direção da fonte de acordo com a causa que originou o distúrbio, pois para cada dependendo da fonte que originou o distúrbio ele é evidenciado com características diferentes. O algoritmo proposto analisa a amplitude da corrente de falta para distúrbios causados por saturação de transformadores, o aumento da potência ativa para distúrbios ocasionados pela partida do motor de indução e a amplitude do segundo componente harmônico para distúrbios causados por curto-circuito. O método é testado em um sistema prático da Coreia e no sistema IEEE 13-nós.

Nos trabalhos [33], [34] é apresentado um algoritmo para localizar uma fonte de distúrbio de qualidade de energia em um sistema de monitoramento distribuído. O sistema é modelado por meio de uma matriz de cobertura que inclui informações sobre a topologia do sistema e por uma matriz de direção que representa as direções do evento de qualidade para cada medidor, onde essa matriz é construída toda vez que um evento ocorre na rede. A localização do evento é determinada pela multiplicação entre a matriz de cobertura e a matriz de direção, resultando em uma matriz candidata. O local da fonte é determinado pelo índice do elemento que apresenta um valor igual ao número de monitores instalados no sistema, significando assim, que o fluxo de energia de todos os monitores foi dirigido para o monitor localizado nessa posição.

O método proposto em [35] identifica o local de origem do afundamento de tensão a partir do maior desvio de tensão caracterizado em cada barra, o qual é estimado por meio de uma rede neural com função de base radial. A metodologia é validada no sistema IEEE 30 barras.

O trabalho [36] estima a tensão em cada barra do sistema utilizando um modelo de regressão multivariada. A localização da fonte que origina o distúrbio é determinada pela barra que apresenta máximo desvio de tensão e o mínimo desvio padrão. O método é validado utilizando o sistema IEEE 9 barras, possuindo 6 medidores e o sistema IEEE 30 barras, possuindo 8 medidores.

Em [37], a Transformada *Wavelet* discreta é utilizada para realizar um pré-processamento nos sinais transitórios obtidos pelo sistema de medição. A energia de cada coeficiente *Wavelet* é adotada como entrada para um sistema híbrido composto por rede neural artificial e análise de componentes principais. Tal sistema é responsável por localizar o evento na rede de distribuição.

Nessa mesma linha, [38] descreve a aplicação da Transformada-S e *Support Vector Machine* (SVM) para identificar em qual zona do sistema está localizada a fonte que gera afundamento de tensão. A Transformada-S é utilizada para extrair as características do sinal, as quais podem caracterizar a localização dos distúrbios. Em seguida, as características extraídas são utilizadas como entrada do método SVM, responsável por detectar a localização da zona que ocorre o distúrbio.

O método proposto em [15] [39] localiza a origem do afundamento de tensão e dos transitórios associados, respectivamente, à falha e ao chaveamento de banco de capacitores, com base no índice de variação de corrente, calculado nos barramentos que os medidores estão instalados. No momento em que ocorre uma falta no sistema, as formas de ondas de tensão e corrente no barramento são alteradas. Assim, segundo os autores, os barramentos que apresentam um afundamento de tensão ou transitórios mais severos estão perto do local que se originou o distúrbio e por isto ocorre uma alteração de corrente em cada barra conectada a este barramento. Com base nestes fatores, um índice de desvio de alteração de corrente pode ser calculado, em cada ramo de ligação, antes e depois do distúrbio. Assim, a zona de origem do distúrbio é encontrada por meio da comparação dos desvios atuais de corrente, medidos em cada ramo ligado aos barramentos que estão instalados os medidores.

De acordo com os trabalhos supracitados nota-se que grandes avanços podem ser almejados a partir de investimentos em uma estrutura de monitoramento e comunicação avançada. Portanto, com isso, o surgimento das redes *smart grid* tornou-se possível desenvolver medidores que permitem acesso a informações sobre alguns parâmetros da rede em tempo real.

2.3 *Smart grid e Smart Meter*

O sistema de energia elétrica utilizado hoje está ultrapassado e passa por um processo de transição devido principalmente ao aumento da demanda de energia elétrica. Essa mudança é ocasionada pelo fato de que se deseja realizar uma entrega de energia mais confiável, econômica e sustentável. A partir disso, um novo conceito de sistema de energia elétrica tem surgido sendo denominado de *smart grid*.

A *smart grid* se caracteriza por ser uma nova infraestrutura de rede de energia elétrica que é capaz de propor melhorias em relação à eficiência, confiabilidade e segurança nos sistemas de geração, transmissão e distribuição de energia. Para isto, aplica-se uma tecnologia de comunicação moderna e segura, que incluem medidores inteligentes (*smart meters*), canais de comunicação e dispositivos de controle, cujo propósito é integrar a rede elétrica para fim de viabilizar serviços e informações em tempo real tanto para os consumidores como para as concessionárias de energia [9]–[12], [40].

Várias pesquisas, a respeito das *smart grid*, têm sido desenvolvidas não só por parte da comunidade científica, como também das concessionárias de energia elétrica. Estas pesquisas propõem novos paradigmas e aplicações a serem utilizadas nesse novo conceito de rede elétrica sendo que os mais importantes são [10], [41]:

- Monitoramento e diagnóstico da rede: as *smart grid* devem fornecer uma análise avançada dos dados, mediante um sistema de gestão inteligente, que deve responder rapidamente, por meio das estratégias correspondentes, aos eventos que ocorrem em algum lugar da rede.
- Reconfiguração automática: ajuste automático na topologia da rede de distribuição, de modo a restaurar o fornecimento de energia no sistema que foi interrompido por uma falta.
- *Microgrids*: operação do sistema em ilha, a partir da conexão de um sistema de geração distribuído.
- Gestão de energia: gerenciamento da energia fornecida e consumida.

Para permitir que estas funções descritas acima estejam disponíveis é essencial prover uma infraestrutura de telecomunicação bidirecional que conecte todos os componentes da rede elétrica, sendo que os principais são: *smart meter*, sensores e atuadores, sistemas de gerenciamento de dados e microgrids. Esta infraestrutura recebe o nome de *automatic metering infrastructure (AMI)* [42], sendo

uma componente chave para a implementação das redes *smart grid*, pois as aplicações fornecidas pelas *smart grid* possuem requisitos de comunicação desafiadores [43].

A AMI é considerada uma rede de telecomunicações complexa que inclui muitos sistemas e lida com grande quantidade e gerenciamento de dados e deve contemplar alguns tipos de serviços como [44]:

- Prioridade na entrega dos dados para aplicações críticas;
- Confiabilidade do sistema de modo a prover a continuidade da comunicação;
- Segurança para combater os ataques de invasores;
- Alta taxa de dados para envio de informações.

Basicamente, dois tipos de infraestruturas de comunicação são utilizados na AMI. O primeiro corresponde ao fluxo de informação entre os aparelhos presentes nas residências e o *smart meters* e o segundo, entre os *smart meters* e centros de dados.

Os *smart meters* são medidores de energia que além de ler informações sobre o consumo pode também disponibilizar o acesso a outras variáveis do sistema em tempo real. Utiliza-se para isso um canal da comunicação que possibilita a troca de informação com outros *smart meters* e com a concessionária de energia, destacando assim uma interface de comunicação entre todos os componentes da rede [9].

A escolha da tecnologia a ser utilizada para comunicação nas *smart grid* é um fator crucial, pois ela deve ser capaz de prover um serviço confiável, seguro e de baixo custo. Vale ressaltar que tais redes dependem principalmente do número de clientes conectados, eficiência energética esperada, taxa de dados requerida e disponibilidade de dados em tempo real.

Esta troca de informação envolvendo os *smart meters* traz grandes benefícios aos utilitários de energia elétrica e pode se tornar uma tendência no futuro dos sistemas de distribuição de energia, transformando-se em um equipamento primordial no sistema.

Por esta razão, algumas aplicações podem ser previstas com a instalação destes medidores, tais como aquelas envolvidas com a análise de falhas, controle de demanda, agendamento de manutenção preventiva, preços em tempo real, comercialização de energia elétrica, análise da qualidade de energia e identificação de cargas conectadas à rede [42], [45].

A partir do monitoramento contínuo pode-se utilizar os *smart meters* para o controle da qualidade de energia elétrica. Os dados provenientes destes medidores podem ser utilizados para tomada de decisões por parte da concessionária de energia. No entanto, os medidores desenvolvidos até o momento não possuem a capacidade de monitorar em tempo real as informações a respeito dos distúrbios de qualidade de energia. Os medidores que se têm disponíveis até o momento fornecem apenas as notificações de interrupções e detecção de sub e sobretensão com limites definidos [46]. Portanto, são modelos que fornecem pequena quantidade de informações e que não são úteis para desenvolver o sistema proposto nessa tese.

2.4 Considerações Finais do Capítulo

O presente capítulo apresentou o referencial teórico a respeito da temática desta pesquisa. Assim, descreve as técnicas encontradas na literatura que são empregadas para detecção, identificação e localização dos distúrbios de VTCDs.

Com relação às pesquisas de localização dos distúrbios de VTCDs destaca-se que a maioria das pesquisas se concentra em investigar os eventos de afundamento de tensão, pelo fato de ser o evento mais comum no sistema de distribuição, sendo que os métodos propostos são encarregados de destacar se o evento ocorreu à jusante ou à montante do local de medição.

Maiores avanços podem ser almejados a partir da análise dos dados advindos da infraestrutura de monitoramento implantada na *Smart Grid*, principalmente quando combinados com algoritmos de aprendizagem de máquina que são responsáveis por analisar de forma automática os dados advindos dos medidores inteligentes.

Os métodos encontrados na literatura, geralmente tendem a analisar o desvio de tensão ou corrente. No entanto, nem sempre a região de localização será composta pelos medidores que sentiram o distúrbio com mais intensidade, pois a propagação do evento em relação à sua origem depende de vários fatores como: topologia da rede, intensidade do distúrbio e localização da fonte causadora em relação a subestação, sendo que a cada nova configuração um novo padrão de propagação é evidenciado.

De modo a superar essas peculiaridades, o algoritmo proposto nesse projeto emprega algoritmos de aprendizagem de máquinas para analisar um conjunto de características compactas extraídas do distúrbio de VTCD propagado em diferentes

pontos do sistema e enviadas para uma central de controle. Quando o conjunto proveniente de vários pontos de medição é agregado em uma central de controle a forma de propagação do evento pode ser estabelecida. Assim, o método irá estimar o local de origem de acordo com o padrão de propagação do distúrbio.

Os próximos capítulos destacam cada uma das etapas que compõem a metodologia completa abordada nesta tese em uma ordem lógica, partindo-se da modelagem do sistema de distribuição, investigação de um hardware de medição capaz de identificar o distúrbio de VTCD e extrair o conjunto de características, e por fim é apresentado o algoritmo desenvolvido para localização da origem dos distúrbios de VTCDs.

3 Modelagem e Simulação dos Eventos de VTCDs

A metodologia proposta para detectar, no sistema de distribuição, a região que o distúrbio de VTCD foi originado têm como princípio básico analisar o padrão de propagação do distúrbio a partir das características extraídas dos sinais de tensão e disponibilizadas pelos *smart meters*.

A disseminação do evento é influenciada por diversos fatores como: topologia da rede de distribuição, intensidade do distúrbio e localização da fonte causadora em relação à subestação. Logo, antes de apresentar o método proposto faz-se primeiro necessário modelar um sistema de distribuição de modo a construir vários casos que simulem diferentes situações que provocam a ocorrência de afundamento de tensão, de elevação de tensão ou de interrupção de tensão.

Posteriormente, os dados resultantes das simulações podem ser analisados, visando à descoberta de particularidades que influenciam no comportamento do sistema de distribuição, auxiliando no desenvolvimento do método de localização. Adicionalmente, esses dados, também, são utilizados para validar a abordagem proposta.

Para isto, parte-se da modelagem e simulação de um Sistema Elétrico de Potência (SEP), sendo implementada por meio do *software ATP (Alternative Transients Program)*. Tendo os modelos que definem cada evento de VTCD, torna-se possível alterar os parâmetros de forma a realizar diferentes simulações que ocasionem distintos distúrbios de VTCDs, cujas características são condizentes com as encontradas no sistema de distribuição real. O sistema utilizado corresponde ao IEEE 34 *Node Test Feeder*.

Neste contexto, o capítulo foi organizado de modo que na Seção 3.1 são expostos os componentes e modelagem do sistema de distribuição IEEE 34 *Node Test Feeder*; a Seção 3.2 destina-se a apresentar, respectivamente, como os eventos que originam os distúrbios de afundamento de tensão, elevação de tensão e

interrupção de tensão são modelados, apresentando os parâmetros variáveis do conjunto de simulações que serão posteriormente executadas e analisadas. Na Seção 3.3 destaca-se o vetor de características extraído de cada sinal são responsáveis por evidenciar o distúrbio. Por fim, na Seção 3.4 as considerações finais do capítulo são apresentadas.

3.1 Modelagem do Sistema IEEE 34-nós

O modelo empregado para o desenvolvimento desta tese corresponde ao sistema IEEE 34-nós, sendo que o termo nó está relacionado a um ponto de acoplamento no sistema, podendo ser denominado ao longo do texto de barra. O IEEE 34-nós apresenta várias peculiaridades que oferecem um bom caso de teste para análise dos distúrbios de VTCDs, dentre elas destacam-se: cargas desbalanceadas, concentradas e distribuídas, banco de capacitores, transformadores trifásicos e linhas aéreas e subterrânea monofásicas, bifásicas e trifásicas. A Figura 3.1 apresenta o diagrama unifilar do sistema de distribuição, destacando algumas propriedades.

Figura 3.1 – Diagrama do Sistema IEEE 34 Node Test Feeder.

Fonte: Adaptado de [47]

Como apresentado na Figura 3.1 o alimentador é composto por 2 transformadores sendo que o primeiro está localizado na subestação e promove um rebaixamento da tensão de 69 kV para 24,9 kV e o outro corresponde ao transformador de linha que reduz a tensão de 24,9 kV para 4,16 kV, sendo conectado entre as barras 832 e 888. Ressalta que o sistema possui dois reguladores de tensão, os quais estão conectados, respectivamente, entre as barras 814 e 850 e entre as barras 852 e 832. Por fim, este sistema ainda apresenta 25 cargas conectadas, sendo 19 cargas distribuídas e dois capacitores conectados nas barras 844 e 848. Os dados que caracterizam cada componente do sistema e que foram utilizados para modelagem podem ser obtidos em [47][48].

Para fim de validar a simulação e também definir os valores de tensão em regime permanente, após a modelagem do sistema, uma simulação sobre operação normal é executada. A Tabela 3.1 apresenta os valores em p.u. das tensões medidas em cada nó, fornecidos pelo ATP.

Tabela 3.1 - Tensão por fase para cada elemento do sistema IEEE 34 barras.

<i>Nós do Sistema</i>	<i>Distância Para Subestação (km)</i>	<i>Tensão [p.u]</i>		
		<i>Va</i>	<i>Vb</i>	<i>Vc</i>
800	0,00	1,050	1,047	1,044
802	1,27	1,048	1,045	1,042
806	2,11	1,046	1,044	1,041
808	17,93	1,020	1,025	1,017
810	20,78		1,025	
812	36,32	0,988	1,005	0,989
814	50,90	0,963	0,989	0,967
816	51,06	1,020	1,019	1,013
818	51,90	1,019		
820	75,51	0,995		
822	82,25	0,992		
824	56,07	1,012	1,010	1,002
826	57,55		1,009	
828	57,97	1,012	1,009	1,002
830	67,99	0,997	0,992	0,981
832	86,32	1,063	1,029	1,005
834	91,57	1,061	1,024	0,998
836	93,89	1,060	1,024	0,998
838	96,40		1,023	
840	94,31	1,060	1,024	0,998
842	91,72	1,061	1,024	0,998
844	93,50	1,060	1,024	0,998
846	95,29	1,061	1,024	0,998
848	95,55	1,061	1,024	0,998
850	50,90	1,020	1,019	1,013
852	86,31	0,971	0,961	0,944
854	68,25	0,997	0,991	0,980
856	79,69		0,991	
858	88,72	1,062	1,027	1,002
860	92,57	1,060	1,024	0,998
862	94,02	1,060	1,024	0,998
864	89,51	1,062		
888	86,32	1,059	1,024	0,999
890	91,49	0,962	0,942	0,910

Fonte: Autoria própria

Tendo os valores de tensão em regime permanente definidos, tornou-se então possível modelar os eventos que ocasionam distúrbios de afundamento, interrupção e elevação, para fim de averiguar o comportamento do sistema de distribuição sobre a presença destes distúrbios de VTCD.

Assim, cada simulação executada retorna um conjunto de 34 sinais de tensão que são medidos em cada barra/nó do sistema IEEE 34 *Node Test Feeder* e que são armazenados em arquivos para posteriores análises.

3.2 Modelagem dos Distúrbios de Variação de Tensão de Curta Duração

As variações de tensão de curta duração são ocasionadas por vários motivos, dentre os quais se destacam: curtos-circuitos no sistema, partidas e desligamento de grandes cargas e introdução de banco de capacitores.

Entretanto, de acordo com [2], os distúrbios de VTCD são, em sua maioria, causada por condições de falhas, uma vez que corresponde ao defeito mais comum no sistema de distribuição. Deste modo, no trabalho são modelados os distúrbios de afundamento e interrupção ocasionados a partir de um curto-circuito no sistema de distribuição. Por sua vez, os eventos de elevação de tensão são modelados a partir do chaveamento de banco de capacitores.

No que segue, são apresentados como estes dois são confeccionados, via modelagem no ATP, para fim de ocasionar na rede de distribuição os distúrbios de afundamento, elevação e interrupção e construir um banco de informações. Assim, os dados de tensão resultantes de cada simulação são armazenados de acordo com o tipo do evento para posteriormente serem analisados. A partir desta análise pretende-se descobrir tendências que possam vir a ser utilizadas no desenvolvimento do método proposto.

3.2.1 Modelagem do Distúrbio de Afundamento de Tensão e Interrupção de Tensão

A ocorrência dos distúrbios de afundamento de tensão e interrupção de tensão são atreladas a modelagem de um curto-circuito aplicado em algum ponto do sistema.

O curto-circuito ocorre por meio da conexão entre uma ou mais fases do sistema com ou sem a presença do elemento terra. Para o trabalho foram analisadas

faltas trifásicas, curto-circuito bifásico fase-fase-terra e curto-circuito monofásico fase-terra. Assim, a modelagem deste evento via software ATP é desenvolvida a partir da ligação entre duas ou mais fases do sistema e/ou entre o elemento terra, sendo esta conexão estabelecida de acordo com a operação de uma chave.

Adicionalmente, em cada fase que participa do curto-circuito é inserido um elemento com resistência constante, para fim de definir o valor da resistência de curto-circuito. Quanto menor o valor de resistência, mais severo é o distúrbio. A Figura 3.2 representa o esquema elétrico do evento de curto-circuito.

Figura 3.2 – Representação do esquema curto-circuito modelado.

Assim, para fim de modelar o curto-circuito no sistema de distribuição IEEE 34-nós, o circuito apresentado na Figura 3.2 pode ser conectado em algum nó que compõe o sistema. Dependendo do local e das características do curto-circuito, podem-se estabelecer eventos de afundamento de tensão e interrupção de tensão.

O distúrbio de afundamento de tensão corresponde a uma redução do valor da tensão entre 0,9 p.u. e 0,1 p.u e pode ser ocasionado por curtos-circuitos trifásicos, bifásico e monofásico, sendo evidenciado nas fases que envolvem o curto-circuito. As Figura 3.3, Figura 3.4 e Figura 3.5 apresentam o sinal de tensão trifásico medido nas simulações que modelam, respectivamente, um curto-circuito trifásico, um curto-circuito monofásico envolvendo a fase C e um curto-circuito bifásico envolvendo a fase C e fase B.

Figura 3.3 – Afundamento de Tensão ocasionado a partir de um curto-circuito trifásico.

Fonte: Autoria própria.

Figura 3.4 – Afundamento de Tensão ocasionado a partir de um curto-circuito monofásico, envolvendo a fase C.

Fonte: Autoria própria.

Figura 3.5 – Afundamento de Tensão ocasionado a partir de um curto-circuito fase-fase-terra, envolvendo a fase C e fase B.

Fonte: Autoria própria.

Por meio das formas de ondas apresentadas nas Figura 3.3, Figura 3.4 e Figura 3.5, observa-se que as simulações ocasionaram um evento de afundamento de tensão nas fases afetadas pelo curto-circuito e um pequeno transitório oscilatório no início do distúrbio. O afundamento de tensão fica presente no sistema durante o intervalo de tempo que o curto-circuito ocorre, sendo assim o início e o fim de cada afundamento de tensão são determinados pela comutação da chave.

Por conseguinte, a obtenção dos dados referentes ao distúrbio de afundamento de tensão parte da modelagem dos 3 tipos de curtos-circuitos. Cada curto-circuito é aplicado em cada nó do sistema de acordo com a fase presente na barra. Nas barras trifásicas são aplicados curto-circuitos do tipo monofásico, bifásico e trifásico. De modo análogo, em barras monofásicas são aplicados somente curto-circuitos do tipo monofásico envolvendo a fase presente no ramo. Para cada ponto de falta, variou-se a resistência de falta, assumindo os valores 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω .

Destaca-se também que para curto-circuito monofásico e bifásico, alteram-se as fases que participam do curto-circuito, de modo que um curto-circuito monofásico pode envolver a Fase A ou a Fase B ou a Fase C. Um curto-circuito bifásico pode

envolver as Fases A e B ou as Fases A e C ou as Fases B e C. Para diversificar os dados, cada evento é aplicado sobre um ângulo de incidência de 0° e 90° . A partir destes parâmetros é possível evidenciar eventos de afundamento de tensão condizentes com os valores estabelecidos na norma.

A Tabela 3.2 resume as características de cada simulação de acordo com o local de aplicação da falta.

Tabela 3.2 – Parâmetros Variáveis nas Simulações que ocasionam Afundamento de Tensão.

Nó de Aplicação	Fases	Tipo de Curto-Circuito Aplicado	Resistência de curto-circuito (Ω)	Ângulo de Fase
802	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
806	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
808	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
810	B	Monofásico Fase B	[10, 20, 30, 40, 50]	[0; 90]
812	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
814	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
816	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
818	A	Monofásico Fase A	[10, 20, 30, 40, 50]	[0; 90]
820	A	Monofásico Fase A	[10, 20, 30, 40, 50]	[0; 90]
822	A	Monofásico Fase A	[10, 20, 30, 40, 50]	[0; 90]
824	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
826	B	Monofásico Fase B	[10, 20, 30, 40, 50]	[0; 90]
828	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
830	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
832	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
834	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
836	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
838	B	Monofásico Fase B	[10, 20, 30, 40, 50]	[0; 90]
840	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
842	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
844	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
846	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
848	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
850	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
852	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
854	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
856	B	Monofásico Fase B	[10, 20, 30, 40, 50]	[0; 90]
858	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
860	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
862	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
864	A	Monofásico Fase A	[10, 20, 30, 40, 50]	[0; 90]
888	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]
890	A; B; C;	Monofásico; Bifásico; Trifásico	[10, 20, 30, 40, 50]	[0; 90]

Fonte: Autoria própria.

De acordo com a Tabela 3.2, em cada nó trifásico são simuladas 70 situações diferentes de curtos-circuitos e em cada barra monofásica são simuladas 10 situações de curto-circuitos, totalizando 1830 cenários diferentes que ocasionam distúrbios de afundamento de tensão.

Depois de obtidos os dados referentes à ocorrência do distúrbio de tensão, os parâmetros do curto-circuitos podem ser alterados para gerar eventos de interrupção de tensão. Esses distúrbios se caracterizam por possuir uma variação de tensão abaixo de 0,1 p.u. e são causados pela operação do dispositivo de proteção da rede

durante uma situação de um curto-circuito severo no sistema, ou seja, o correto funcionamento do dispositivo de proteção interrompe o fornecimento de energia até que o sistema retorne à condição normal de operação [2], [49].

O evento de interrupção de energia foi modelado a partir de um curto-circuito trifásico com valor de resistência de falta muito baixo. A Figura 3.6 apresenta a operação do curto-circuito trifásico com resistência de 1 Ω . Destaca-se que a duração do evento de interrupção de tensão é determinada pelo tempo de operação da chave.

Figura 3.6 – Interrupção de Tensão ocasionada pela operação do sistema de proteção.

Fonte: Autoria própria.

De acordo com a Figura 3.6 observa-se a presença de um evento de interrupção de tensão durante a ocorrência do curto-circuito trifásico. Assim, esse distúrbio pode ser modelado a partir da ocorrência de um curto-circuito com valor de resistência de curto igual a 1 Ω . Desse modo, a modelagem depende apenas do local de aplicação do distúrbio, logo, em cada simulação variou-se o local de origem do evento, sendo aplicado em todas as barras trifásicas do sistema de distribuição. De modo a diversificar os dados referentes aos distúrbios de interrupção de tensão, alterou-se também o ângulo de aplicação do curto-circuito. Assim, um total de 50 distúrbios de interrupção de tensão são modelados. A Tabela 3.3 resume as características de cada simulação.

Tabela 3.3 – Parâmetros Variáveis nas Simulações que ocasionam Interrupção de Tensão.

<i>Nó de Aplicação</i>	<i>Fases</i>	<i>Tipo de Curto-Circuito Aplicado</i>	<i>Resistência de curto-circuito (Ω)</i>	<i>Ângulo de Fase</i>
802	A; B; C;	Trifásico	[1]	[0; 90]
806	A; B; C;	Trifásico	[1]	[0; 90]
808	A; B; C;	Trifásico	[1]	[0; 90]
812	A; B; C;	Trifásico	[1]	[0; 90]
814	A; B; C;	Trifásico	[1]	[0; 90]
816	A; B; C;	Trifásico	[1]	[0; 90]
824	A; B; C;	Trifásico	[1]	[0; 90]
828	A; B; C;	Trifásico	[1]	[0; 90]
830	A; B; C;	Trifásico	[1]	[0; 90]
832	A; B; C;	Trifásico	[1]	[0; 90]
834	A; B; C;	Trifásico	[1]	[0; 90]
836	A; B; C;	Trifásico	[1]	[0; 90]
840	A; B; C;	Trifásico	[1]	[0; 90]
842	A; B; C;	Trifásico	[1]	[0; 90]
844	A; B; C;	Trifásico	[1]	[0; 90]
846	A; B; C;	Trifásico	[1]	[0; 90]
848	A; B; C;	Trifásico	[1]	[0; 90]
850	A; B; C;	Trifásico	[1]	[0; 90]
852	A; B; C;	Trifásico	[1]	[0; 90]
854	A; B; C;	Trifásico	[1]	[0; 90]
858	A; B; C;	Trifásico	[1]	[0; 90]
860	A; B; C;	Trifásico	[1]	[0; 90]
862	A; B; C;	Trifásico	[1]	[0; 90]
888	A; B; C;	Trifásico	[1]	[0; 90]
890	A; B; C;	Trifásico	[1]	[0; 90]

Fonte: Autoria própria.

3.2.2 Modelagem do Distúrbio de Elevação de Tensão

As elevações de tensões se caracterizam por apresentar um aumento do valor da tensão maior que 1.1 p.u. e são causadas pelas saídas temporárias de cargas ou chaveamento de banco de capacitores [1]. Esse evento ocorre com menos frequência do que os afundamentos de tensão, porém, também causam grandes problemas, uma vez que as elevações podem inutilizar vários equipamentos elétricos.

Nesse trabalho, o distúrbio de elevação de tensão foi gerado de forma a simular o chaveamento de um banco de capacitor utilizado para corrigir o fator de potência do sistema, o qual é alterado pela operação de um motor de indução trifásico. A Figura 3.7 apresenta os sinais que caracterizam este evento, destacando as etapas que definem a ocorrência do evento de elevação de tensão.

Figura 3.7 – Elevação de Tensão ocasionada pela conexão de um banco de capacitores.

Fonte: Autoria própria.

De acordo com a Figura 3.7, pode-se observar que a partida do motor de indução provoca um afundamento na tensão do sistema, devido à alta corrente formada pelo acionamento da máquina. O distúrbio de afundamento de tensão possui as mesmas características em todas as fases e é atenuado à medida que o motor alcança sua velocidade de operação. A presença do motor altera o fator de potência e para correção faz necessário a utilização de uma carga capacitiva. Portanto, após o motor atingir sua velocidade de operação, o banco de capacitores é acionado para corrigir o fator de potência. Como resultado, ocorre uma correção no valor da tensão. Ao fim da operação do motor e com a presença do banco de capacitor ocorre um distúrbio de elevação de tensão, até que o banco seja desconectado [49].

Assim, a ocorrência do distúrbio de elevação de tensão é modelada a partir da conexão no sistema de distribuição de um elemento puramente capacitivo. Uma chave determina a duração deste evento conectado na rede e, conseqüentemente, a duração do evento de elevação de tensão. Este evento é simulado em cada uma das barras trifásicas do sistema, logo, obtém-se um total de 25 casos que provocam eventos de elevação de tensão.

3.3 Características Analisadas no Sinal de Tensão

Para que se possa analisar cada distúrbio evidenciado no sinal de tensão, faz-se importante primeiro extrair características destes sinais que ressaltem as diferenças entre os eventos

As características analisadas devem ser simples e reduzir o vetor de padrão de entrada (isto é, a forma de onda da perturbação detectada) para uma dimensão menor, preservando toda a informação útil do vetor original. Com isto, elas devem auxiliar tanto na tarefa de detecção e identificação do distúrbio de VTCD como também evidenciar a propagação do evento na rede de distribuição.

Nesse contexto, para análise de cada distúrbio resultante das simulações, as técnicas de processamento de sinais são aplicadas. Faz-se importante ressaltar que o método de detecção e classificação que fazem uso dessas características são explanados em detalhes no Capítulo 5, fornecendo uma perspectiva a respeito da sua implementação em hardware.

Para fins desse estudo são investigadas quatro características do sinal no domínio do tempo, as quais correspondem ao *Root Mean Square* (RMS), Valor de Pico, Fator de Pico e Valor Médio, sendo expressas, respectivamente, em (3.1), (3.2), (3.3) e (3.4).

$$RMS = \sqrt{\frac{1}{N} * \sum_{j=1}^N d_j^2} \quad (3.1)$$

$$Valor\ de\ pico = \max(d_1, d_2, \dots, d_j, \dots, d_N) \quad (3.2)$$

$$Fator\ de\ Pico = \frac{Valor\ de\ Pico}{RMS} \quad (3.3)$$

$$ValorMédio = \frac{\sum_{j=1}^N d_j}{N} \quad (3.4)$$

onde, d_j equivale ao j -ésimo ponto do distúrbio segmentado de tamanho N .

O interesse direto destas medidas tem relação com o fato de que os distúrbios de VTCDs alteram os valores de tensão da forma de onda senoidal pura e, portanto, estas 4 características têm como objetivo descrever esta distorção.

O RMS ou valor quadrático médio corresponde ao cálculo médio estatístico de uma grandeza variável que oscila entre valores positivos e negativos em relação à

grandeza elétrica. No contexto elétrico, o RMS representa o valor de tensão alternada que produz a mesma dissipação de potência que uma tensão contínua. Para uma onda senoidal pura, sem distúrbio, com amplitude de 1 p.u., o valor eficaz é em torno de 0,7071.

O Valor de Pico de uma onda senoidal corresponde ao máximo valor absoluto dentre os valores que compõem a forma de onda que representa o distúrbio, sendo numericamente igual à amplitude de sua senóide.

O Fator de Pico calcula a relação entre o Valor de Pico e o valor RMS, sendo utilizado para destacar a presença de valores atípicos ou pontuais presentes no sinal senoidal em relação ao valor eficaz. Assim, para uma senóide pura, o fator de pico é igual a 1,4142, podendo variar de acordo com a intensidade do transitório oscilatório presente no início ou no final do distúrbio. Caso o sinal apresente Valor de Pico de maior intensidade, o fator de pico será maior. Do contrário, ele apresenta valores menores.

O Valor Médio foi utilizado para fim de extrair características do transitório oscilatório presente no início da ocorrência de alguns distúrbios, sem a necessidade de aplicar outras ferramentas como Transformada Rápida de Fourier ou Transformada *Wavelet*. Para uma onda senoidal sem distúrbio o valor médio é igual a 0. Porém, ondas senoidais distorcidas por transitórios oscilatórios apresentam variações destes valores.

Pode-se fazer aqui uma rápida análise destas características, aplicando-as em sinais senoidais com a presença de um distúrbio de afundamento de tensão e elevação de tensão. Estes sinais são ilustrados na Figura 3.8, a qual apresenta um distúrbio de Afundamento de Tensão (a) e de Elevação de Tensão (b). Ao lado dos gráficos destacam-se os valores das características extraídas no instante de tempo que o distúrbio ocorre.

Figura 3.8 – Comparação dos valores RMS, Valor de Pico, Fator de Pico e Valor Médio extraídos do evento de Afundamento de Tensão(a) e Elevação de Tensão (b).

Fonte: Autoria própria.

De acordo com a Figura 3.8, pode-se observar que como o afundamento de tensão é caracterizado por uma amplitude baixa, essa condição é refletida nos valores RMS e Valor de Pico, os quais são menores do que os valores extraídos para o sinal de elevação de tensão.

O Valor Médio consegue caracterizar o transitório oscilatório presente no início do sinal e o Fator de Pico destaca a relação entre o pico do transitório oscilatório e o valor RMS de todo o evento.

De acordo com esta representação, pode-se destacar que essas quatro características podem ser aplicadas para caracterizar os distúrbios presentes nos sinais de tensões resultantes de cada simulação.

3.4 Considerações Finais do Capítulo

O presente capítulo apresentou detalhes de como o sistema de distribuição é modelado para fim de gerar eventos de afundamento de tensão, elevação de tensão

e interrupção de tensão. Esta modelagem foi implementada partindo-se de um sistema de distribuição IEEE 34 nós.

Variando os parâmetros livres de cada simulação, distintos casos que acarretam VTCD podem ser simulados e armazenados. Assim, em cada simulação executada é possível alterar o tipo do evento que ocasiona o distúrbio (curto-circuito ou chaveamento de banco de capacitores).

Ao final deste processo são obtidos 25 casos de elevação de tensão e 50 casos de interrupção de tensão. Por sua vez, como os eventos de afundamento de tensão são os que mais ocorrem no sistema de energia, nessa tese é concedido uma maior atenção para as simulações que ocasionam esse tipo distúrbio. Com isso, são configurados 1830 casos. Dos quais, 250 casos representam curtos-circuitos trifásicos, outros 750 casos estão relacionados com curto-circuitos bifásicos e 830 casos determinam curto-circuitos monofásicos.

Após a modelagem de cada distúrbio de VTCD, este conjunto de dados pode ser analisados a partir de métricas estatísticas, de modo que ao final seja possível determinar heurísticas a respeito de como os parâmetros variáveis de cada simulação influenciam no comportamento do sistema de distribuição. Todo este estudo é explanado no Capítulo 4.

4 Análise das Simulações

De acordo com [2] o distúrbio de VTCD originado em um determinado ponto do sistema de distribuição é disseminado na rede elétrica com diferentes características. Entretanto, sua propagação ocorre em um curto intervalo de tempo e sofre influência tanto das propriedades do sistema de distribuição como também do tipo de fonte que o originou. Assim, a localização do nó de origem não é uma tarefa trivial.

Em consequência disso, é de extrema importância obter novas contribuições que auxiliem no problema de localização da fonte geradora do distúrbio, a qual não seja influenciada pelas características inerentes do sistema. Adicionalmente, faz-se necessário adequar o método para ser empregado sobre o contexto das redes *smart grids*, de forma a equilibrar o custo computacional e o custo de produção.

A metodologia desenvolvida nessa tese tem como princípio básico inferir sobre as características dos distúrbios evidenciados nos nós próximos ao local de origem e que são fornecidas pelos *smart meters*, agrupando estes dados em uma região comum.

Nessa perspectiva, para que se possa desenvolver, de fato, uma abordagem a ser aplicada na tarefa de localização utilizando tais princípios, faz-se de extrema importância clarificar se as características dos distúrbios fornecidas pelos *smart meters* conseguem sintetizar a propagação do evento no sistema de distribuição.

De modo complementar, também é importante averiguar se é possível desenvolver um hardware que possa ser utilizado para detectar e classificar os distúrbios de VTCD.

Para fins do desenvolvimento da metodologia completa, este capítulo tem objetivo de resumir como ocorre a propagação dos distúrbios de VTCDs ocasionados em diferentes cenários de simulações. Para isto, métricas estatísticas e ferramentas de visualização de dados são utilizadas para confrontar a distribuição dos valores das características RMS, Valor de Pico, Fator de Pico e Valor Médio resultantes de cada

simulação. Fundamentado nesta análise estatística, busca-se comprovar se o conjunto de características fornece informações suficientes que auxiliem na tarefa de localização dos distúrbios.

Posteriormente, no Capítulo 5 será explanado os detalhes a respeito do hardware desenvolvido que implementa o método de detecção, classificação e extração de característica do sinal de tensão.

Dessa forma, esse capítulo é dividido em 4 seções. A Seção 4.1 apresenta o ferramental que será utilizado para analisar os vetores de características resultantes das simulações de modo a sintetizar o padrão de propagação do evento. A Seção 4.2 apresenta a análise de dados resultantes das simulações que ocasionam eventos de afundamento de tensão, elevação de tensão e interrupção de tensão. Adicionalmente, na Seção 4.3 resume as informações que foram obtidas a partir da análise estatística. Por fim, a Seção 4.4 apresenta as conclusões do capítulo.

4.1 Ferramentas Utilizadas para Análise do Padrão de Propagação dos Distúrbios de VTCDs

De forma geral, o padrão de propagação do distúrbio está relacionado com a forma como ele é evidenciado em cada ponto do sistema. Sendo assim, a agregação das características extraídas em cada ponto de medição, no instante da ocorrência do evento, pode quantificar o formato de disseminação.

O padrão de propagação do distúrbio está relacionado com a distribuição dos valores de características calculadas em cada barra do sistema. Por conseguinte, torna-se possível averiguar se as características RMS, Valor de Pico, Fator de Pico e Valor Médio resultante de uma simulação destacam semelhanças entre os distúrbios detectados em torno da região de origem e apresentam diferenças entre os distúrbios medidos nos locais distantes, descrevendo a propagação do evento. Adicionalmente, anseia a busca de heurísticas que auxiliem na descoberta da zona de origem do distúrbio.

Assim, a disseminação de valores obtidos em um caso simulado pode ser confrontada com os valores obtidos em outro cenário distinto. Nessa perspectiva, a partir do inter-relacionamento entre a distribuição do vetor de característica resultante de cada simulação e seus parâmetros variáveis pode-se compreender como a propagação do distúrbio é influenciada pelas particularidades da fonte geradora do evento de VTCD.

Para descrever, analisar e confrontar a distribuição dos valores de características resultantes de cada simulação serão aplicadas métricas estatísticas, as quais tendem a resumir numericamente a tendência, dispersão e distribuição do conjunto de dados.

Como forma de melhor ilustrar como cada parâmetro variante em um cenário de simulação (natureza e local de origem do distúrbio) irá influenciar na disseminação do distúrbio na rede elétrica, os valores das métricas estatísticas obtidos nas simulações serão então confrontados por meio de ferramentas de visualização de dados.

4.1.1 Métricas Estatísticas

A estatística descritiva fornece meios para descrever, analisar e interpretar quantitativamente a tendência, dispersão e distribuição de um conjunto de dados, dando suporte à tomada de decisões [50]. Nessa perspectiva, tais métricas podem ser utilizadas para resumir o conjunto de características extraídas dos distúrbios detectados em um determinado cenário de simulação, ao passo que estas métricas podem ser então confrontadas, para fim de obter conclusões sobre o comportamento do sistema.

Em linhas gerais, cada um dos 1905 casos de simulação exemplificados no Capítulo 3 retorna um arquivo que representa os sinais de tensões medidos em cada barra. Uma vez que esta simulação ocasiona um distúrbio de VTCD, um vetor com quatro características (RMS, Valor de Pico, Fator de Pico e Valor Médio) pode ser extraído em cada nó do sistema de distribuição em que o distúrbio é evidenciado. Dessa forma, os sinais das tensões medidos em cada barra são descritos por um vetor de dados.

Para fins do estudo, os vetores obtidos em uma simulação podem ser agrupados e representados por meio de uma matriz de dados. As linhas são relacionadas com o tipo de característica extraída do distúrbio e cada coluna identifica uma barra do sistema que o distúrbio foi medido. A Tabela 4.1 destaca a matriz de dados resultante de uma simulação de um curto-circuito trifásico envolvendo a barra 802 com resistência de $10\ \Omega$ e ângulo de incidência igual a 0° para os distúrbios medidos na fase A. Destaca-se que como corresponde a um afundamento provocado por curto-circuito trifásico são considerados apenas os nós trifásicos do sistema.

Tabela 4.1 – Matriz dos vetores agregados da Simulação de um Curto-circuito Trifásico no nó 802 com resistência de 10 Ω e ângulo de incidência igual a 0°.

	802	806	808	810	812	814	818	850	816	820	822	824	826	828	830	838	...
RMS	0.2468	0.2464	0.2403	-	0.2332	0.2278	-	0.2413	0.2397	-	-	0.2396	-	0.2366	0.2531	-	...
Valor de Pico	0.3536	0.3529	0.3411	-	0.3336	0.3286	-	0.3481	0.3481	-	-	0.3465	-	0.3464	0.3433	-	...
Fator de Pico	1.4329	1.4321	1.4196	-	1.4303	1.4423	-	1.4425	1.4452	-	-	1.4455	-	1.4510	1.4607	-	...
Valor Médio	-0.0194	-0.0191	-0.0122	-	-0.0051	0.0011	-	0.0013	0.0035	-	-	0.0037	-	0.0082	0.0171	-	...

	854	852	832	888	856	858	890	834	842	860	844	836	862	864	840	846	848
RMS	0.2526	0.2525	0.2525	0.2526	-	0.2525	0.2526	0.2526	0.2414	0.2312	0.2365	0.2529	0.2525	-	0.2525	0.2523	0.2310
Valor de Pico	0.3432	0.3377	0.3697	0.3683	-	0.3696	0.3370	0.3695	0.3695	0.3694	0.3695	0.3694	0.3694	-	0.3694	0.3696	0.3696
Fator de Pico	1.4630	1.4631	1.4631	1.4630	-	1.4632	1.4631	1.4631	1.4423	1.4607	1.4511	1.4618	1.4631	-	1.4631	1.4596	1.4591
Valor Médio	0.0185	0.0185	0.0186	0.0185	-	0.0186	0.0186	0.0186	0.0012	0.0156	0.0083	0.0177	0.0185	-	0.0185	0.0198	0.0305

Fonte: Autoria própria.

Assim, partindo dessa matriz, torna-se possível sintetizar os dados numéricos relacionados a cada característica (linhas) por meio de aplicações de métricas estatísticas, resumindo as informações de cada simulação por valores que quantificam a distribuição, tendência e dispersão de cada característica.

A primeira métrica calculada corresponde à média aritmética, sendo a medida de tendência central mais utilizada. A média aritmética de uma característica é obtida pela razão entre a soma de todos os valores e o número de nós que fornecem valores de característica diferente de zero, de acordo com (4.1).

$$Média_i = \frac{\sum_{j=1}^N d_{ij}}{N} \quad (4.1)$$

onde d_{ij} fornece o valor de característica relacionada à linha i extraída no nó correspondente a coluna j .

A média identifica um valor central em torno de todos os valores obtidos para a característica i representados nas linhas. Assim, caso um cenário de simulação provoque um distúrbio de VTCD mais severo em relação a outro, a diferença de intensidade é refletida no valor da média.

A segunda e a terceira métrica analisadas correspondem ao desvio padrão e à amplitude do conjunto. Tais medidas são responsáveis por definir a dispersão do conjunto de dados de acordo com a variabilidade existente entre os valores que o compõem, quantificando se os dados estão mais ou menos concentrados [51]. O desvio padrão e a amplitude são calculados por meio das expressões (4.2) e (4.3)

$$\sigma_i = \sqrt{\frac{\sum_{j=1}^N (d_{ij} - média_i)^2}{N}} \quad (4.2)$$

$$Amplitude_i = \max(d_{i1}, d_{i2}, \dots, d_{iN}) - \min(d_{i1}, d_{i2}, \dots, d_{iN}) \quad (4.3)$$

O desvio padrão corresponde à raiz quadrada da variância e, portanto, neste caso a dispersão do conjunto está relacionada com o quadrado da diferença entre o valor de cada amostra d_{ij} e a média de todas as amostras i . Assim sendo, um desvio padrão baixo determina que os valores dos dados observados estão mais concentrados em torno do valor da média.

Diferente do desvio padrão, a amplitude obtém a dispersão sem utilizar o valor da média do conjunto de dados, sendo calculada pela diferença entre o maior e o menor valor de característica observado sobre a linha analisada.

Para o trabalho estas métricas estão relacionadas diretamente com a propagação do distúrbio e determinam a variabilidade do conjunto das características extraídas em cada barra do sistema. De forma geral, descrevem se o distúrbio foi disseminado com características (Valor de Pico, RMS, Fator de Pico e Valor Médio) iguais em todos os pontos.

Por fim, são calculadas as medidas de assimetria e curtoses, as quais auxiliam a compreensão de distribuição de frequência, sendo úteis para comparar se a distribuição dos dados observados é simétrica. Uma distribuição simétrica ocorre quando a maioria dos dados observados se distribui em torno da média [52]. A assimetria e curtoses são medidas independentes e que não se influenciam mutuamente [51].

As métricas de assimetria e curtoses avaliam, respectivamente, se existem desvios de obliquidade ou achatamento na distribuição. A assimétrica ou obliquidade define se os dados observados estão concentrados abaixo ou acima do valor da média, sendo definida por (4.4).

$$Assimetria_i = \frac{\frac{1}{N} \sum_{j=1}^N (d_{ij} - média_i)^3}{\sigma_i^3} \quad (4.4)$$

onde, σ_i e $média_i$ correspondem, respectivamente, ao desvio padrão e média da característica i . Uma obliquidade negativa indica que os dados possuem mais elementos com valores menores que a média. Por outro lado, caso o valor da obliquidade seja positivo, a distribuição possui uma maior quantidade de dados com valores acima da média. Uma obliquidade nula determina uma distribuição simétrica. A Figura 4.1 apresenta os gráficos de uma distribuição negativa, nula e positiva.

Figura 4.1 – Distribuição com Assimetria: (a) negativa, (b) nula e (c) positiva.

Fonte: Autoria própria.

A curtose quantifica a distribuição dos dados em torno do ponto central e define o grau de achatamento da curva. Quando um conjunto de dados com distribuição normal é representado graficamente, obtêm-se uma curva em forma de sino, com um pico central e caudas finas. No entanto, quando a curtose está presente, a forma da distribuição é influenciada por valores atípicos diferentes do que seriam sob uma distribuição curva normal. Assim, esta medida descreve a forma da cauda de uma distribuição em relação à sua forma geral e é obtida de acordo com a expressão (4.5).

$$Curtoses_i = \frac{\frac{1}{N} \sum_{j=1}^N (d_{ij} - média_i)^4}{\sigma_i^4} \quad (4.5)$$

Distribuições que são influenciadas por valores atípicos apresentam uma curtose menor que 3 e são chamadas de platocúrtica, neste caso a distribuição tem uma maior dispersão de valores nos extremos. Por outro lado, uma curtose maior que 3 indica uma distribuição leptocúrtica e os dados estão concentrados no centro. A Figura 4.2 apresenta os gráficos de cada uma das distribuições.

Figura 4.2 – Distribuição com Curtose: (a) leptocúrtica, (b) normal e (c) platocúrtica.

Fonte: Autoria própria.

De forma geral, as cinco métricas estatísticas são obtidas de cada vetor de característica i (RMS, Valor de Pico, Fator de Pico e Valor Médio) resultante de uma simulação. A vantagem de resumir o conjunto de dados, em torno destas métricas, reside, especialmente, em quantificar a distribuição destes valores, tornando mais fácil compreender as tendências obtidas em cada simulação.

Dada a relevância destas medidas e a quantidade de dados fornecidos pelas simulações idealizadas, optou-se por representa-los de uma forma mais clara e objetiva. Para isto, os dados numéricos que descrevem cada simulação são representados a partir de gráfico de visualização de dados, os quais estabelecem uma comunicação visual de uma informação quantitativa.

4.1.2 Visualização de Dados

Dependendo da quantidade de dimensões quantitativas, a análise para fim de descobrir tendências e relações entre os dados torna-se complexa e dispendiosa. A visualização de dados fornece uma abordagem para explorar e apresentar as tendências e resultados de um conjunto de amostras [53]. Portanto, essa área surgiu com a necessidade de transmitir a informação de uma maneira mais intuitiva.

De modo geral existem duas categorias de visualização de dados que são: a categoria exploratória e a categoria de apresentação ou explicação. Na categoria exploratória, os gráficos são utilizados para encontrar informações, sendo empregados quando se tem vários dados quantitativos e não conhecem os padrões inseridos neles. Por outro lado, os gráficos de apresentação destacam informações conhecidas ou relevantes no conjunto de dados analisados [53], [54].

O campo de visualização de dados consegue sumarizar os dados qualitativos ou quantitativos de diferentes formas. Para isto, fazem uso de vários tipos de gráficos como: histogramas, gráficos de barras, *heatmap*, *boxplot*. Há de se considerar que um mesmo dado pode ser codificado de diversas formas. Assim sendo, é de suma importância que os gráficos desenvolvidos apresentem uma mistura efetiva de conteúdo, contexto, construção e design [53]. Logo, a escolha do tipo do gráfico depende principalmente da classe dos dados e das relações que se deseja obter entre eles.

Para fins do estudo de representação das características resultantes de cada simulação, são utilizadas técnicas de visualização de dados baseadas em matrizes de cores e gráficos de linhas.

A matriz de cor corresponde a estruturas de duas dimensões que utilizam cores para indicar tendências em grandes conjuntos de dados. Em alguns casos, uma matriz de cor pode ser denominada de gráficos *heatmap*. As cores representativas de cada elemento do conjunto de dados definem relações entre eles. Assim, elas conseguem destacar valores fora de uma faixa específica, ou realizar uma comparação entre um valor específico e todos os valores observados [54].

No trabalho, a matriz de cor é utilizada para comparar os dados agregados das características que são extraídas das barras onde o distúrbio é evidenciado. Cada linha i da matriz é relacionada com uma das quatro características extraídas e cada coluna j corresponde ao número da barra que a característica i foi calculada.

As colunas são ordenadas de acordo com a distância da barra à subestação e cada elemento é representado por uma coloração, definida de acordo com o valor do elemento d_{ij} em relação à média da linha i . Valores elevados em relação à média da simulação recebem a coloração verde. Em vermelho são destacados os elementos que apresentaram os menores valores. Por sua vez, os pontos em amarelos apresentam valores próximos à média.

Logo, a matriz de cor resultante de uma simulação é representada por quatro linhas de pixel, que corresponde aos valores das quatro características, calculadas em cada barra. A Figura 4.3 ilustra a matriz resultante da simulação que modela um curto-circuito trifásico localizado na barra 802.

Figura 4.3 – Matriz de cor resultante da simulação curto-circuito trifásico envolvendo o nó 802.

	802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848
RMS	0.2468	0.2464	0.2403	0.2332	0.2278	0.2414	0.2413	0.2397	0.2396	0.2366	0.2365	0.2312	0.2531	0.2523	0.2529	0.2310	0.2526	0.2526	0.2525	0.2525	0.2525	0.2525	0.2525	0.2525	0.2526
Valor de Pico	0.3536	0.3529	0.3411	0.3336	0.3286	0.3481	0.3481	0.3465	0.3464	0.3433	0.3432	0.3377	0.3697	0.3683	0.3696	0.3370	0.3695	0.3695	0.3694	0.3695	0.3694	0.3694	0.3694	0.3696	0.3696
Fator de Pico	1.4329	1.4321	1.4196	1.4303	1.4423	1.4423	1.4425	1.4452	1.4455	1.4510	1.4511	1.4607	1.4607	1.4596	1.4618	1.4591	1.4630	1.4630	1.4631	1.4632	1.4631	1.4631	1.4631	1.4631	1.4631
Valor Médio	-0.0194	-0.0191	-0.0122	-0.0051	0.0011	0.0012	0.0013	0.0035	0.0037	0.0082	0.0083	0.0156	0.0171	0.0198	0.0177	0.0305	0.0185	0.0185	0.0185	0.0186	0.0185	0.0185	0.0186	0.0186	0.0186

Fonte: Autoria própria.

Pela Figura 4.3, torna-se possível caracterizar visualmente a região do sistema onde o distúrbio de afundamento de tensão é evidenciado de forma mais significativa (pontos vermelhos), ou seja, os menores valores das características RMS, Valor de Pico, Fator de Pico e Valor Médio foram extraídos nos primeiros nós do sistema.

Ao agregar as linhas relacionadas com uma característica específica e que são resultantes de diferentes simulações, torna-se então possível confrontar a disseminação do distúrbio em termos da característica escolhida para diferentes situações. Como exemplo, a Figura 4.4 apresenta a agregação das linhas relacionadas com a característica RMS obtida para as simulações de curto-circuito trifásico com resistência de 10 Ω aplicada sobre todos os nós trifásicos do sistema de distribuição.

Figura 4.4– Matriz de cor agregada para característica RMS extraída das simulações de curto-circuito trifásicos de 10 Ω .

	802	806	808	812	814	850	816	824	826	830	854	852	832	868	858	890	834	842	860	844	836	862	840	846	848
802	0.247	0.246	0.240	0.233	0.228	0.241	0.241	0.240	0.240	0.237	0.237	0.231	0.253	0.252	0.253	0.231	0.253	0.253	0.253	0.253	0.252	0.252	0.252	0.253	0.253
806	0.251	0.244	0.238	0.231	0.226	0.239	0.239	0.238	0.237	0.234	0.234	0.229	0.251	0.250	0.251	0.229	0.250	0.250	0.250	0.250	0.250	0.250	0.250	0.250	0.250
808	0.353	0.344	0.201	0.195	0.190	0.202	0.202	0.201	0.200	0.198	0.198	0.194	0.212	0.212	0.212	0.194	0.212	0.212	0.212	0.212	0.212	0.212	0.212	0.212	0.212
812	0.446	0.438	0.300	0.163	0.159	0.169	0.169	0.168	0.168	0.166	0.166	0.163	0.178	0.178	0.178	0.164	0.178	0.178	0.178	0.178	0.178	0.178	0.178	0.178	0.178
814	0.498	0.491	0.368	0.232	0.141	0.150	0.150	0.149	0.149	0.147	0.147	0.144	0.158	0.157	0.157	0.145	0.157	0.157	0.157	0.157	0.157	0.157	0.157	0.157	0.157
850	0.495	0.488	0.362	0.222	0.128	0.136	0.136	0.135	0.135	0.133	0.133	0.131	0.143	0.143	0.143	0.133	0.143	0.143	0.143	0.143	0.143	0.143	0.143	0.143	0.143
816	0.496	0.489	0.363	0.222	0.129	0.136	0.136	0.135	0.135	0.133	0.133	0.131	0.143	0.143	0.143	0.133	0.143	0.143	0.143	0.143	0.143	0.143	0.143	0.143	0.143
824	0.514	0.507	0.387	0.250	0.149	0.158	0.157	0.128	0.128	0.126	0.126	0.124	0.136	0.136	0.136	0.127	0.136	0.136	0.136	0.136	0.136	0.136	0.136	0.136	0.136
828	0.515	0.509	0.388	0.252	0.151	0.160	0.159	0.130	0.128	0.126	0.126	0.124	0.136	0.136	0.136	0.126	0.136	0.136	0.136	0.136	0.136	0.136	0.136	0.136	0.136
830	0.546	0.540	0.430	0.303	0.204	0.216	0.215	0.177	0.174	0.115	0.115	0.113	0.124	0.124	0.124	0.115	0.124	0.124	0.124	0.124	0.124	0.124	0.124	0.124	0.124
854	0.547	0.541	0.431	0.304	0.205	0.217	0.216	0.178	0.175	0.116	0.115	0.113	0.124	0.123	0.124	0.115	0.124	0.124	0.124	0.124	0.124	0.124	0.124	0.124	0.124
852	0.587	0.582	0.488	0.378	0.291	0.308	0.307	0.271	0.269	0.199	0.198	0.097	0.107	0.106	0.107	0.099	0.107	0.107	0.107	0.107	0.107	0.107	0.107	0.107	0.107
832	0.587	0.582	0.486	0.374	0.285	0.302	0.301	0.264	0.261	0.190	0.188	0.083	0.091	0.090	0.091	0.085	0.091	0.091	0.091	0.091	0.091	0.091	0.091	0.091	0.091
888	0.711	0.709	0.683	0.652	0.627	0.664	0.664	0.656	0.656	0.640	0.640	0.613	0.671	0.587	0.670	0.533	0.669	0.669	0.669	0.669	0.669	0.669	0.669	0.669	0.669
858	0.590	0.585	0.491	0.381	0.294	0.311	0.310	0.274	0.271	0.200	0.198	0.089	0.097	0.097	0.089	0.091	0.089	0.089	0.089	0.089	0.089	0.089	0.090	0.090	0.090
890	0.718	0.717	0.692	0.662	0.638	0.676	0.676	0.669	0.668	0.653	0.653	0.626	0.686	0.618	0.685	0.478	0.684	0.684	0.684	0.684	0.684	0.684	0.684	0.684	0.684
834	0.595	0.590	0.497	0.389	0.303	0.321	0.320	0.285	0.282	0.212	0.210	0.097	0.107	0.106	0.099	0.088	0.088	0.088	0.088	0.088	0.088	0.088	0.088	0.088	0.088
842	0.595	0.590	0.497	0.389	0.304	0.322	0.321	0.285	0.282	0.212	0.211	0.098	0.107	0.107	0.097	0.100	0.088	0.087	0.088	0.088	0.088	0.088	0.088	0.088	0.088
860	0.596	0.591	0.499	0.392	0.307	0.325	0.324	0.288	0.285	0.216	0.214	0.101	0.110	0.110	0.100	0.103	0.090	0.090	0.087	0.087	0.087	0.087	0.090	0.090	0.090
844	0.596	0.591	0.499	0.391	0.306	0.324	0.323	0.288	0.285	0.215	0.213	0.100	0.110	0.109	0.099	0.102	0.089	0.089	0.089	0.087	0.089	0.089	0.089	0.087	0.087
836	0.598	0.593	0.502	0.395	0.311	0.329	0.328	0.293	0.290	0.221	0.219	0.105	0.115	0.115	0.104	0.107	0.093	0.093	0.090	0.093	0.086	0.086	0.086	0.093	0.093
862	0.598	0.593	0.502	0.396	0.311	0.330	0.329	0.294	0.291	0.222	0.220	0.106	0.116	0.115	0.105	0.108	0.093	0.093	0.090	0.093	0.086	0.086	0.086	0.094	0.094
840	0.599	0.594	0.503	0.396	0.312	0.331	0.330	0.295	0.292	0.223	0.221	0.107	0.117	0.116	0.106	0.109	0.094	0.094	0.091	0.094	0.087	0.087	0.085	0.094	0.094
846	0.598	0.593	0.502	0.396	0.312	0.330	0.329	0.294	0.291	0.222	0.220	0.106	0.116	0.116	0.105	0.108	0.094	0.094	0.091	0.094	0.087	0.087	0.086	0.086	0.086
848	0.599	0.594	0.503	0.397	0.313	0.331	0.330	0.295	0.292	0.223	0.222	0.107	0.117	0.117	0.106	0.109	0.095	0.094	0.095	0.092	0.095	0.095	0.095	0.086	0.086

Fonte: Autoria própria.

Na Figura 4.4 as linhas representam o local em que a falta foi aplicada e a coluna define a barra que a característica foi extraída, confrontando assim, os valores da característica calculada com a posição de origem do distúrbio. Para uma melhor visualização, em cada quadro agregado, as linhas e colunas são ordenadas de acordo com as distâncias dos nós em relação à subestação. Assim, as primeiras linhas/colunas apresentam os casos/medidores próximos à subestação, enquanto as últimas linhas/colunas representam casos/medidores mais distantes da subestação. A diagonal principal destaca, em cada linha, o local de aplicação do curto-circuito.

Outra forma de representar o relacionamento dos dados obtidos em cada simulação pode se dar a partir da utilização de um gráfico de linhas. Este gráfico é composto por pontos que representam os dados, unidos por segmentos de retas. Um gráfico de linhas simples representa duas dimensões de dados, como por exemplo, o preço das ações de uma empresa em dias diferentes.

Considerando o estudo realizado, cada ponto do gráfico pode representar o valor de uma métrica estatística (média, desvio padrão, amplitude, assimetria e

curtoses) calculadas sobre um conjunto de características (RMS, Valor de Pico, Fator de Pico e Valor Médio) resultante de uma simulação.

Assim, ao contrário da matriz que destaca os nós que evidenciaram o distúrbio com mais intensidade a partir da análise dos valores de características obtidos em cada linha, o gráfico de linhas descreve uma visão mais global de cada conjunto de característica comparando as métricas estatísticas calculadas em vários cenários de simulação.

Posteriormente, se várias séries/linhas são apresentadas no mesmo gráfico, ele pode destacar o relacionamento de três dimensões diferentes [54], onde cada linha presente no gráfico descreve uma série. Nesta situação, o gráfico de linhas pode ser utilizado para confrontar os valores de uma métrica estatística obtida tanto em relação ao local de origem do distúrbio de VTCD, como também em função da natureza do evento, apontando-se a relação dos diferentes dados entre si que são medidos de acordo com o local de origem do distúrbio.

A Figura 4.5 ilustra uma sobreposição do gráfico de linha que confronta os valores obtidos para a média da característica RMS obtida a partir de duas séries representadas pelas linhas azul e vermelha. A linha azul corresponde às simulações que ocasionam distúrbios a partir de um curto-circuito trifásico com resistência de $10\ \Omega$ e a linha vermelha correspondem às simulações ocasionadas por curto-circuito trifásico com resistência de $50\ \Omega$, onde para cada série altera-se também o local de origem do distúrbio. Sendo assim, o eixo x do gráfico ilustra os locais de aplicação do curto-circuito e o eixo y fornece os valores da métrica média calculada em cada caso. As series são representadas pelas linhas azul e vermelha.

Figura 4.5 – Gráfico de linhas que confronta a média das características RMS obtidas das simulações de curto-circuito trifásico com resistência de $10\ \Omega$ (azul) e $50\ \Omega$ (vermelho).

Fonte: Autoria própria.

De acordo com os exemplos gráficos apresentados fica evidente que eles conseguem representar as relações entre as matrizes de dados resultantes de cada simulação. Fundamentado nestes gráficos e nas características estatísticas, busca-se destacar então se a matriz de característica resultante das simulações consegue evidenciar a propagação do distúrbio. Adicionalmente, almeja-se também encontrar informações que auxiliem no desenvolvimento do método.

Na sequência, é apresentada a análise, em termos dos vetores de características, das simulações que ocasionam distúrbios de VTCDs.

4.2 Análise de Simulações que Ocasionam Distúrbios de VTCDs

Como foram definidos no Capítulo 3, os distúrbios de afundamento de tensão e interrupção de tensão são provenientes de eventos de curtos-circuitos no sistema de distribuição, onde dependendo do local e de suas características pode-se evidenciar na rede de distribuição um destes dois tipos de distúrbios. Por outro lado, os distúrbios de elevação de tensão foram modelados pela comutação de banco de capacitores.

Assim, a análise apresentada nessa seção tem como objetivo averiguar como o local de aplicação e a natureza e característica da fonte geradora pode influenciar na disseminação destes três distúrbios.

Com este objetivo, partiu-se primeiro em averiguar a distribuição das características resultantes das simulações que modelam o fenômeno de curto-circuito, de acordo com os parâmetros livres de cada simulação. Posteriormente, o estudo é estendido para os dados relacionados com o evento de comutação de banco de capacitores.

4.2.1 Análise das Simulações que Modelam Curto-Circuito

Neste trabalho o curto-circuito é aplicado em qualquer nó do sistema e pode ser trifásico, bifásico ou monofásico, em que o valor de resistência de cada evento se estabelece entre os valores 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω ou 50 Ω . O ângulo de incidência é também modificado e pode assumir o valor 0° ou 90°. Portanto, o local de origem, o tipo, o valor de resistência e o valor do ângulo do curto-circuito podem alterar a forma como o evento é caracterizado em cada barra.

Partindo dessa consideração, no presente estudo um destes 4 fatores é alterado, enquanto os demais apresentam valores fixos. Desse modo, é quantificada a influência do fator modificado sobre a distribuição dos valores de características resultante de cada simulação.

A princípio, objetiva-se descrever como ocorre a propagação do distúrbio de acordo com o seu local de origem em relação à subestação. Para isto, são analisados os dados resultantes das simulações que modelam curto-circuito trifásico de $10\ \Omega$ com ângulo de fase de 0° envolvendo cada nó trifásico do sistema de distribuição IEEE 34-nós.

Tendo-se os dados de tensão das simulações que implementam este tipo de curtos-circuitos trifásicos, é então possível segmentar e extrair as características das barras que evidenciaram o distúrbio e, conseqüentemente, analisar a influência do local de origem.

O confronto entre os valores de características RMS, Valor de Pico, Fator de Pico e Valor Médio, extraídas em cada barra do sistema, pode ser realizado mediante uma matriz de cor construída para cada uma das quatro características. Cada matriz irá agregar o conjunto de característica resultante dos cenários de simulação a serem analisados. Assim, é possível descrever visualmente como ocorreu a propagação do distúrbio em cada simulação em função do nó de origem do distúrbio

A Tabela 4.2 à Tabela 4.5 apresentam, respectivamente, os quadros construídos para as características RMS, Valor de Pico, Fator de Pico e Valor Médio obtidas nas simulações de curto-circuitos trifásicos com resistência igual a $10\ \Omega$ e ângulo de fase 0° . Nestes quadros, são adicionados ao final, 7 colunas, onde as 5 primeiras fornecem os valores, respectivamente, das métricas estatísticas representando a média, o desvio padrão, a amplitude, a assimetria e a curtose. As duas últimas colunas destacam a barra que apresentou maior valor e menor valor da característica analisada em cada linha.

Tabela 4.2 – Quadro do conjunto de Característica RMS resultantes das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.

RMS																												Métricas Estatísticas							
	802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848	Media	Desv Pad.	Ampl.	Assim.	Curtores	Min	Max			
802	0.2468	0.2464	0.2403	0.2332	0.2278	0.2414	0.2413	0.2307	0.2396	0.2366	0.2365	0.2312	0.2531	0.2523	0.2529	0.2310	0.2526	0.2526	0.2525	0.2525	0.2525	0.2525	0.2526	0.2526	0.2526	0.245	0.009	0.025	-0.545	1.853	814	832			
806	0.2515	0.2441	0.2380	0.2311	0.2257	0.2391	0.2391	0.2375	0.2374	0.2344	0.2343	0.2291	0.2508	0.2500	0.2505	0.2289	0.2503	0.2502	0.2502	0.2502	0.2502	0.2502	0.2502	0.2503	0.2503	0.243	0.009	0.026	-0.565	1.817	814	802			
808	0.3528	0.3440	0.2010	0.1949	0.1905	0.2018	0.2018	0.2005	0.2004	0.1980	0.1980	0.1938	0.2122	0.2116	0.2120	0.1944	0.2118	0.2118	0.2117	0.2118	0.2117	0.2117	0.2117	0.2118	0.2118	0.217	0.040	0.162	2.919	9.971	814	802			
812	0.4460	0.4384	0.2999	0.1634	0.1595	0.1690	0.1689	0.1678	0.1677	0.1658	0.1657	0.1626	0.1780	0.1776	0.1779	0.1638	0.1778	0.1778	0.1777	0.1777	0.1777	0.1777	0.1778	0.1778	0.1778	0.199	0.078	0.286	2.652	8.458	814	802			
814	0.4480	0.4913	0.3682	0.2317	0.1414	0.1498	0.1497	0.1486	0.1485	0.1468	0.1465	0.1439	0.1575	0.1573	0.1574	0.1455	0.1574	0.1574	0.1574	0.1574	0.1574	0.1574	0.1575	0.1575	0.192	0.102	0.367	2.406	7.205	814	802				
850	0.4950	0.4882	0.3622	0.2216	0.1283	0.1359	0.1359	0.1349	0.1349	0.1331	0.1331	0.1309	0.1433	0.1432	0.1433	0.1330	0.1433	0.1432	0.1432	0.1432	0.1432	0.1432	0.1434	0.1434	0.179	0.105	0.367	2.404	7.187	814	802				
816	0.4956	0.4886	0.3629	0.2225	0.1286	0.1395	0.1357	0.1348	0.1347	0.1330	0.1329	0.1307	0.1431	0.1430	0.1431	0.1328	0.1431	0.1431	0.1431	0.1430	0.1430	0.1430	0.1432	0.1432	0.179	0.105	0.367	2.401	7.175	814	802				
824	0.5136	0.5071	0.3866	0.2501	0.1492	0.1581	0.1570	0.1284	0.1284	0.1265	0.1245	0.1363	0.1362	0.1363	0.1267	0.1363	0.1363	0.1363	0.1362	0.1362	0.1362	0.1364	0.1364	0.181	0.113	0.389	2.304	6.743	852	802					
828	0.5150	0.5085	0.3885	0.2523	0.1512	0.1602	0.1591	0.1287	0.1279	0.1260	0.1259	0.1240	0.1357	0.1356	0.1357	0.1262	0.1357	0.1357	0.1358	0.1357	0.1357	0.1357	0.1359	0.1359	0.181	0.114	0.391	2.294	6.704	852	802				
830	0.5461	0.5401	0.4300	0.3028	0.2302	0.2158	0.2146	0.1768	0.1739	0.1152	0.1151	0.1131	0.1238	0.1237	0.1238	0.1154	0.1238	0.1238	0.1238	0.1238	0.1238	0.1238	0.1240	0.1240	0.190	0.129	0.433	1.965	5.551	852	802				
854	0.5468	0.5400	0.4310	0.3040	0.2501	0.2172	0.2160	0.1782	0.1753	0.1159	0.1149	0.1128	0.1235	0.1234	0.1235	0.1151	0.1236	0.1236	0.1235	0.1235	0.1235	0.1235	0.1237	0.1237	0.190	0.129	0.434	1.955	5.519	852	802				
852	0.5873	0.5823	0.4878	0.3780	0.2900	0.3076	0.3071	0.2714	0.2685	0.1993	0.1976	0.0975	0.1067	0.1062	0.1067	0.0990	0.1068	0.1068	0.1068	0.1067	0.1067	0.1067	0.1070	0.1070	0.214	0.154	0.490	1.284	3.532	852	802				
836	0.5868	0.5816	0.4856	0.3739	0.2853	0.3022	0.3010	0.2644	0.2614	0.1898	0.1880	0.0828	0.0906	0.0903	0.0907	0.0851	0.0909	0.0909	0.0910	0.0909	0.0909	0.0909	0.0911	0.0912	0.203	0.160	0.504	1.258	3.460	852	802				
888	0.7108	0.7094	0.6828	0.6518	0.6271	0.6644	0.6640	0.6563	0.6557	0.6404	0.6400	0.6131	0.6711	0.6711	0.6713	0.6529	0.6893	0.6892	0.6891	0.6890	0.6890	0.6890	0.6892	0.6893	0.656	0.306	1.178	-0.708	6.765	890	802				
858	0.5905	0.5854	0.4909	0.3809	0.2937	0.3111	0.3100	0.2739	0.2709	0.2000	0.1983	0.0886	0.0970	0.0967	0.0852	0.0909	0.0893	0.0893	0.0893	0.0893	0.0893	0.0896	0.0896	0.0896	0.207	0.162	0.502	1.205	3.319	852	802				
890	0.7183	0.7170	0.6916	0.6620	0.6385	0.6764	0.6761	0.6686	0.6680	0.6531	0.6527	0.6264	0.6857	0.6857	0.6858	0.6748	0.6838	0.6838	0.6837	0.6836	0.6836	0.6836	0.6838	0.6838	0.667	0.306	1.178	-0.708	6.765	890	802				
834	0.5947	0.5897	0.4970	0.3890	0.3033	0.3213	0.3202	0.2847	0.2818	0.2119	0.2102	0.0974	0.1067	0.1063	0.0969	0.0964	0.0876	0.0876	0.0876	0.0875	0.0875	0.0875	0.0879	0.0879	0.212	0.164	0.507	1.147	3.174	862	802				
842	0.5949	0.5899	0.4972	0.3893	0.3038	0.3218	0.3207	0.2852	0.2823	0.2125	0.2107	0.0979	0.1072	0.1068	0.0973	0.0999	0.0876	0.0875	0.0875	0.0875	0.0875	0.0878	0.0878	0.0878	0.212	0.164	0.507	1.145	3.169	842	802				
806	0.5961	0.5912	0.4990	0.3917	0.3068	0.3248	0.3237	0.2884	0.2855	0.2159	0.2142	0.1007	0.1102	0.1099	0.0999	0.1027	0.0897	0.0897	0.0898	0.0897	0.0897	0.0897	0.0900	0.0900	0.214	0.164	0.509	1.131	3.137	862	802				
844	0.5956	0.5906	0.4986	0.3911	0.3060	0.3241	0.3230	0.2877	0.2848	0.2152	0.2134	0.1001	0.1096	0.1092	0.0994	0.1021	0.0894	0.0894	0.0894	0.0894	0.0894	0.0897	0.0897	0.0897	0.214	0.164	0.509	1.136	3.147	844	802				
836	0.5880	0.5931	0.5017	0.3892	0.3108	0.3293	0.3282	0.2932	0.2903	0.2212	0.2194	0.1052	0.1151	0.1148	0.1042	0.1072	0.0930	0.0930	0.0930	0.0931	0.0931	0.0931	0.0937	0.0937	0.218	0.164	0.512	1.114	3.095	862	802				
862	0.5882	0.5933	0.5019	0.3968	0.3113	0.3298	0.3287	0.2936	0.2908	0.2217	0.2200	0.1057	0.1157	0.1154	0.1047	0.1077	0.0934	0.0934	0.0934	0.0934	0.0934	0.0939	0.0939	0.218	0.164	0.513	1.112	3.092	862	802					
840	0.5986	0.5937	0.5025	0.3964	0.3122	0.3307	0.3296	0.2947	0.2918	0.2228	0.2211	0.1067	0.1168	0.1165	0.1057	0.1077	0.0942	0.0942	0.0942	0.0886	0.0886	0.0854	0.0944	0.0944	0.219	0.164	0.513	1.109	3.085	840	802				
846	0.5983	0.5934	0.5022	0.3959	0.3117	0.3302	0.3291	0.2941	0.2912	0.2222	0.2205	0.1063	0.1163	0.1160	0.1054	0.1081	0.0940	0.0943	0.0940	0.0913	0.0940	0.0940	0.0940	0.0940	0.219	0.164	0.512	1.114	3.097	848	802				
848	0.5987	0.5938	0.5027	0.3966	0.3125	0.3311	0.3300	0.2950	0.2922	0.2232	0.2215	0.1072	0.1174	0.1170	0.1063	0.1090	0.0940	0.0943	0.0948	0.0920	0.0947	0.0947	0.0947	0.0947	0.219	0.164	0.513	1.112	3.091	848	802				

Fonte: Autoria própria

Tabela 4.3 - Quadro do conjunto de Característica Valor de Pico resultantes das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.

Valor de Pico																												Métricas Estatísticas							
802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848	Media	Desv Pad	Ampl.	Assim.	Curtores	Min	Max				
802	0.3683	0.3673	0.3519	0.3334	0.3263	0.3457	0.3456	0.3447	0.3446	0.3428	0.3428	0.3405	0.3727	0.3736	0.3729	0.3516	0.3730	0.3731	0.3730	0.3731	0.3730	0.3730	0.3733	0.3733	0.359	0.016	0.047	-0.522	1.752	814	832				
806	0.3689	0.3650	0.3500	0.3315	0.3240	0.3433	0.3432	0.3423	0.3423	0.3406	0.3406	0.3381	0.3701	0.3711	0.3703	0.3492	0.3705	0.3705	0.3705	0.3705	0.3704	0.3705	0.3707	0.3707	0.357	0.016	0.047	-0.533	1.746	814	802				
808	0.5344	0.5187	0.3063	0.2878	0.2802	0.2969	0.2969	0.2966	0.2966	0.2961	0.2961	0.2974	0.3256	0.3276	0.3260	0.3130	0.3265	0.3265	0.3265	0.3265	0.3265	0.3265	0.3268	0.3268	0.329	0.061	0.254	-0.747	9.377	814	802				
812	0.6750	0.6629	0.4280	0.2465	0.2333	0.2471	0.2472	0.2476	0.2477	0.2495	0.2496	0.2543	0.2784	0.2817	0.2790	0.2732	0.2796	0.2797	0.2797	0.2797	0.2797	0.2797	0.2799	0.2799	0.305	0.115	0.442	0.675	8.724	814	802				
814	0.7421	0.7314	0.5404	0.3276	0.2115	0.2240	0.2238	0.2208	0.2204	0.2170	0.2171	0.2238	0.2451	0.2490	0.2459	0.2455	0.2468	0.2468	0.2469	0.2470	0.2469	0.2469	0.2469	0.2472	0.2472	0.292	0.148	0.531	2.439	7.394	814	802			
850	0.7402	0.7294	0.5340	0.3171	0.1918	0.2032	0.2030	0.2003	0.1999	0.1981	0.1982	0.2055	0.2249	0.2291	0.2258	0.2276	0.2268	0.2268	0.2270	0.2269	0.2269	0.2269	0.2272	0.2272	0.275	0.154	0.548	2.429	7.394	814	802				
816	0.7407	0.7299	0.5351	0.3184	0.1923	0.2037	0.2026	0.1999	0.1995	0.1977	0.1978	0.2051	0.2246	0.2287	0.2254	0.2274	0.2264	0.2265	0.2265	0.2265	0.2265	0.2268	0.2268	0.2275	0.154	0.548	2.426	7.391	814	802					
824	0.7602	0.7504	0.5643	0.3597	0.2131	0.2258	0.2246	0.1919	0.1917	0.1868	0.1868	0.1943	0.2127	0.2127	0.2137	0.2176	0.2151	0.2152	0.2154	0.2152	0.2152	0.2152	0.2156	0.2156	0.274	0.164	0.573	2.437	6.949	852	802				
828	0.7620	0.7522	0.5669	0.3640	0.2157	0.2285	0.2273	0.1930	0.1911	0.1859	0.1860	0.1935	0.2118	0.2162	0.2129	0.2169	0.2142	0.2142	0.2143	0.2145	0.2143	0.2143	0.2147	0.2147	0.274	0.165	0.576	2.338	6.980	852	802				
830	0.8025	0.7936	0.6252	0.4400	0.2884	0.3055	0.3036	0.2544	0.2498	0.1703	0.1705	0.1735	0.1899	0.1948	0.1910	0.1988	0.1922	0.1923	0.1923	0.1925	0.1923	0.1923	0.1927	0.1927	0.283	0.185	0.632	2.044	5.824	852	802				
832	0.8036	0.7948	0.6265	0.4417	0.2904	0.3076	0.3057	0.2571	0.2526	0.1714	0.1700	0.1730	0.1984	0.1942	0.1904	0.1983	0.1917	0.1917	0.1918	0.1920	0.1918	0.1918	0.1918	0.1922	0.1922	0.284	0.185	0.634	2.034	5.792	852	802			
834	0.8529	0.8456	0.7090	0.5625	0.4238	0.4489	0.4471	0.3943	0.3949	0.2840	0.2813	0.1420	0.1555	0.1587	0.1551	0.1679	0.1588	0.1599	0.1586	0.1613	0.1581	0.1581	0.1581	0.1615	0.1615	0.314	0.223	1.711	1.299	3.563	852	802			
836	0.8512	0.8436	0.7079	0.5473	0.4224	0.4474	0.4458	0.3927	0.3883	0.2768	0.2741	0.1239	0.1353	0.1361	0.1398	0.1474	0.1427	0.1429	0.1428	0.1434	0.1427	0.1427	0.1427	0.1429	0.1429	0.303	0.229	1.728	1.253	3.437	852	802			
838	1.0052	1.0033	0.9670	0.9246	0.8008	0.9437	0.9434	0.9326	0.9317	0.9014	0.9099	0.8703	0.9558	0.9583	0.9561	0.9694	0.9541	0.9540	0.9540	0.9539	0.9539	0.9539	0.9542	0.9543	0.934	0.409	0.236	-1.680	6.396	890	802				
839	0.9551	0.9489	0.7190	0.5575	0.4386	0.4686	0.4630	0.4099	0.4055	0.2958	0.2931	0.1590	0.1653	0.1621	0.1478	0.1605	0.1493	0.1493	0.1494	0.1496	0.1492	0.1492	0.1494	0.1504	0.1505	0.313	0.228	0.709	1.213	3.386	852	802			
840	0.9156	0.9117	0.7930	0.5905	0.4511	0.4800	0.4784	0.4256	0.4210	0.3210	0.3164	0.1622	0.1704	0.1680	0.1550	0.1773	0.1440	0.1448	0.1448	0.1447	0.1438	0.1438	0.1438	0.1455	0.1510	0.303	0.228	0.709	1.262	3.280	852	802			
842	0.8581	0.8510	0.7222	0.5718	0.4532	0.4818	0.4785	0.4259	0.4215	0.3218	0.3193	0.1620	0.1773	0.1782	0.1598	0.1783	0.1490	0.1454	0.1447	0.1483	0.1449	0.1449	0.1449	0.1513	0.1519	0.323	0.230	0.713	1.134	3.139	842	802			
843	0.8813	0.8543	0.7252	0.5751	0.4578	0.4850	0.4834	0.4307	0.4263	0.331	0.3206	0.1884	0.1844	0.1817	0.1629	0.1795	0.1490	0.1454	0.1424	0.1510	0.1410	0.1410	0.1409	0.1533	0.1535	0.326	0.231	0.720	1.123	3.112	862	802			
844	0.8579	0.8508	0.7220	0.5747	0.4558	0.4829	0.4813	0.4304	0.4263	0.3355	0.3229	0.1686	0.1846	0.1803	0.1716	0.1833	0.1553	0.1545	0.1555	0.1556	0.1555	0.1555	0.1545	0.1551	0.328	0.227	0.707	1.139	3.151	844	802				
846	0.8580	0.8520	0.7233	0.5791	0.4624	0.4899	0.4883	0.4340	0.4317	0.3283	0.3257	0.1741	0.1906	0.1855	0.1675	0.1899	0.1552	0.1566	0.1574	0.1584	0.1562	0.1564	0.1568	0.1594	0.330	0.231	0.729	1.133	3.094	862	802				
862	0.8583	0.8583	0.7288	0.5794	0.4620	0.4901	0.4887	0.4365	0.4322	0.3289	0.3263	0.1746	0.1910	0.1857	0.1680	0.1876	0.1568	0.1572	0.1480	0.1590	0.1370	0.1358	0.1371	0.1507	0.1599	0.330	0.231	0.730	1.112	3.094	862	802			
840	0.8659	0.8590	0.7297	0.5802	0.4637	0.4912	0.4896	0.4375	0.4332	0.3301	0.3275	0.1753	0.1919	0.1866	0.1690	0.1889	0.1579	0.1583	0.1493	0.1599	0.1380	0.1376	0.1350	0.1606	0.1607	0.331	0.231	0.731	1.111	3.091	840	802			
840	0.8609	0.8538	0.7259	0.5793	0.4635	0.4911	0.4895	0.4365	0.4365	0.3348	0.3359	0.1765	0.1932	0.1878	0.1809	0.1911	0.1662	0.1655	0.1633	0.1619	0.1663	0.1663	0.1663	0.1509	0.1511	0.336	0.226	0.710	1.120	3.111	848	802			
848	0.8614	0.8543	0.7265	0.5799	0.4646	0.4922	0.4907	0.4419	0.4379	0.3402	0.3378	0.1776	0.1944	0.1888	0.1822	0.1921	0.1676	0.1670	0.1679	0.1638	0.1678	0.1678	0.1678	0.1509	0.1502	0.337	0.226	0.711	1.118	3.107	848	802			

Tabela 4.5 - Quadro do conjunto de Característica Valor Médio resultante das simulações de curto-circuito trifásicos de 10 Ω e ângulo de fase 0°.

	Valor Médio																								Métricas Estatísticas							
	802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848	Média	Desv.Pad.	Ampl.	Assim.	Curtores	Min	Max
802	0.01943	0.01805	0.01223	0.00510	0.00112	0.00119	0.00129	0.00350	0.00389	0.00823	0.00835	0.01559	0.01707	0.01885	0.01771	0.03084	0.01846	0.01849	0.01852	0.01861	0.01855	0.01855	0.01855	0.01864	0.01864	0.010	0.013	0.050	-0.879	2.934	802	890
806	0.01402	0.02023	0.01326	0.00593	0.00049	0.00042	0.00052	0.00277	0.00236	0.00757	0.00788	0.01059	0.01632	0.01935	0.01718	0.03032	0.01795	0.01797	0.01801	0.01810	0.01804	0.01804	0.01812	0.01813	0.01813	0.009	0.013	0.051	-0.780	2.753	806	890
808	0.02118	0.01905	0.02105	0.01224	0.00441	0.00467	0.00455	0.00184	0.00161	0.00385	0.00388	0.01086	0.01408	0.01740	0.01486	0.03091	0.01576	0.01579	0.01584	0.01584	0.01587	0.01587	0.01588	0.01598	0.01598	0.009	0.012	0.052	-0.779	3.017	808	890
812	0.02233	0.02137	0.00862	0.01682	0.00826	0.00874	0.00862	0.00580	0.00556	0.00004	0.00018	0.01043	0.01142	0.01516	0.01235	0.03074	0.01344	0.01348	0.01353	0.01366	0.01356	0.01356	0.01357	0.01373	0.01374	0.008	0.012	0.048	-0.393	2.469	812	890
814	0.01956	0.01895	0.00834	0.00297	0.01369	0.01450	0.01437	0.01142	0.01118	0.00530	0.00515	0.00624	0.00683	0.01095	0.00789	0.02847	0.00913	0.00917	0.00922	0.00939	0.00926	0.00926	0.00927	0.00950	0.00951	0.004	0.011	0.043	-0.236	2.478	814	890
850	0.02006	0.01947	0.00913	0.00188	0.01235	0.01311	0.01296	0.00999	0.00975	0.00384	0.00369	0.00770	0.00843	0.01257	0.00948	0.03003	0.01073	0.01077	0.01082	0.01088	0.01086	0.01086	0.01087	0.01110	0.01112	0.006	0.011	0.043	-0.260	2.486	850	890
816	0.02001	0.01942	0.00916	0.00172	0.01214	0.01286	0.01305	0.01009	0.00985	0.00395	0.00380	0.00761	0.00834	0.01248	0.00940	0.02998	0.01064	0.01069	0.01074	0.01090	0.01077	0.01077	0.01078	0.01102	0.01104	0.006	0.011	0.043	-0.251	2.489	816	890
824	0.01860	0.01811	0.01040	0.00352	0.00624	0.00555	0.00571	0.01225	0.01232	0.00549	0.00534	0.00576	0.00631	0.01063	0.00747	0.02898	0.00884	0.00889	0.00894	0.00894	0.00898	0.00898	0.00899	0.00928	0.00930	0.005	0.010	0.041	-0.024	2.959	824	890
828	0.01853	0.01805	0.01050	0.00381	0.00479	0.00508	0.00524	0.01168	0.01221	0.00669	0.00655	0.00560	0.00613	0.01047	0.00730	0.02886	0.00868	0.00873	0.00878	0.00898	0.00882	0.00882	0.00882	0.00912	0.00914	0.005	0.010	0.041	0.000	3.012	828	890
830	0.01799	0.01771	0.01267	0.00701	0.00215	0.00228	0.00218	0.00197	0.00231	0.01065	0.01041	0.00180	0.00197	0.00656	0.00306	0.02608	0.00433	0.00438	0.00444	0.00459	0.00448	0.00448	0.00449	0.00469	0.00471	0.005	0.008	0.037	0.633	4.462	830	890
854	0.01796	0.01768	0.01269	0.00709	0.00228	0.00241	0.00232	0.00180	0.00213	0.01040	0.01061	0.00169	0.00185	0.00644	0.00294	0.02600	0.00421	0.00426	0.00432	0.00447	0.00436	0.00436	0.00437	0.00457	0.00458	0.005	0.008	0.037	0.652	4.484	854	890
852	0.01519	0.01506	0.01272	0.01004	0.00782	0.00829	0.00823	0.00579	0.00559	0.00071	0.00058	0.00841	0.00920	0.00396	0.00796	0.01874	0.00652	0.00647	0.00640	0.00623	0.00635	0.00635	0.00634	0.00613	0.00612	0.001	0.009	0.028	0.551	1.841	852	890
832	0.01538	0.01526	0.01311	0.01054	0.00859	0.00910	0.00905	0.00668	0.00649	0.00177	0.00168	0.00707	0.00773	0.00245	0.00202	0.02922	0.00505	0.00500	0.00493	0.00476	0.00488	0.00488	0.00487	0.00466	0.00468	0.002	0.009	0.028	0.581	1.950	832	890
858	0.00729	0.00709	0.00276	0.00723	0.01078	0.01142	0.01148	0.01363	0.01380	0.01810	0.01821	0.02806	0.02853	0.02850	0.02816	0.02751	0.02749	0.02746	0.02740	0.02744	0.02744	0.02744	0.02737	0.02737	0.02737	0.020	0.011	0.048	0.236	2.789	858	890
858	0.01513	0.01502	0.01309	0.01086	0.00905	0.00959	0.00954	0.00733	0.00715	0.00273	0.00262	0.00568	0.00611	0.00394	0.00394	0.02755	0.02835	0.02814	0.02813	0.02812	0.02812	0.02812	0.02812	0.02812	0.02812	0.002	0.009	0.028	0.512	1.848	858	890
890	0.00187	0.00180	0.00100	0.00010	0.00219	0.00232	0.00234	0.00318	0.00322	0.00485	0.00480	0.00788	0.00863	0.01334	0.00840	0.02435	0.00814	0.00813	0.00812	0.00809	0.00811	0.00811	0.00811	0.00808	0.00808	-0.007	0.008	0.044	-3.130	14.462	890	890
834	0.01485	0.01476	0.01306	0.01106	0.00952	0.01009	0.01004	0.00800	0.00784	0.00376	0.00365	0.00397	0.00435	0.00060	0.00570	0.02145	0.00733	0.00729	0.00721	0.00703	0.00716	0.00716	0.00716	0.00695	0.00693	0.002	0.009	0.029	0.408	1.772	834	890
842	0.01484	0.01475	0.01306	0.01107	0.00955	0.01012	0.01007	0.00804	0.00788	0.00382	0.00371	0.00388	0.00425	0.00069	0.00560	0.02149	0.00723	0.00737	0.00711	0.00707	0.00708	0.00708	0.00705	0.00699	0.00698	0.002	0.009	0.029	0.407	1.775	842	890
860	0.01476	0.01468	0.01311	0.01126	0.00983	0.01042	0.01038	0.00841	0.00825	0.00432	0.00421	0.00314	0.00344	0.00143	0.00475	0.02189	0.00833	0.00828	0.00727	0.00604	0.00723	0.00723	0.00722	0.00695	0.00694	0.002	0.009	0.029	0.396	1.813	860	890
844	0.01476	0.01469	0.01307	0.01114	0.00969	0.01026	0.01022	0.00823	0.00808	0.00409	0.00398	0.00345	0.00379	0.00169	0.00511	0.02187	0.00871	0.00861	0.00727	0.00654	0.00655	0.00654	0.00719	0.00718	0.00718	0.002	0.009	0.029	0.403	1.795	844	890
836	0.01466	0.01458	0.01318	0.01153	0.01027	0.01087	0.01084	0.00897	0.00881	0.00508	0.00498	0.00201	0.00220	0.00255	0.00346	0.02290	0.00498	0.00493	0.00389	0.00469	0.00720	0.00721	0.00716	0.00460	0.00458	0.003	0.009	0.030	0.382	1.900	862	890
862	0.01465	0.01457	0.01319	0.01156	0.01031	0.01092	0.01088	0.00902	0.00887	0.00516	0.00506	0.00189	0.00207	0.00267	0.00332	0.02256	0.00483	0.00478	0.00574	0.00455	0.00707	0.00718	0.00701	0.00446	0.00445	0.003	0.009	0.030	0.384	1.912	862	890
840	0.01462	0.01455	0.01321	0.01162	0.01040	0.01102	0.01098	0.00914	0.00899	0.00532	0.00522	0.00165	0.00181	0.00291	0.00305	0.02269	0.00455	0.00450	0.00545	0.00427	0.00674	0.00675	0.00720	0.00418	0.00417	0.003	0.009	0.030	0.386	1.937	840	890
846	0.01460	0.01452	0.01315	0.01157	0.01029	0.01090	0.01087	0.00899	0.00884	0.00511	0.00501	0.00193	0.00212	0.00262	0.00336	0.02251	0.00488	0.00497	0.00476	0.00541	0.00471	0.00472	0.00471	0.00717	0.00716	0.003	0.009	0.030	0.401	1.921	846	890
848	0.01457	0.01450	0.01316	0.01163	0.01038	0.01099	0.01095	0.00910	0.00895	0.00525	0.00515	0.00172	0.00188	0.00283	0.00312	0.02250	0.00462	0.00471	0.00451	0.00515	0.00446	0.00446	0.00445	0.00691	0.00716	0.003	0.009	0.030	0.404	1.944	848	890

Fonte: Autoria própria

Confrontando o padrão de cor destacado em cada uma das linhas que compõem a Tabela 4.2 à Tabela 4.5 fica claro que o local de origem do evento influencia na distribuição dos valores de características resultantes em cada simulação, ou seja, o padrão de propagação do distúrbio é alterado. Essa diferença torna-se mais evidente, entre os padrões de cores resultantes das simulações que aplicam curto-circuito próximo à subestação (primeiras linhas), comparados com os padrões obtidos para simulações aplicadas em pontos distantes da subestação (últimas linhas). Com isto, fica claro que o evento originado pelo curto-circuito localizado nos nós próximos a subestação é propagado de forma diferente dos distúrbios originados nas barras distantes.

As matrizes de cores relacionadas com o conjunto de característica RMS e Valor de Pico denotam padrões equivalentes. Os menores valores dessas características são medidos nas barras próximas ao local de curto-circuito e também nas barras localizadas à jusante do ponto de curto-circuito; logo, em torno dessa região ocorre uma predominância da cor amarela ou vermelha. Nesses quadros, nota-se que as duas primeiras linhas, referente aos fenômenos modelados, respectivamente, nas barras 802 e 808, possuem duas cores predominantes (vermelho e verde). Em sequência, as próximas linhas realçam um padrão diferente, onde fica clara a predominância de três cores, representando uma maior diversificação na forma como o distúrbio é disseminado.

Há de se considerar que a distribuição em torno da tonalidade das cores averiguadas entre as últimas linhas do quadro são semelhantes. Tais linhas caracterizam as simulações que modelam um curto-circuito nas barras localizadas após o nó 834. Logo, quanto mais distante for o local do curto-circuito em relação à subestação mais severo será o distúrbio evidenciado próximo ao local de origem.

De modo suplementar, a característica Fator de Pico destaca um padrão de cor equivalente entre as linhas. No quadro que caracteriza essa característica nota-se que nas primeiras colunas da tabela predomina a cor vermelha; logo, independentemente do local de aplicação do curto-circuito trifásicos com resistência de $10\ \Omega$ e ângulo de fase 0° , o menor Fator de Pico será evidenciado nas barras próximas à subestação. Para as colunas que representam um nó mais afastado da subestação, a característica obtida apresenta um valor próximo à média, exceção para curtos-circuitos localizados nos últimos nós do sistema, onde o Fator de Pico calculado nestas barras apresenta um valor acima da média.

Por sua vez, a Tabela 4.5 determina a visualização da característica Valor Médio. Como comentado, o valor desta característica varia em torno de 0 e denota o comportamento do transitório oscilatório. Assim, quanto mais distante de 0 for o valor médio calculado de um sinal senoidal mais intenso será o transitório oscilatório. De forma a melhor representar esta evidência, a Tabela 4.5 apresenta o valor absoluto dessa característica e quanto mais baixo o valor desta característica, menor será a intensidade do transitório oscilatório.

Assim, pelo quadro de matriz de cor observa-se que os menores valores estão localizados nos elementos relacionados às colunas localizadas no meio da tabela. Há de se considerar também que nesta região está presente um regulador de tensão somado com transformador conectado entre as barras 852 e 888. Logo, estes componentes do sistema influenciam na presença do transitório. Adicionalmente, em torno da diagonal principal destaca-se uma tonalidade amarela, onde o valor médio caracteriza um transitório oscilatório próximo à média da simulação.

Por fim, é preciso acentuar que a Tabela 4.2 à Tabela 4.5 determinam que as simulações envolvendo os nós 890 e 888 evidenciam um padrão de cor discrepante, quando comparada com os demais casos. Essas barras estão localizadas após um transformador de linha, que abaixa a tensão do barramento, sendo que mais uma vez a propagação do distúrbio é influenciada por este componente.

Diante deste mapeamento visual, conclui-se que o local de origem do curto-circuito influi na forma como o distúrbio de afundamento de tensão ou interrupção de tensão é disseminado no sistema de distribuição. Analisando os valores das métricas estatísticas calculadas em cada simulação e apresentadas nas últimas colunas de cada tabela, torna-se possível descrever quantitativamente a distribuição dos valores de mesma natureza (RMS, Valor de Pico, Valor Médio e Fator de Pico). Com isto é

possível evidenciar de forma mais clara as tendências de propagação em relação ao local de origem do distúrbio.

Assim, os valores das métricas estatísticas de cada simulação de curto-circuito trifásico com resistência de $10\ \Omega$ e ângulo de fase 0° são confrontados visualmente, mediante um gráfico de linhas apresentados nas Figura 4.6 à Figura 4.9. Cada figura está relacionada, respectivamente, com as medidas estáticas calculadas para as características RMS, Valor de Pico, Fator de Pico e Valor Médio, as quais são compostas pelos gráficos Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e). O eixo da abcissa apresenta o local de aplicação do curto-circuito e o eixo das ordenadas destaca o valor da métrica obtida na simulação; por conseguinte, tais gráficos permitem que se tenha uma visão global da tendência, distribuição e dispersão do conjunto de características obtido em cada simulação (linhas).

Figura 4.6- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica RMS, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.

Fonte: Autoria própria.

Figura 4.7- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Valor de Pico, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.

Fonte: Autoria própria.

Nas Figura 4.6 e Figura 4.7 verificam-se que as medidas estatísticas calculadas das características RMS e Valor de Pico destacam uma distribuição semelhante em torno do conjunto de dados obtidos em cada simulação de curto-circuitos trifásicos com resistência de $10\ \Omega$, uma vez que o contorno das linhas fornecidas no gráfico relacionados com as 5 métricas são equivalentes.

Analisando a métrica média observa-se que um curto-circuito com resistência $10\ \Omega$ possui um valor de média constante, em quase todos os casos. Assim, os valores de RMS e Pico obtido em cada barra estão situados respectivamente em torno de 0,2 e 0,3. Estes valores representam uma tendência global do sistema independentemente do local do curto-circuito, exceção nas barras 888 e 890 devido ao fato de estarem localizadas após um transformador de linha, que abaixa a tensão do barramento.

Com relação à medida desvio padrão e amplitude é observado que o curto-circuito localizado próximo à subestação (802, 806, 808 e 812) resulta em um desvio padrão pequeno, quando comparado com o desvio padrão e amplitude obtidos para as demais simulações. O desvio padrão exprime uma medida de dispersão dos dados em torno da média. Logo, esse baixo valor demonstra que para curtos-circuitos

localizados próximos à subestação o distúrbio é propagado com amplitude semelhante e próximo ao valor da média em todas as barras do sistema.

De acordo com a assimetria, as simulações que envolvem as barras próximas da subestação e as barras 888 e 890 retornam uma assimetria negativa, permitindo afirmar que para estes casos a dispersão do conjunto de características RMS e Valor de Pico apresentam uma maior concentração de valores abaixo do valor da métrica média. Por outro lado, nas demais simulações são obtidas uma assimetria positiva, exibindo uma maior variedade de valores acima da média.

Para medida de curtoses as simulações que originam distúrbio próximo à subestação denotam um valor de curtose menor que 3, caracterizando uma maior concentração de valores em seu pico modal. Porém, eventos originados no meio do sistema o pico modal é maior que 3 e os valores à sua vizinhança são representativos para a totalidade. Em última análise, para simulações envolvendo as barras distantes da subestação, o valor de curtose é próximo de 3, destacando uma distribuição bem próxima da curva normal. Convém observar que como as características RMS e Valor de Pico fornecem informações semelhantes, nas próximas análises será avaliada somente a distribuição do RMS, sendo que a compressão em torno desta característica pode ser estendida para a característica Valor de Pico.

Figura 4.8 – Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Fator de Pico, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.

Fonte: Autoria própria.

A Figura 4.8 exprime o gráfico de linha para as métricas calculadas do conjunto de característica Fator de Pico. Os dados apresentam que os distúrbios localizados nas primeiras barras do sistema destacam um baixo valor de média, desvio padrão e amplitude, quando comparada com as simulações que modelam um curto-circuito originado distante da subestação. Assim, nos primeiros casos, o vetor Fator de Pico representa uma dispersão dos dados homogênea e apresenta uma distribuição com valores próximos da média. À medida que o local de aplicação do curto-circuito se Distância da subestação ocorre um aumento no valor da média, desvio padrão e amplitude. Nas barras 888 e 890 estas métricas apresentam valores baixos, devido à presença do transformador abaixador que altera o padrão de propagação nos demais nós.

Com relação às medidas assimetria e curtoses, responsáveis por quantificar a dispersão dos dados em torno da média, destaca-se que em quase todos os casos foram obtidos valores que caracterizam uma distribuição simétrica, onde a assimetria é próxima de 0 e o valor de curtose fica em torno de 3. Diferenças significativas são encontradas quando o distúrbio está localizado nas barras próximas ao transformador abaixador, onde se encontra valores altos tanto para curtoses como para assimetria.

Figura 4.9 – Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Valor Médio, extraídas das simulações de curto-circuito trifásico, variando a barra de origem do evento.

Fonte: Autoria própria.

A Figura 4.9 destaca as medidas estatísticas calculadas a partir do conjunto de característica Valor Médio, resultantes das simulações de curto-circuito trifásico de $10\ \Omega$ e ângulo de fase de 0° . O gráfico referente à métrica média descreve que o transitório oscilatório é menos intenso nos casos onde o distúrbio é originado distante da subestação. O valor do desvio padrão e da amplitude diminui à medida que a origem do evento se Distância da subestação; portanto, o transitório oscilatório no início do evento é propagado com características semelhantes quando o curto-circuito é aplicado em barras distantes.

Um curto-circuito trifásico próximo à subestação apresenta uma assimetria negativa, em termos da distribuição dos valores referente à característica Valor Médio. Por outro lado, um curto-circuito originado a partir da barra 828 a assimetria torna-se positiva. Convém observar que para curtos-circuitos aplicados longe da subestação o vetor da característica valor médio destaca valores de média, desvio padrão, assimetria e curtose praticamente constantes.

Dado a análise acima, nota-se que a distância de origem do distúrbio em relação à subestação exerce influência na forma como o distúrbio originado pelo curto-circuito é disseminado em cada barra do sistema de distribuição. Para isto foram analisados os dados provenientes das simulações de curto-circuito trifásico com resistência de $10\ \Omega$ e ângulo de fase igual a 0° . Diante de tal situação, cabe averiguar se a natureza do curto-circuito (ângulo de fase, resistência e tipo do curto-circuito) interfere no comportamento do evento.

Assim, a seguir é avaliada a influência do valor de resistência de curto-circuito. Para isto, são confrontados os vetores de características resultantes das simulações de curto-circuitos trifásicos com ângulo de fase de 0° , onde o valor de resistência é diversificado entre $1\ \Omega$, $10\ \Omega$, $20\ \Omega$, $30\ \Omega$, $40\ \Omega$ e $50\ \Omega$, em que $1\ \Omega$ corresponde a um curto-circuito mais severo e $50\ \Omega$ um evento menos severo. Dessa maneira, a Figura 4.10 confronta, por meio de uma matriz de cor, os vetores relacionados à característica RMS extraídos dos distúrbios originados a partir da falta trifásica de $1\ \Omega$ (a), $10\ \Omega$ (b), $20\ \Omega$ (c), $30\ \Omega$ (d), $40\ \Omega$ (e) e $50\ \Omega$ (f).

Figura 4.10 – Matriz de cores da Característica RMS resultante das simulações de curtos-circuitos trifásicos de 1 Ω (a) 10 Ω (b), 20 Ω (c), 30 Ω (d), 40 Ω (e) e 50 Ω (f) com ângulo de incidência 0°.

Fonte: Autoria própria

Pela Figura 4.10 observa-se que para todos os cinco casos de curto-circuitos a matriz apresentou o mesmo padrão de cor; porém, quanto maior o valor de resistência, mais claro é o tom de cor visualizado em torno da diagonal principal. Portanto, presume-se que quanto menor a resistência de curto-circuito, mais severo é o distúrbio evidenciado em cada barra.

Tal tendência pode ser mais bem visualizada a partir dos gráficos de linhas que são apresentados na Figura 4.11. Eles são responsáveis por comparar a tendência (média), distribuição (desvio padrão e amplitude) e dispersão (assimetria e curtoses) do conjunto de dados RMS resultantes das simulações de curto-circuitos trifásicos com resistência de 1 Ω (preto), 10 Ω (azul), 20 Ω (roxo), 30 Ω (vermelho), 40 Ω (amarelo) e 50 Ω (verde), aplicados em todas as barras do sistema.

Figura 4.11 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica RMS extraídas das simulações de curto-circuito trifásico com resistência de 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω com ângulo de incidência 0°.

Fonte: Autoria própria

Dados os gráficos de linhas apresentados na Figura 4.11 observa-se que em um curto-circuito trifásico de 1 Ω a tensão média do distúrbio evidenciado nas barras é menor que a tensão média obtida em um curto-circuito com resistência de 50 Ω . A métrica média quantifica o valor central para uma distribuição; logo, neste caso ela resume o conjunto dos valores RMS obtidos em uma simulação em um valor típico. Assim, comparando a área destacada em cada série, pode-se concluir que a média do conjunto RMS é diretamente proporcional ao valor da resistência de curto-circuito.

As medidas desvio padrão e amplitude quantificam a dispersão do conjunto de dados em relação à média; logo, definem se o distúrbio propagado no sistema é evidenciado em cada barra com características semelhantes ou diferentes. De acordo com o gráfico destas métricas, observa-se que quanto maior o valor da resistência de curto-circuito menor o valor do desvio padrão e amplitude medida e, por conseguinte, o distúrbio é evidenciado com valores de características RMS semelhantes em cada nó. A seguir a Figura 4.12 confronta, respectivamente, a matriz de cor obtida a partir do conjunto de característica Fator de Pico das simulações de curto-circuitos trifásicos com resistência de 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω .

Figura 4.12 – Matriz de Cores da Característica Fator de Pico resultante das simulações de curtos-circuitos trifásicos de 1 Ω (a) 10 Ω (b), 20 Ω (c), 30 Ω (d), 40 Ω (e) e 50 Ω (f) com ângulo de incidência 0°.

Fonte: Autoria própria

A matriz que representa os dados do Fator de Pico obtidos para as simulações de curtos-circuitos com resistência de 1 Ω indica que o menor fator de pico é medido nas barras localizadas próximas a subestação. Com relação ao curto-circuito com resistência de 10 Ω a Figura 4.12b ilustra um padrão de propagação equivalente entre as simulações, onde para cada linha os menores valores estão localizados na posição à esquerda da matriz de cor.

À medida que o valor de resistência aumenta, a coloração em torno da diagonal principal apresenta uma tonalidade em verde (Figura 4.12b, Figura 4.12c, Figura 4.12d, Figura 4.12e). Tal fato torna-se mais evidente nos casos onde o curto-circuito é aplicado próximo a subestação, indicando que o aumento da resistência do

curto-circuito, aumentou também o valor do Fator de Pico extraído nas barras próximas ao local de origem.

Nessa perspectiva é possível destacar que a resistência impacta na distribuição do valor Fator de Pico extraído em cada nó do sistema. Essa discrepância é visualizada quando se confronta o padrão entre as series ilustradas pelos gráficos de linhas apresentado na Figura 4.13.

Figura 4.13 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da Característica Fator de Pico extraída das simulações de curto-circuito trifásico com resistência de 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω com ângulo de incidência 0°.

Fonte: Autoria própria

O gráfico de linhas apresentados nas Figura 4.13a, Figura 4.13b e Figura 4.13c confrontam as métricas média, desvio padrão e amplitude obtidas em cada simulação, de acordo com o valor de resistência. Desse modo, nota-se que um curto-circuito de resistência 1 Ω e 10 Ω aumenta a dispersão dos dados que compõem o vetor resultante da simulação. Por outro lado, para faltas de 20 Ω , 30 Ω , 40 Ω e 50 Ω o gráfico destaca uma variância semelhante, independentemente do valor da resistência. Nesse caso, como a característica Fator de Pico quantifica a relação entre o valor de pico do transitório oscilatório e o valor RMS do sinal, pode-se concluir que quanto menor o valor de resistência mais evidente o transitório oscilatório no sinal em relação a amplitude do distúrbio.

Há de se considerar que os gráficos de linhas relacionados às métricas assimetria e curtoses exemplificam que quando o local de aplicação do curto-circuito encontra-se longe da subestação a distribuição amostral em torno do ponto médio são semelhantes, independentemente do valor de resistência da falta. Para os demais casos, observou-se que alterando o valor de resistência acarreta em uma mudança no contorno da linha.

Para fim da análise em torno da interferência do valor de resistência de curto-circuito, a Figura 4.14 confronta a distribuição do conjunto de característica Valor Médio resultantes das simulações de curto-circuitos trifásicos com resistência de 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω .

Figura 4.14 – Matriz de Cores da Característica Valor Médio resultante das simulações de curtos-circuitos trifásicos de 1 Ω (a), 10 Ω (b), 20 Ω (c), 30 Ω (d), 40 Ω (e) e 50 Ω (f) com ângulo de incidência 0°.

Fonte: Autoria própria

No que tange a matriz de cores da característica Valor Médio (Figura 4.14) a cor verde encontra-se relacionada com as barras que apresentam maior valor desta característica e, conseqüentemente, o local onde o transitório oscilatório presente no sinal é evidenciado de forma mais acentuada. O aumento do valor da resistência de curto-circuito provoca o aumento da característica Valor Médio nas barras próximas à origem (cor verde em torno da diagonal principal) do distúrbio reduzindo o valor desta característica nas barras localizadas distante do local de curto. De modo a clarificar esta tendência, a Figura 4.15 ilustra os gráficos de linhas das métricas estatísticas obtidas nesses casos.

Figura 4.15 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da Característica Valor Médio extraída das simulações de curto-circuito trifásico com resistência de 1 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω com ângulo de incidência 0°.

Fonte: Autoria própria

Os gráficos apresentados na Figura 4.15 resumem as informações a respeito da distribuição dos valores da característica Valor Médio obtida em cada simulação. De acordo com os gráficos de assimetria e curtose destaca-se que os dados apresentam um padrão semelhante, independentemente do valor da resistência. Entretanto, para as métricas desvio padrão e amplitude, tal equivalência não é evidenciada e, portanto, a dispersão do vetor resultante da característica Valor Médio de cada simulação sofre influencia do valor de resistência do curto-circuito.

Após a análise da influência da resistência de curto-circuito, faz-se necessário analisar o comportamento, em termos dos valores de características, referente às mudanças do ângulo de incidência. A partir disso pretende-se descobrir como o valor do ângulo interfere na propagação do distúrbio ocasionado por curto-circuito.

Para isto, os dados de curto-circuitos trifásicos de $10\ \Omega$ com ângulo de incidência de 0° são confrontados com os valores obtidos das simulações de curto-circuitos trifásicos de $10\ \Omega$ e ângulo de fase igual a 90° . A Figura 4.16, fornece uma comparação, por meio de uma matriz de cor, da característica RMS obtidas das simulações que modelam esses dois cenários. Por sua vez, a Figura 4.17 apresenta o gráficos de linhas das métricas estatísticas.

A partir das comparações ilustradas entre as Figura 4.16 e Figura 4.17 fica claro que o ângulo de incidência não interfere na disseminação dos valores RMS resultantes das simulações. Nesses casos, o distúrbio é evidenciado de forma mais intensa nas barras localizadas próximas ao ponto de ocorrência do curto-circuito.

Figura 4.16 – Matriz de cor para característica RMS para simulações de curtos-circuitos trifásicos de $10\ \Omega$ com ângulo de fase de 0° (a), 90° (b).

Fonte: Autoria própria

Figura 4.17 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica RMS extraídas das simulações de curto-circuito trifásico com resistência de $10\ \Omega$ e ângulo de fase 0° e 90° .

Fonte: Autoria própria

A seguir, a análise é estendida para o conjunto de característica Fator de Pico e Valor Médio das simulações de curto-circuito trifásica de $10\ \Omega$, onde se altera o ângulo de fase entre os valores 0° e 90° . Nessa perspectiva, as Figura 4.18 e Figura 4.19 apresentam a matriz de cores, encarregadas de confrontar o conjunto de características Fator de Pico e Valor Médio extraídos dos distúrbios evidenciados em cada simulação.

Figura 4.18 – Matriz de cor para característica Fator de Pico para simulações de curtos-circuitos trifásicos de $10\ \Omega$ com ângulo de fase de 0° (a) e 90° (b).

Fonte: Autoria própria

Figura 4.19 – Matriz de cor para característica Valor Médio para simulações de curtos-circuitos trifásicos de $10\ \Omega$ com ângulo de fase de 0° (a) e 90° (b).

Fonte: Autoria própria

Assim sendo, observa-se que a distribuição dos valores destas características é influenciada pelo ângulo de incidência, onde cada matriz destaca um padrão de cor diferente. As matrizes demonstram que para os distúrbios evidenciados a partir de curto-circuito com ângulo de incidência 0° as barras localizadas ao lado esquerdo da matriz apresentam menores valores da característica Fator de Pico, independentemente do local de aplicação da falta (Figura 4.18a), e uma maior caracterização do transitório oscilatório (Figura 4.19a).

Por sua vez, a interferência do ângulo de incidência igual a 90° resulta em um maior valor de Fator de Pico observado nas barras localizadas mais distantes da subestação (Figura 4.18b) e uma menor caracterização do distúrbio transitório oscilatório (Figura 4.19b).

Fundamentado nos dados visualizados a partir da matriz de cor, a Figura 4.20 e Figura 4.21 apresentam, respectivamente, os gráficos de linhas das métricas característica Fator de Pico e Valor Médio, as quais ilustram a disposição da distribuição dos vetores de características resultantes das simulações.

Figura 4.20 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica Fator de Pico extraídas das simulações de curto-circuito trifásico com resistência de $10\ \Omega$ e ângulo de fase 0° e 90° .

Fonte: Autoria própria

Figura 4.21 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude(c), Assimetria (d) e Curtoses (e) da Característica Valor Médio extraídas das simulações de curto-circuito trifásico com resistência de $10\ \Omega$ e ângulo de fase 0° e 90° .

Fonte: Autoria própria

De acordo com os gráficos de linhas, fica claro que o ângulo de incidência altera a forma de como o distúrbio é disseminado em cada nó do sistema, em termos das características Fator de Pico e Valor Médio, ao contrário da distribuição obtida para a característica RMS (Figura 4.17), a qual não é influenciada pelo ângulo de

incidência do curto-circuito, sendo possível obter uma tendência global que depende apenas do valor do local de aplicação do curto-circuito.

Após a análise de como os fatores ângulo de incidência e resistência definem a propagação do distúrbio em termos de características RMS, Fator de Pico e Valor Médio extraídas do sinal, faz-se necessário analisar, em último caso, a ação dos diferentes tipos de tipos de curto-circuito (trifásicos, bifásicos e monofásicos).

Para tanto, as métricas obtidas a partir do vetor de características resultantes das simulações que aplicam curto-circuito trifásico, bifásico e monofásico com resistência $10\ \Omega$ e um ângulo de fase de 0° são confrontadas por meio de um gráfico de linhas. Logo, nestes casos, o tipo de curto-circuito será o fator variável e a disseminação do evento será influenciada por ele. A Figura 4.22, Figura 4.23 e Figura 4.24 ilustra o gráfico obtido para as características RMS, Fator de Pico e Valor Médio.

Figura 4.22 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da característica RMS das simulações de curto-circuito trifásico, bifásicos e monofásico com resistência de $10\ \Omega$ e ângulo de fase 0° .

Fonte: Autoria própria

Figura 4.23 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da característica Fator de Pico das simulações de curto-circuito trifásico, bifásicos e monofásico com resistência de $10\ \Omega$ e ângulo de fase 0°

Métricas Estatísticas Característica Fator de Pico

Fonte: Autoria própria

Figura 4.24 – Comparação por meio de gráfico de linha das Métricas Estatísticas Média (a), Desvio Padrão (b), Amplitude (c), Assimetria (d) e Curtoses (e) da característica Valor médio das simulações de curto-circuito trifásico, bifásicos e monofásico com resistência de $10\ \Omega$ e ângulo de fase 0° .

Métricas Estatísticas Característica Valor Médio

Fonte: Autoria própria

Os gráficos apresentados na Figura 4.22, Figura 4.23 e Figura 4.24 mostram que a característica RMS e Valor Médio fornecem medidas de tendência, distribuição

e dispersão com padrões de linhas equivalentes, independentemente do tipo de curto-circuito modelado. Por outro lado, a característica Fator de Pico em alguns casos destaca uma distribuição diferente de acordo com o local de aplicação do curto-circuito e do tipo do curto-circuito. Isto ocorre porque esta característica é fortemente influenciada pelo pico do transitório oscilatório, ou seja, quando o valor desta componente ultrapassa o valor da amplitude do distúrbio, a relação entre o valor RMS e o Valor de Pico do sinal detectado se reflete na característica Fator de Pico.

4.2.2 Análise de Simulações Ocasionadas pelo Chaveamento de Banco de Capacitores

Essa análise visa averiguar o comportamento do distúrbio, em termos dos valores das características RMS, Valor de Pico, Fator de Pico e Valor Médio, ocasionados a partir de um evento de chaveamento de banco de capacitores que foi modelado no Sistema IEEE 34-nós, sendo que este evento ocasiona a ocorrência de distúrbio de elevação de tensão.

A relação entre a distribuição dos valores que compõem o conjunto de características resultantes de cada simulação de acordo com o local de origem do evento pode ser visualizada mediante uma matriz de cor. Assim, a Tabela 4.6, Tabela 4.7, Tabela 4.8 e Tabela 4.9 destacam os quadros obtidos, respectivamente, para as características RMS, Valor de Pico, Fator de Pico e Valor Médio. As 7 últimas colunas fornecem os valores, respectivamente, das métricas estatísticas média, desvio padrão, amplitude, assimetria, curtose e destacam o nó que apresentou maior valor e menor valor da característica analisada em cada linha.

É importante clarificar que na matriz de cor, os pontos vermelhos correspondem aos locais onde o distúrbio é sentido com maior amplitude, exceção à característica Valor Médio, onde estes locais são representados pelos pontos verdes.

Tabela 4.6 – Quadro do conjunto de Característica RMS resultantes das simulações que modelam chaveamento de banco de capacitor.

RMS																												Métricas Estadísticas					
802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848	Media	Desv Pad.	Ampl.	Assim.	Curtores	Min	Max		
802	0.8570	0.8559	0.8397	0.8228	0.8094	0.8353	0.8350	0.8290	0.8285	0.8167	0.8164	0.7956	0.8710	0.8667	0.8699	0.7874	0.8685	0.8685	0.8684	0.8683	0.8683	0.8683	0.8685	0.8686	0.846	0.026	0.084	-0.728	2.240	890	832		
806	0.8568	0.8572	0.8412	0.8242	0.8108	0.8366	0.8363	0.8303	0.8298	0.8179	0.8176	0.7968	0.8723	0.8680	0.8712	0.7885	0.8698	0.8698	0.8697	0.8696	0.8696	0.8696	0.8698	0.8699	0.847	0.026	0.084	-0.726	2.247	890	832		
808	0.8526	0.8533	0.8676	0.8500	0.8361	0.8622	0.8620	0.8538	0.8532	0.8385	0.8381	0.8162	0.8935	0.8891	0.8923	0.8076	0.8910	0.8909	0.8908	0.8907	0.8907	0.8907	0.8909	0.8910	0.867	0.026	0.086	-0.652	2.319	890	832		
812	0.8475	0.8480	0.8592	0.8765	0.8621	0.8890	0.8887	0.8803	0.8797	0.8644	0.8641	0.8374	0.9099	0.9005	0.9087	0.8225	0.9074	0.9073	0.9072	0.9071	0.9071	0.9071	0.9073	0.9074	0.884	0.027	0.087	-0.739	2.326	890	832		
814	0.8421	0.8425	0.8506	0.8647	0.8787	0.9061	0.9059	0.8972	0.8965	0.8810	0.8806	0.8533	0.9164	0.9119	0.9152	0.8359	0.9138	0.9138	0.9136	0.9136	0.9135	0.9135	0.9135	0.9138	0.9138	0.892	0.028	0.080	-0.878	2.215	890	832	
850	0.8500	0.8504	0.8602	0.8765	0.8925	0.9203	0.9201	0.9109	0.9113	0.9016	0.8950	0.8946	0.8671	0.9413	0.9367	0.9400	0.8502	0.9396	0.9395	0.9394	0.9393	0.9393	0.9393	0.9395	0.9396	0.911	0.034	0.091	-0.731	2.015	890	832	
816	0.8499	0.8503	0.8600	0.8763	0.8924	0.9202	0.9201	0.9114	0.9117	0.9016	0.8950	0.8946	0.8671	0.9412	0.9367	0.9399	0.8502	0.9395	0.9395	0.9393	0.9393	0.9392	0.9392	0.9395	0.9395	0.910	0.034	0.091	-0.733	2.017	890	832	
824	0.8463	0.8466	0.8548	0.8694	0.8839	0.9115	0.9116	0.9134	0.9129	0.8970	0.8966	0.8690	0.9402	0.9356	0.9389	0.8516	0.9375	0.9375	0.9373	0.9372	0.9372	0.9372	0.9374	0.9375	0.909	0.034	0.094	-0.715	1.995	890	832		
826	0.8460	0.8463	0.8544	0.8699	0.8833	0.9108	0.9109	0.9127	0.9129	0.8972	0.8968	0.8692	0.9400	0.9355	0.9388	0.8516	0.9373	0.9373	0.9371	0.9371	0.9370	0.9370	0.9373	0.9373	0.908	0.034	0.094	-0.712	1.993	890	832		
830	0.8389	0.8390	0.8442	0.8553	0.8671	0.8941	0.8942	0.8948	0.8949	0.8897	0.8893	0.8715	0.9341	0.9296	0.9329	0.8537	0.9314	0.9314	0.9312	0.9312	0.9311	0.9311	0.9311	0.9314	0.9314	0.901	0.035	0.095	-0.605	1.890	890	832	
854	0.8387	0.8388	0.8439	0.8549	0.8667	0.8937	0.8937	0.8943	0.8945	0.8891	0.8893	0.8715	0.9339	0.9295	0.9327	0.8537	0.9312	0.9312	0.9311	0.9310	0.9309	0.9309	0.9309	0.9312	0.9312	0.901	0.035	0.095	-0.600	1.885	890	832	
852	0.8251	0.8249	0.8247	0.8295	0.8363	0.8624	0.8624	0.8609	0.8608	0.8612	0.8613	0.8681	0.9300	0.9253	0.9278	0.8496	0.9253	0.9253	0.9250	0.9250	0.9246	0.9246	0.9246	0.9250	0.885	0.041	0.105	-0.184	1.358	890	832		
832	0.8348	0.8347	0.8355	0.8431	0.8533	0.8799	0.8799	0.8794	0.8795	0.8825	0.8826	0.8961	0.9599	0.9552	0.9577	0.8754	0.9551	0.9551	0.9547	0.9548	0.9544	0.9544	0.9544	0.9548	0.909	0.048	0.125	-0.237	1.436	890	832		
888	0.7436	0.7426	0.7285	0.7144	0.6857	0.7265	0.7262	0.7212	0.7208	0.6971	0.6967	0.7616	0.7589	0.7522	0.7579	0.6759	0.7568	0.7567	0.7566	0.7566	0.7565	0.7565	0.7567	0.7568	0.733	0.031	0.108	-0.059	1.308	890	888		
858	0.8327	0.8326	0.8325	0.8391	0.8486	0.8750	0.8750	0.8741	0.8742	0.8765	0.8766	0.8889	0.9523	0.9476	0.9558	0.8684	0.9532	0.9532	0.9528	0.9525	0.9525	0.9525	0.9529	0.9529	0.905	0.049	0.123	-0.189	1.367	890	858		
890	0.7431	0.7421	0.7280	0.7138	0.6849	0.7256	0.7254	0.7203	0.7199	0.6962	0.6959	0.7608	0.7576	0.7596	0.7568	0.6580	0.7555	0.7554	0.7553	0.7552	0.7552	0.7552	0.7555	0.7555	0.732	0.030	0.101	-0.105	1.301	890	888		
834	0.8302	0.8300	0.8289	0.8343	0.8428	0.8691	0.8691	0.8678	0.8678	0.8694	0.8695	0.8804	0.9431	0.9385	0.9465	0.8596	0.9507	0.9507	0.9503	0.9504	0.9500	0.9499	0.9499	0.9504	0.9504	0.900	0.049	0.122	-0.136	1.306	890	834	
842	0.8301	0.8299	0.8288	0.8341	0.8425	0.8688	0.8688	0.8675	0.8675	0.8690	0.8691	0.8800	0.9427	0.9380	0.9460	0.8595	0.9502	0.9502	0.9498	0.9502	0.9495	0.9495	0.9494	0.9502	0.9503	0.900	0.049	0.122	-0.134	1.304	890	842	
890	0.8296	0.8294	0.8280	0.8330	0.8413	0.8675	0.8675	0.8662	0.8662	0.8675	0.8676	0.8782	0.9408	0.9361	0.9440	0.8577	0.9482	0.9482	0.9482	0.9479	0.9498	0.9498	0.9498	0.9499	0.9499	0.898	0.049	0.122	-0.124	1.295	890	890	
844	0.8296	0.8293	0.8279	0.8329	0.8412	0.8674	0.8674	0.8660	0.8660	0.8673	0.8674	0.8779	0.9405	0.9358	0.9438	0.8575	0.9479	0.9482	0.9482	0.9475	0.9495	0.9495	0.9495	0.9496	0.9496	0.898	0.049	0.122	-0.126	1.296	890	844	
836	0.8290	0.8285	0.8267	0.8313	0.8393	0.8654	0.8654	0.8639	0.8639	0.8649	0.8650	0.8751	0.9375	0.9338	0.9407	0.8547	0.9448	0.9448	0.9448	0.9445	0.9495	0.9495	0.9495	0.9495	0.9495	0.896	0.049	0.123	-0.109	1.285	890	836	
862	0.8287	0.8284	0.8266	0.8311	0.8390	0.8652	0.8652	0.8636	0.8636	0.8646	0.8647	0.8749	0.9371	0.9325	0.9404	0.8544	0.9445	0.9444	0.9444	0.9441	0.9492	0.9495	0.9491	0.9491	0.9491	0.896	0.049	0.123	-0.108	1.284	890	862	
840	0.8285	0.8283	0.8263	0.8307	0.8386	0.8647	0.8647	0.8631	0.8631	0.8641	0.8642	0.8741	0.9368	0.9318	0.9396	0.8535	0.9437	0.9437	0.9437	0.9434	0.9484	0.9484	0.9484	0.9484	0.9484	0.895	0.049	0.123	-0.106	1.281	890	840	
846	0.8282	0.8280	0.8259	0.8301	0.8378	0.8639	0.8639	0.8623	0.8623	0.8631	0.8632	0.8729	0.9352	0.9305	0.9384	0.8527	0.9424	0.9427	0.9420	0.9440	0.9417	0.9416	0.9416	0.9482	0.9482	0.894	0.048	0.122	-0.105	1.279	890	846	
848	0.8280	0.8278	0.8256	0.8297	0.8373	0.8634	0.8634	0.8618	0.8617	0.8625	0.8626	0.8722	0.9344	0.9298	0.9376	0.8519	0.9416	0.9419	0.9412	0.9431	0.9409	0.9408	0.9408	0.9474	0.9480	0.893	0.048	0.122	-0.103	1.277	890	848	

Fonte: Autoria própria

Tabela 4.7 – Quadro do conjunto de Característica Valor de Pico resultante das simulações que modelam chaveamento de banco de capacitor.

Valor de Pico																												Métricas Estatísticas					
	802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848	Media	Desv Pad.	Ampl.	Assim.	Curtores	Min	Max	
802	1.2171	1.2266	1.2339	1.2107	1.1924	1.1988	1.1984	1.1779	1.1772	1.1605	1.1601	1.1306	1.2377	1.2317	1.2362	1.1191	1.2343	1.2343	1.2341	1.2340	1.2340	1.2340	1.2340	1.2343	1.2344	1.208	0.036	0.119	-0.089	3.020	890	832	
806	1.2307	1.2172	1.2352	1.2118	1.1934	1.1984	1.1980	1.1786	1.1788	1.1620	1.1616	1.1322	1.2374	1.2334	1.2367	1.1206	1.2360	1.2360	1.2358	1.2357	1.2356	1.2356	1.2360	1.2361	1.209	0.036	0.119	-0.083	3.010	890	832		
808	1.2263	1.2274	1.2540	1.2286	1.2086	1.2466	1.2463	1.2344	1.2335	1.2210	1.2115	1.1546	1.2640	1.2579	1.2624	1.1426	1.2605	1.2604	1.2602	1.2602	1.2601	1.2601	1.2601	1.2605	1.2605	1.238	0.032	0.121	-1.725	5.399	890	832	
812	1.1916	1.1967	1.2158	1.2040	1.2202	1.2252	1.2250	1.2460	1.2451	1.2235	1.2229	1.1581	1.2875	1.2813	1.2858	1.1404	1.2839	1.2838	1.2836	1.2835	1.2835	1.2835	1.2836	1.2839	1.2839	1.251	0.038	0.124	-0.744	2.336	890	832	
814	1.1916	1.1920	1.2030	1.2241	1.2241	1.2844	1.2844	1.3046	1.2705	1.2697	1.2474	1.2468	1.2080	1.2968	1.2905	1.2951	1.1836	1.2921	1.2921	1.2929	1.2928	1.2928	1.2928	1.2931	1.2932	1.264	0.040	0.121	-0.868	2.203	890	816	
816	1.2028	1.2034	1.2175	1.2410	1.2763	1.3032	1.3036	1.2907	1.2898	1.2674	1.2668	1.2278	1.3323	1.3259	1.3305	1.2035	1.3285	1.3284	1.3282	1.3281	1.3280	1.3280	1.3280	1.3284	1.3285	1.291	0.048	0.129	-0.796	2.087	890	832	
818	1.2027	1.2032	1.2173	1.2406	1.2891	1.3285	1.3299	1.2909	1.2900	1.2674	1.2669	1.2278	1.3323	1.3258	1.3304	1.2035	1.3284	1.3283	1.3281	1.3280	1.3279	1.3279	1.3279	1.3283	1.3284	1.291	0.048	0.130	-0.836	2.143	890	832	
820	1.1977	1.1981	1.2101	1.2310	1.2523	1.2914	1.2913	1.2937	1.3167	1.2705	1.2699	1.2307	1.3308	1.3244	1.3290	1.2062	1.3270	1.3269	1.3267	1.3266	1.3266	1.3266	1.3270	1.3270	1.3270	1.287	0.049	0.133	-0.766	2.027	890	832	
828	1.1973	1.1977	1.2095	1.2303	1.2512	1.2902	1.2902	1.3072	1.3261	1.2707	1.2702	1.2301	1.3308	1.3242	1.3288	1.2064	1.3268	1.3267	1.3265	1.3264	1.3264	1.3264	1.3267	1.3268	1.3268	1.287	0.048	0.133	-0.753	2.027	890	832	
830	1.1872	1.1874	1.1951	1.2111	1.2282	1.2664	1.2665	1.2675	1.2677	1.2740	1.2709	1.2310	1.3225	1.3176	1.3211	1.2094	1.3185	1.3184	1.3183	1.3181	1.3182	1.3182	1.3184	1.3184	1.3184	1.277	0.049	0.135	-0.679	1.934	890	832	
836	1.1869	1.1871	1.1947	1.2106	1.2275	1.2658	1.2659	1.2668	1.2670	1.2616	1.2613	1.2241	1.3220	1.3157	1.3202	1.2094	1.3182	1.3181	1.3179	1.3178	1.3178	1.3178	1.3177	1.3181	1.3181	1.276	0.049	0.135	-0.638	1.931	890	832	
852	1.1681	1.1680	1.1681	1.1753	1.1855	1.2254	1.2254	1.2204	1.2204	1.2214	1.2213	1.2314	1.3211	1.3126	1.3164	1.2046	1.3129	1.3128	1.3122	1.3123	1.3117	1.3117	1.3116	1.3123	1.3123	1.256	0.059	0.154	-0.188	1.369	890	832	
858	1.1825	1.1824	1.1841	1.1954	1.2014	1.2482	1.2482	1.2476	1.2477	1.2524	1.2526	1.2600	1.3632	1.3563	1.3682	1.2425	1.3564	1.3563	1.3559	1.3560	1.3553	1.3553	1.3553	1.3560	1.3560	1.290	0.069	0.181	-0.258	1.457	890	832	
888	1.1057	1.0503	1.0321	1.0125	0.9699	1.0276	1.0272	1.0201	1.0195	0.9867	0.9862	0.9510	1.0704	1.0752	1.0702	0.9673	1.0704	1.0704	1.0702	1.0701	1.0701	1.0701	1.0701	1.0704	1.0704	1.037	0.043	0.151	-0.151	3.063	890	832	
890	1.1795	1.1793	1.1798	1.1897	1.1937	1.2412	1.2412	1.2402	1.2402	1.2441	1.2442	1.2625	1.3625	1.3547	1.3576	1.2325	1.3540	1.3539	1.3535	1.3536	1.3529	1.3529	1.3538	1.3536	1.3536	1.285	0.070	0.178	-0.196	1.378	890	858	
892	1.1500	1.0496	1.0299	1.0099	0.9687	1.0263	1.0260	1.0188	1.0182	0.9859	0.9858	0.9510	1.0704	1.0754	1.0702	0.9673	1.0686	1.0686	1.0683	1.0683	1.0683	1.0683	1.0686	1.0686	1.0686	1.035	0.042	0.139	-0.978	2.792	890	858	
894	1.1759	1.1757	1.1747	1.1829	1.1897	1.2329	1.2329	1.2313	1.2314	1.2342	1.2343	1.2509	1.3401	1.3331	1.3342	1.2208	1.3501	1.3504	1.3506	1.3499	1.3500	1.3499	1.3500	1.3506	1.3506	1.278	0.072	0.180	-0.141	1.316	890	842	
896	1.1759	1.1755	1.1745	1.1826	1.1952	1.2325	1.2325	1.2309	1.2309	1.2337	1.2338	1.2502	1.3393	1.3325	1.3462	1.2208	1.3506	1.3507	1.3508	1.3499	1.3499	1.3499	1.3504	1.3504	1.3504	1.278	0.071	0.176	-0.140	1.313	890	842	
898	1.1751	1.1748	1.1743	1.1811	1.1934	1.2306	1.2306	1.2289	1.2290	1.2315	1.2316	1.2435	1.3365	1.3296	1.3472	1.2174	1.3515	1.3511	1.3502	1.3499	1.3497	1.3498	1.3498	1.3499	1.3499	1.275	0.072	0.178	-0.128	1.304	890	842	
900	1.1747	1.1747	1.1743	1.1811	1.1934	1.2306	1.2306	1.2287	1.2288	1.2310	1.2314	1.2435	1.3365	1.3296	1.3472	1.2174	1.3515	1.3511	1.3502	1.3499	1.3497	1.3498	1.3498	1.3499	1.3499	1.275	0.072	0.178	-0.128	1.306	890	842	
902	1.1737	1.1737	1.1715	1.1786	1.1904	1.2275	1.2274	1.2257	1.2257	1.2270	1.2270	1.2435	1.3316	1.3248	1.3371	1.2150	1.3423	1.3425	1.3454	1.3419	1.3402	1.3406	1.3406	1.3418	1.3419	1.272	0.071	0.177	-0.102	1.293	890	840	
904	1.1737	1.1734	1.1713	1.1783	1.1900	1.2271	1.2271	1.2252	1.2252	1.2272	1.2273	1.2425	1.3311	1.3243	1.3368	1.2155	1.3423	1.3422	1.3451	1.3413	1.3401	1.3409	1.3402	1.3413	1.3413	1.272	0.071	0.179	-0.112	1.292	890	840	
906	1.1735	1.1731	1.1709	1.1777	1.1894	1.2264	1.2264	1.2245	1.2245	1.2263	1.2265	1.2415	1.3300	1.3233	1.3354	1.2115	1.3407	1.3406	1.3435	1.3402	1.3407	1.3407	1.3407	1.3402	1.3402	1.271	0.070	0.178	-0.111	1.290	890	840	
908	1.1731	1.1727	1.1703	1.1769	1.1883	1.2253	1.2253	1.2233	1.2233	1.2250	1.2251	1.2409	1.3282	1.3215	1.3338	1.2100	1.3386	1.3382	1.3383	1.3411	1.3378	1.3377	1.3377	1.3377	1.3377	1.270	0.070	0.177	-0.111	1.288	890	840	
910	1.1728	1.1724	1.1698	1.1763	1.1876	1.2246	1.2245	1.2225	1.2225	1.2241	1.2242	1.2388	1.3271	1.3203	1.3318	1.2089	1.3378	1.3380	1.3390	1.3402	1.3396	1.3396	1.3396	1.3395	1.3395	1.268	0.070	0.182	-0.103	1.289	890	840	

Tabela 4.9 – Quadro do conjunto de Característica Valor Médio resultantes das simulações que modelam chaveamento de banco de capacitor.

Valor Médio																												Métricas Estatísticas					
802	806	808	812	814	850	816	824	828	830	854	852	832	888	858	890	834	842	860	844	836	862	840	846	848	Média	Desv	Pad.	Ampl.	Assim.	Curtores	Min	Max	
802	0.00377	0.00377	0.00410	0.00404	0.00400	0.00357	0.00357	0.00353	0.00353	0.00346	0.00346	0.00333	0.00333	0.00365	0.00354	0.00364	0.00318	0.00363	0.00363	0.00363	0.00363	0.00363	0.00362	0.00362	0.00362	0.003	0.003	0.008	-2.329	6.443	814	890	
806	0.00377	0.00377	0.00411	0.00405	0.00400	0.00357	0.00356	0.00353	0.00353	0.00346	0.00346	0.00333	0.00333	0.00364	0.00354	0.00364	0.00318	0.00362	0.00362	0.00362	0.00362	0.00362	0.00362	0.00362	0.00362	0.003	0.003	0.008	-2.329	6.443	814	890	
808	0.00419	0.00419	0.00430	0.00425	0.00417	0.00430	0.00429	0.00426	0.00425	0.00422	0.00422	0.00323	0.00323	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00350	0.00350	0.000	0.004	0.008	-0.240	1.060	828	890		
812	0.00419	0.00420	0.00430	0.00425	0.00420	0.00430	0.00429	0.00426	0.00425	0.00422	0.00422	0.00323	0.00323	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00351	0.00350	0.00350	0.000	0.004	0.008	-0.240	1.060	828	890		
814	0.00418	0.00419	0.00428	0.00424	0.00420	0.00429	0.00428	0.00425	0.00424	0.00421	0.00421	0.00312	0.00312	0.00340	0.00340	0.00340	0.00294	0.00340	0.00340	0.00340	0.00340	0.00340	0.00340	0.00339	0.00339	0.001	0.004	0.008	0.078	1.009	812	890	
850	0.00423	0.00424	0.00434	0.00428	0.00423	0.00434	0.00433	0.00430	0.00429	0.00426	0.00426	0.00461	0.00461	0.00310	0.00297	0.00308	0.00268	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	-0.001	0.004	0.008	-0.082	1.012	812	890
816	0.00423	0.00424	0.00434	0.00428	0.00423	0.00434	0.00433	0.00430	0.00429	0.00426	0.00426	0.00461	0.00461	0.00310	0.00297	0.00308	0.00268	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	-0.001	0.004	0.008	-0.082	1.012	812	890
824	0.00422	0.00422	0.00431	0.00425	0.00420	0.00429	0.00428	0.00425	0.00424	0.00421	0.00421	0.00312	0.00312	0.00340	0.00340	0.00340	0.00294	0.00340	0.00340	0.00340	0.00340	0.00340	0.00340	0.00340	0.00339	0.00339	-0.001	0.004	0.008	0.077	1.010	812	890
828	0.00422	0.00422	0.00431	0.00425	0.00420	0.00429	0.00428	0.00425	0.00424	0.00421	0.00421	0.00312	0.00312	0.00340	0.00340	0.00340	0.00294	0.00340	0.00340	0.00340	0.00340	0.00340	0.00340	0.00340	0.00339	0.00339	-0.001	0.004	0.008	0.077	1.010	812	890
830	0.00420	0.00420	0.00428	0.00423	0.00418	0.00428	0.00427	0.00424	0.00423	0.00420	0.00420	0.00310	0.00310	0.00338	0.00338	0.00338	0.00292	0.00338	0.00338	0.00338	0.00338	0.00338	0.00338	0.00338	0.00337	0.00337	-0.001	0.004	0.007	0.076	1.011	852	890
854	0.00420	0.00420	0.00428	0.00423	0.00418	0.00428	0.00427	0.00424	0.00423	0.00420	0.00420	0.00310	0.00310	0.00338	0.00338	0.00338	0.00292	0.00338	0.00338	0.00338	0.00338	0.00338	0.00338	0.00338	0.00337	0.00337	-0.001	0.004	0.007	0.076	1.011	852	890
852	0.00416	0.00417	0.00425	0.00420	0.00415	0.00425	0.00424	0.00421	0.00420	0.00417	0.00417	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
858	0.00425	0.00426	0.00436	0.00430	0.00425	0.00436	0.00435	0.00432	0.00431	0.00428	0.00428	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
888	0.00335	0.00334	0.00356	0.00352	0.00348	0.00356	0.00355	0.00352	0.00351	0.00348	0.00348	0.00290	0.00290	0.00321	0.00321	0.00321	0.00270	0.00321	0.00321	0.00321	0.00321	0.00321	0.00321	0.00321	0.00320	0.00320	0.002	0.002	0.007	-2.052	6.048	802	890
858	0.00425	0.00425	0.00436	0.00430	0.00425	0.00436	0.00435	0.00432	0.00431	0.00428	0.00428	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
890	0.00334	0.00334	0.00356	0.00352	0.00348	0.00356	0.00355	0.00352	0.00351	0.00348	0.00348	0.00290	0.00290	0.00321	0.00321	0.00321	0.00270	0.00321	0.00321	0.00321	0.00321	0.00321	0.00321	0.00321	0.00320	0.00320	0.002	0.002	0.007	-2.054	6.056	808	890
834	0.00424	0.00425	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
842	0.00424	0.00425	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
840	0.00424	0.00424	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
844	0.00424	0.00424	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
836	0.00424	0.00424	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
862	0.00424	0.00424	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
840	0.00424	0.00424	0.00435	0.00429	0.00424	0.00435	0.00434	0.00431	0.00430	0.00427	0.00427	0.00309	0.00309	0.00337	0.00337	0.00337	0.00290	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00337	0.00336	0.00336	-0.001	0.004	0.007	0.076	1.011	852	890
846	0.00423	0.00424	0.00434	0.00428	0.00423	0.00434	0.00433	0.00430	0.00429	0.00426	0.00426	0.00461	0.00461	0.00310	0.00297	0.00308	0.00268	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	-0.001	0.004	0.008	0.078	1.009	812	890
848	0.00423	0.00424	0.00434	0.00428	0.00423	0.00434	0.00433	0.00430	0.00429	0.00426	0.00426	0.00461	0.00461	0.00310	0.00297	0.00308	0.00268	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	-0.001	0.004	0.008	0.078	1.009	812	890
848	0.00423	0.00424	0.00434	0.00428	0.00423	0.00434	0.00433	0.00430	0.00429	0.00426	0.00426	0.00461	0.00461	0.00310	0.00297	0.00308	0.00268	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	0.00306	-0.001	0.004	0.008	0.078	1.009	812	890

Fonte: Autoria própria

A partir das tonalidades evidenciadas em cada linha é possível averiguar como o nó de origem do distúrbio interfere na propagação do evento ocasionado pelo chaveamento de um banco de capacitor. Por meio das Tabela 4.6 e Tabela 4.7, destaca-se que as características RMS e Valor de Pico exprimem uma tonalidade de cor equivalente. Assim, em termos de distribuição dos valores destas características, pode-se evidenciar que o distúrbio é sentindo com mais intensidade nas barras localizadas à jusante do ponto de origem do evento. Quando o distúrbio está situado próximo da subestação a distribuição é mais branda, sendo que o distúrbio é evidenciado próxima à média (coloração amarela) nas barras próximas à origem.

Em contrapartida, este comportamento é alterado em eventos localizados distante da subestação. Para este cenário, a matriz de cor destaca uma predominância na cor verde na posição inferior esquerda (distante da origem), sendo, portanto, evidenciado de forma mais severas nas barras próximas à origem. Por conseguinte, para estes casos o local de aplicação do evento de comutação evidenciou o distúrbio com mais intensidade.

A Tabela 4.8 exprime a distribuição em termos das características Fator de Pico. Esta característica é útil para quantificar a presença do maior pico do sinal medido, em relação ao valor RMS. Com base na matriz de cor para esta característica destaca-se que o maior valor de pico em cada simulação é calculado nas barras em torno do nó de origem do distúrbio. Entretanto, nas simulações envolvendo as barras 802 e 806, a propagação do distúrbio em relação a característica Fator de Pico é diferente, sendo que o menor valor é evidenciado nos nós de origem. Assim, o transformador da subestação torna este ponto mais robusto.

Por fim, a característica Valor Médio, quantifica a intensidade do transitório oscilatório. Nota-se que esta característica é quase sempre próxima de zero, sendo assim o transitório evidenciado é brando. Pelo quadro de cor, ressalta-se uma tonalidade de verde em torno da diagonal principal, definindo que nos pontos próximos da origem do distúrbio a intensidade do transitório oscilatório é um pouco maior, quando comparada com os distúrbios evidenciados nos demais nós.

Fundamentados nos dados das simulações é possível calcular os valores de média, desvio padrão, amplitude, assimetria e curtoses, de modo a resumir as informações de tendência, dispersão e do conjunto de dados resultantes da simulação. Assim, fica mais fácil entender o comportamento do sistema na presença de um evento de elevação de tensão.

Diante dessa realidade, a Figura 4.25, Figura 4.26 e Figura 4.27 representam os valores calculados destas métricas por meio de um gráfico de linhas. Tais gráficos permitem que se tenha uma visão global da tendência, distribuição e dispersão do conjunto de características obtidas em cada simulação (linhas).

Figura 4.25- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica RMS, extraídas das simulações que modelam chaveamento de banco de capacitor.

Fonte: Autoria própria.

Figura 4.26- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Fator de Pico, extraídas das simulações que modelam chaveamento de banco de capacitor

Fonte: Autoria própria.

Figura 4.27- Métricas Estatísticas Média(a), Desvio Padrão(b), Amplitude(c), Assimetria(d) e Curtoses(e) calculadas para o conjunto de característica Valor Médio, extraídas das simulações que modelam chaveamento de banco de capacitor

Fonte: Autoria própria.

De acordo com a Figura 4.25, nota-se que os eventos originados na primeira barra do sistema apresentam uma baixa dispersão; logo, os valores que formam o conjunto de características resultantes destas simulações são próximos do valor da média, destacando um padrão de propagação semelhante em todas as barras. Por

sua vez, quando o evento é destacado distante da subestação origina uma maior variação amostral dos valores.

Com relação à assimetria destaca-se que todas as simulações retornam um valor de assimetria negativa, representando uma maior quantidade de valores abaixo da média. Importante destacar que os eventos localizados longe da subestação apresentam uma distribuição, em relação à obliquidade, próxima de uma distribuição assimétrica, sendo que para eventos ocasionados longe da subestação a disseminação é mais semelhante a uma distribuição simétrica.

Pelo gráfico que representa a distribuição do Fator de Pico, nota-se que os valores das métricas média, desvio padrão e amplitude são pequenos e possuem pouca variação, independentemente do local de origem do distúrbio. Ilustrando que o distúrbio de elevação de tensão é propagado com valor desta característica bem semelhante em todos os pontos do sistema. Tal fato fica mais evidente quando se observa os valores encontrados pelas métricas assimetria e curtoses. Um alto valor de curtoses e assimetria destaca que todos os dados apresentam valores próximos à média; logo, a distribuição apresenta uma grande concentração. Neste sentido, qualquer pequena variação em um elemento deste conjunto altera drasticamente o valor desta característica.

As métricas para o valor médio exprimem uma mudança abrupta em termos da distribuição dos valores das características de acordo com o local de origem. Quando o local está próximo à subestação, as métricas determinam que o vetor de dados possua um alto desvio padrão e uma dispersão próxima da distribuição normal. Por conseguinte, ao se distanciar da subestação, os gráficos denotam uma distribuição com baixa variância em torno da média e uma assimetria positiva.

4.3 Conclusões sobre o Estudo Referente à Distribuição dos Valores de Características

A partir do estudo envolvendo as simulações que modelam o evento de curto-circuito e comutação de banco de capacitores no sistema de distribuição IEEE 34-nós, foi possível determinar como os parâmetros variáveis de cada simulação afetam na caracterização do distúrbio propagado no sistema. Assim, é possível obter tendências globais sobre o comportamento dos sinais.

Destaca-se que o local de origem do distúrbio em relação à subestação como corresponde ao fator que mais influencia a distribuição do evento ao longo do sistema.

De fato, a variância amostral dos valores de características extraídas do distúrbio evidenciado em cada barra do sistema diminui à medida que a origem do evento se aproxima da subestação.

Com relação aos distúrbios ocasionados por curto-circuito, fica claro que quando o evento é originado próximo à subestação, o distúrbio é caracterizado em todas as barras com características RMS e Valor de Pico semelhantes, sendo o distúrbio propagado de forma mais intensa em direção à subestação. Neste caso, as distribuições dos valores para estas características apresentam um menor desvio padrão, uma assimetria negativa e uma curtose platicúrtica. De modo contrário, eventos modelados em uma posição distante apresentam maior dispersão em termos dos valores, sendo mais fácil caracterizar o local de origem.

Para as características RMS e Valor de Pico, tais tendências se mantêm estáveis, independentemente da mudança dos outros parâmetros da simulação como: ângulo de fase, resistência da falta e o tipo de curto-circuito. Tal fato não é observado em relação às características Fator de Pico e Valor Médio, onde a dispersão e distribuição destas características são influenciadas tanto pelo local de origem, como também pela intensidade do curto-circuito e o valor do ângulo de incidência.

Em relação à intensidade do curto-circuito, observou-se que quanto menor o valor de resistência, maior a intensidade do distúrbio evidenciado em cada barra; entretanto, um maior valor de resistência configura que o distúrbio será propagado com características semelhantes. Assim, a resistência interfere na intensidade e na dispersão do afundamento no sistema de distribuição.

Com relação ao distúrbio originado a partir do chaveamento de banco de capacitores, destaca-se que o padrão de propagação do distúrbio é semelhante, em termos das características Valor de Pico e RMS. Assim, o distúrbio é propagado com maior intensidade sempre em direção às barras localizadas à jusante da origem do evento. Entretanto, nota-se por meio das métricas estatísticas que as variâncias amostrais destes dados são diferentes, onde um distúrbio próximo à subestação é disseminado com características semelhantes, apresentando um menor desvio padrão e amplitude.

As características Fator de Pico e Valor Médio obtidas pelo evento ocasionado do chaveamento de banco de capacitores apresentam valores próximos, sofrendo-se uma baixa variação. Tal fato pode dificultar a aplicação do método, visto que ele

pretende analisar a variância dos valores observados próximos ao local de origem do distúrbio, confrontando com os valores extraídos nas barras distantes da origem.

De qualquer modo, convém observar que apesar desta baixa discrepância encontrada para este caso, nos cenários que foram avaliados a dispersão dos valores das características RMS, Valor de Pico, Fator de Pico e Valor Médio, demonstram que os distúrbios detectados próximo ao local de origem apresentam valores semelhantes.

A busca e conclusões desse estudo são possíveis derivar heurísticas importantes que são utilizadas no desenvolvimento da metodologia. Dentre as quais destacam:

- As barras que estão próximas da subestação são menos susceptíveis aos distúrbios. E por esse motivo, o distúrbio presente na subestação apresenta um grau de severidade menor quando comparado com o restante do sistema.
- Quanto menor é a resistência de curto-circuito, mais distinto será o distúrbio caracterizado em cada barra do sistema.
- O distúrbio é sentido com maior intensidade nas barras localizadas à montante do local da fonte causadora de afundamento de tensão.
- Quando a fonte causadora do distúrbio está localizada em uma barra próxima à subestação, o distúrbio é então sentido com características semelhantes em todas as barras do sistema.
- Quando a fonte causadora do distúrbio está localizada nas extremidades do sistema, o distúrbio será sentido com uma maior intensidade no local que este se originou.

Nessa perspectiva, as análises combinadas de todos os valores de características podem ser aplicadas para inferir sobre o padrão de propagação dos distúrbios. Por sua vez, as características RMS ou Valor de Pico conseguem generalizar várias situações, visto que elas sofrem interferência apenas do local de aplicação do evento de curto-circuito ou comutação de banco de capacitores.

Por fim, destaca-se que como as características RMS e Valor de Pico contribuem de igual forma para evidenciar a propagação do distúrbio, a característica Valor de Pico não será então considerada para o desenvolvimento do método.

4.4 Considerações Finais do Capítulo

A partir do estudo comentado no decorrer do capítulo, o padrão de propagação do distúrbio pode ser descrito, de acordo com a distribuição, dispersão e tendências dos valores de características calculados em cada barra em que o distúrbio é detectado.

De forma a melhor visualizar essa disseminação, o conjunto de características resultante de cada simulação são confrontadas, a partir de gráficos de matriz de cores e gráficos de linhas. Partindo destes gráficos, fez-se possível visualizar a relevância de cada característica para a tarefa de localização da origem do distúrbio de VTCD. Adicionalmente, foi possível também estabelecer uma relação entre a natureza da fonte que originou o distúrbio e o padrão de propagação.

O conhecimento que foi destacado corrobora para evidenciar que é possível descrever, em termos das características RMS, Valor de Pico, Fator de Pico e Valor Médio, a disseminação do distúrbio de VTCD no sistema de distribuição, ressaltando seu local de origem.

A partir disso, pode-se propor uma metodologia compacta que será encarregada de analisar mutualmente os conjuntos das características obtidas no instante de tempo que um distúrbio de VTCD é evidenciado no sistema de distribuição, para fim de inferir o local de origem do distúrbio.

Entretanto, antes de descrever o método, faz-se necessário averiguar se é possível embarcar em hardware um método responsável por detectar e extrair característica do distúrbio de VTCD. Assim sendo, o Capítulo 5 explana detalhes a respeito do hardware desenvolvido que implementa o método de detecção e extração de característica do sinal de tensão.

5 Hardware Desenvolvido

Como foi explanado no Capítulo 4 o método de localização das fontes causadoras de VTCDs proposto na tese pretende inferir sobre o local de origem do distúrbio, a partir das características extraídas dos distúrbios evidenciados no sistema de distribuição e que são fornecidas pelos medidores.

Neste caso, para garantir a viabilidade do método de localização é necessária à utilização de um medidor/*smart meter* capaz de realizar o processamento local do sinal de tensão, para fim de detectar o distúrbio de VTCD. Adicionalmente, ele também deve ser capaz de fornecer em um canal de comunicação as características extraídas dos distúrbios detectados, as quais são utilizadas como entrada do algoritmo de localização do distúrbio de VTCDs.

Dada a relevância da utilização do medidor com tais características, surgiu a necessidade de desenvolver uma plataforma de medição responsável por mensurar os distúrbios de VTCDs. Assim, por conseguinte, deve ser analisado em hardware o desenvolvimento de um método responsável por detectar e classificar os distúrbios de VTCDs evidenciados no sinal de tensão, fornecendo por meio de um canal de comunicação as características RMS, Valor de Pico, Fator de Pico e Valor Médio do distúrbio detectado.

É necessário sublinhar que o método empregado para detecção e classificação do distúrbio tem como característica o baixo custo computacional, de modo que o algoritmo possa ser implementado em um microcontrolador.

Nessa perspectiva, este projeto de hardware corresponde a uma das contribuições desta tese, sendo que todos os cuidados foram tomados de modo a implementar um hardware que possa ser reutilizável em outros trabalhos como, por exemplo, na detecção de harmônicos no sinal de tensão.

Diante de tal situação, o medidor foi desenvolvido a partir de um Sistema Operacional de Tempo Real (*Real-Time Operating System* - RTOS) [55]. A utilização de RTOS garante o gerenciamento das operações a serem realizadas pelo

microcontrolador, ao passo que torne mais fácil a prototipagem de várias funcionalidades. No trabalho, o RTOS irá auxiliar no escalonamento das seguintes tarefas: amostragem dos dados de tensão, cálculos realizados pelos métodos de detecção e classificação de distúrbios e envio de dados pelo canal de comunicação.

O desenvolvimento desta arquitetura corresponde a uma etapa importante da pesquisa, pois o bom funcionamento do medidor irá determinar a precisão do método de localização. Em primeira instância, serão apresentadas, na Seção 5.1, as características do hardware, seguido dos testes de aquisição que comprovam a eficácia dos sensores que são utilizados para capturar os distúrbios de VTCDs. Logo após, a Seção 5.2, descreve em detalhes como ocorre a implementação do algoritmo por meio de um RTOS, destacando-se também as suas vantagens. A Seção 5.3 apresenta os passos do algoritmo de detecção e classificação que foi embarcado no microcontrolador. Por fim, a Seção 5.4 apresenta as considerações do capítulo.

5.1 Aspectos do Hardware

A plataforma de hardware desenvolvida e que será utilizada para embarcar o método de detecção e classificação pode ser visualizada na Figura 5.1.

Figura 5.1 – Hardware para detecção e classificação dos distúrbios de VTCDs.

Fonte: Autoria própria

Como observa-se pela Figura 5.1, para idealização do hardware de aquisição do sinal de tensão, optou-se por empregar sensores de efeito *Hall*. Um sensor de

efeito Hall é um transdutor que, sob a aplicação de um campo magnético, responde com uma variação em sua tensão de saída. Estes sensores são capazes de capturar os sinais de tensão e corrente, podendo ser empregados para a utilização em medidores eletrônicos [56]. Para isto são empregados sensores de efeito Hall modelo LV20-P (LEM *componentes*®).

Os sinais de tensões medidos por esses sensores são conectados na entrada dos conversores analógicos-digitais do microcontrolador utilizado no projeto, modelo TM4C1294NCPDT, responsável por implementar as rotinas de detecção e classificação dos distúrbios de VTCDs. Entretanto, a tensão de saída desses sensores não é adequada para utilizar como entrada dos conversores analógicos-digitais do microcontrolador, visto que elas aceitam níveis de entrada entre 0 a 3,3 V.

Sendo assim, os sinais provenientes destes sensores foram então condicionados para que suas amplitudes estejam adequadas às entradas dos conversores analógico-digitais. Para realizar este condicionamento de sinal, foi empregado o circuito de aquisição desenvolvido em [57] que adequa o sinal de saída do sensor *hall* modelo LV20-P para uma tensão de 3,3 V com o uso de amplificadores operacionais.

Destaca-se que microcontrolador utilizado TM4C1294NCPDT está conectado a uma placa de baixo custo desenvolvida pela *Texas Instruments* (modelo EK-TM4C1294XL). Ele apresenta uma frequência de processamento de 120 MHz alinhado a um baixo custo de aquisição (20 dólares). Além de fornecer uma interface de comunicação Ethernet que será utilizada para o envio do conjunto de características extraídas do distúrbio.

Adicionalmente, no hardware desenvolvido são conectados dois módulos que são utilizados pelo método. O primeiro corresponde a um módulo de cartão SD e é responsável por armazenar os sinais que foram detectados e classificados. Por sua vez o segundo módulo corresponde a um relógio de tempo e pode ser utilizado para fornecer informações sobre o tempo de ocorrência do distúrbio.

Após a construção do hardware foram realizados vários testes para garantir que a aquisição do sinal possua uma boa resolução das formas de onda dos distúrbios de VTCDs. Para isso, foi necessário montar um banco de dados com diversos sinais que representam as VTCDs, onde cada sinal é configurado com diferentes amplitudes e durações. Estes distúrbios foram obtidos por meio de equações paramétricas apresentadas em [23]. Visando obter sinais que apresentem características

condizentes com distúrbios de QEE reais, estas equações seguirão as definições do IEEE Std 1159TM-2009 [2]. A Tabela 5.1 apresenta as equações para Afundamentos, Elevações e Interrupções.

Tabela 5.1- Equações sintéticas que modelam os distúrbios de VTCDs.

Distúrbio	Equação	Parâmetros
Afundamento	$v(t) = \{1 - v_n([u(t - T_i) - u(t - T_f)])\} \text{sen}(2\pi f * t + \varphi)$	$0.1 \leq v_n \leq 0.9$ $T \leq T_f - T_i \leq 9T$ $0 \leq \varphi \leq 2\pi$
Elevação	$v(t) = \{1 + v_n([u(t - T_i) - u(t - T_f)])\} \text{sen}(2\pi f * t + \varphi)$	$0.1 \leq v_n \leq 0.9$ $T \leq T_f - T_i \leq 9T$ $0 \leq \varphi \leq 2\pi$
Interrupção	$v(t) = \{1 - v_n([u(t - T_i) - u(t - T_f)])\} \text{sen}(2\pi f * t + \varphi)$	$0 \leq v_n \leq 0.1$ $T \leq T_f - T_i \leq 9T$ $0 \leq \varphi \leq 2\pi$

Fonte: Autoria própria.

De acordo com as equações apresentadas na Tabela 5.1, para modelagem de um evento de VTCDs (Afundamento, Elevação e Interrupção), é necessário adicionar ao sinal senoidal puro, representado pela função $\text{sen}(2\pi f * t + \varphi)$ (f é a frequência fundamental e φ é o ângulo de fase) uma componente que altere a amplitude da onda no intervalo de tempo de duração do distúrbio representado por $T_f - T_i$. O parâmetro T_f corresponde ao tempo final e o parâmetro T_i corresponde ao tempo inicial. Para isto, utiliza-se uma função degrau (u) que retorna o valor 1 durante o período de tempo que o distúrbio ocorre, ou o valor 0, caso contrário. A saída da função degrau será multiplicada pelo parâmetro v_n que corresponde à amplitude do distúrbio a ser inserido.

A partir destas equações, 100 estudos de caso de cada distúrbio de VTCDs foram gerados com uma frequência fundamental de 60 Hz e com uma duração de 10 ciclos. Como ainda não foi estabelecida a taxa de amostragem do hardware, esses distúrbios foram gerados a princípio sobre a taxa de amostragem de 16 amostras/ciclo, 32 amostras/ciclo, 64 amostras/ciclo, 128 amostras/ciclo e 256 amostras/ciclo.

Com base em [58]–[64], o ruído Gaussiano é inserido nos sinais sintéticos para emular tantos os ruídos ocasionados pelos dispositivos de aquisição de dados, como também o ruído eletromagnético causado pelos diferentes tipos de

equipamentos e cargas conectados na rede de distribuição. Assim, para cada uma das 100 formas de ondas relacionadas aos distúrbios de VTCDs, são criados 6 novos sinais, os quais possuem as mesmas características do sinal original, diferenciando-se somente na relação sinal ruído. As taxas utilizadas são 20 dB, 25 dB, 30 dB, 35 dB, 40 dB e 45 dB.

Ao final do processo são construídas 5 tabelas de dados diferentes, cada uma representando, respectivamente, as taxas de amostragem de 16 amostras/ciclo, 32 amostras/ciclo, 64 amostras/ciclo, 128 amostras/ciclo e 256 amostras/ciclo, onde cada tabela é composta de 700 formas de onda. Assim, o banco de dados possui informações dos distúrbios de VTCDs com características, taxa de amostragem e ruído diferentes.

Após a construção do banco de dados foi utilizado o equipamento DOUBLE F6150 *Power System Simulator*, capaz de fornecer um sinal real de saída semelhante a um sinal sintético fornecido como entrada. Deste modo, a fonte foi utilizada para obter uma forma de onda real que possua as mesmas características dos sinais que compõem o banco de dados. A forma de onda real de saída é fornecida como entrada dos sensores Hall e circuito de condicionamento de sinal. O sinal condicionado é capturado pelo conversor A/D do microcontrolador.

A partir de uma interface de comunicação entre o microcontrolador e um computador, alguns testes foram realizados, para fim de garantir a confiabilidade do equipamento de aquisição. É preciso acentuar que não é foco deste trabalho determinar a melhor arquitetura de medição e, portanto, os testes realizados são apenas para certificar que o sinal medido no microcontrolador é condizente com o sinal de entrada fornecido pela Double F6150. Os ensaios foram realizados utilizando uma bancada de testes que pode ser visualizada pela Figura 5.2.

Figura 5.2 – Esquema da bancada que foi utilizado para os testes de aquisição do sinal de entrada.

Fonte: Autoria própria.

Numa primeira etapa de testes, foi dado como entrada um sinal normal, sem a presença de distúrbios, com tensão nominal de 127 V e frequência nominal de 60 Hz. A Figura 5.3 e Figura 5.4 apresentam gráficos que comparam o sinal de entrada (azul) e o sinal armazenado no microcontrolador, após a etapa de conversão analógico-digital (vermelho) sobre diferentes taxas de amostragem e diferentes níveis de ruído.

Figura 5.3– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal normal.

Fonte: Autoria própria.

Figura 5.4– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal com ruído.

Fonte: Autoria própria.

De acordo com as Figura 5.3 e Figura 5.4, nota-se que o sistema conseguiu capturar o sinal de entrada conservando todas as características do evento, independente da taxa de amostragem utilizada.

Nessa perspectiva, a Figura 5.5, Figura 5.6 e Figura 5.7 confrontam, respectivamente, o distúrbio de afundamento, elevação e interrupção após conversão A/D, certificando-se que o desempenho desta arquitetura para aquisição dos distúrbios de VTCDs.

Figura 5.5– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal contendo afundamento de tensão.

Fonte: Autoria própria.

Figura 5.6 – Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal contendo elevação de tensão.

Fonte: Autoria própria.

Figura 5.7– Comparação entre o sinal gerado pela fonte (azul) e o sinal após a etapa de conversão A/D obtido pelo medidor (vermelho tracejado) para um sinal contendo interrupção de tensão.

Fonte: Autoria própria.

De acordo com as Figura 5.5, Figura 5.6 e Figura 5.7 nota-se que os sensores de aquisição e o conversor A/D do microcontrolador conseguem conservar as características de afundamento, elevação e interrupção de tensão. Sendo comprovada a eficácia da arquitetura de aquisição, torna-se então viável implementar a metodologia para detecção e classificação.

5.2 Aspectos da Implementação do Sistema de Monitoramento de VTCDs

Conforme previamente mencionado, toda a metodologia proposta para a detecção e classificação de distúrbios foi embarcada no microcontrolador por meio de um RTOS. O RTOS é um sistema operacional que gerencia os recursos do microcontrolador, com o objetivo de garantir que os eventos sejam atendidos dentro de uma restrição de tempo [55].

A grande vantagem da utilização do RTOS é que um sistema desenvolvido sem a utilização do RTOS será constituído de várias rotinas de tratamento de interrupção, onde o controle de tempo de cada rotina é implementado pelo próprio programador. Assim, dependendo da complexidade do software e também da velocidade da aplicação, o desenvolvimento do sistema torna-se complicado. O RTOS é uma alternativa para facilitar o desenvolvimento e reduzir o tempo de projeto, pois ele possui uma “camada de abstração” que fornece quatro tipos de serviços: Alocação dinâmica de memória; intercomunicação e sincronização de processos; gerenciamento de tempo; gerenciamento de tarefas [65].

A “camada de abstração” é implementada pelo *kernel* do RTOS, que é o software responsável por garantir que todos os eventos sejam executados dentro de suas restrições de tempo, podendo aproveitar melhor recursos de hardware com uma arquitetura de prioridades de tarefas.

Em um RTOS uma tarefa é executada pelo processador até o surgimento de uma tarefa com maior prioridade. As tarefas são executadas de forma independente e se comunicam entre si, sendo esta a principal diferença entre um sistema operacional de tempo real para um sistema operacional de tempo-compartilhado. Os sistemas de tempo-compartilhado permitem que diversos programas sejam executados a partir da divisão de tempo do processador em pequenos intervalos, denominado fatia de tempo. Caso a fatia de tempo não seja suficiente para a conclusão do programa, ele é interrompido pelo sistema operacional (SO) e substituído por outro, enquanto fica aguardando por uma nova fatia de tempo.

Como exemplo, um RTOS pode ser desenvolvido para monitorar o sistema de alarme de uma casa. Para isso são especificadas duas tarefas. A tarefa 1 tem prioridade baixa e é responsável por realizar a leitura dos sensores de presença, indicando se existe ou não a presença de algum intruso; por sua vez, a tarefa 2 tem uma prioridade alta e é responsável pelo acionamento das sirenes.

A Figura 5.8 apresenta como ocorre o escalonamento das tarefas para a execução do programa. O programa inicia na função *main()* que configura todas as variáveis e executa o início do código. Ao inicializar *kernel* executa a função de menor prioridade no caso a tarefa 1. Quando a tarefa 1 detecta a presença de um intruso por meio dos sensores de presença, ela enviará uma mensagem para que a tarefa 2 seja executada. Quando ela é acionada, o *kernel* do SO interrompe a tarefa 1 e começa a executar a tarefa 2 e, ao ser finalizada, o kernel retorna a execução do programa para a tarefa 1, como mostra a Figura 5.8.

Figura 5.8 – Escalonamento das tarefas para a execução do programa implementado utilizando um RTOS.

Fonte: Autoria própria

No trabalho foi utilizado o RTOS fornecido pela *Texas Instruments*, denominado TI-RTOS [66], que possui uma biblioteca de serviços que combina um *kernel* de tempo real com componentes comuns do sistema, como: gerenciamento de memória; driver de dispositivos de entrada e saída; protocolo TCP/IP; sistema FAT; análise em tempo real; programação em *threads*. Tais recursos fazem com que o programador se concentre na programação de tarefas específicas da aplicação, minimizando consideravelmente o tempo de desenvolvimento do projeto. Adicionalmente, o TI-RTOS fornece uma interface padrão para gerenciamento de recursos de hardware, tais como: interrupções, exceções e temporizadores.

O TI-RTOS é um agendador preemptivo de modo que a tarefa de mais alta prioridade sempre é executada em primeiro lugar. Ele possui três tipos de *threads* que são: Interrupções de Hardware (IHW), Interrupções de Software (ISW) e tarefas.

As Interrupções de Hardware têm prioridade mais alta, já as Interrupções de Software são funções desenvolvidas pelo usuário e possuem uma prioridade menor que a IHW. Por sua vez, as tarefas têm uma prioridade menor quando comparada com as IHW e ISW. Outra diferença corresponde ao fato que elas estão sempre ativas

na execução do programa, ao contrário das IHW e ISW que são acionadas por um gatilho.

A importância de utilizar as IHW e ISW é que a primeira pode ser configurada para tratar a interface de entrada e saída, como por exemplo, a leitura de um sensor, por sua vez a ISW fica responsável por processar o dado capturado pela IHW. Como exemplo pode-se explicar que uma IHW executa a leitura de um pino de entrada e aciona por meio de um gatilho uma ISW, responsável por processar o dado capturado na leitura.

Como uma IHW sempre interromperá a execução de ISW, se durante o processamento deste dado for então preciso realizar uma leitura, o *kernel* irá parar a execução da ISW, para executar a IHW. Quando esta for finalizada, o *kernel* retornará à execução do programa para a ISW anterior. Caso esse escalonamento de procedimento fosse realizado na rotina de interrupção, a próxima leitura do dado só seria possível após o término da execução de todo processamento.

Tanto a IHW e ISW possuem uma pilha de execução. Assim, quando um evento IHW ou ISW é disparado, ele é então inserido na pilha e só é executado de acordo com sua ordem de execução ou de prioridade. Neste contexto, uma IHW pode chamar várias vezes uma ISW, só que a ISW irá ser executada de acordo com a posição na pilha ou ordem de prioridade.

A Figura 5.9 mostra a execução de um programa que possui uma tarefa principal que roda em *background*, duas IHW e três ISW com ordem de prioridade definidas. De acordo com a Figura 5.9, a tarefa *idle* está presente durante toda a execução do programa e, durante um determinado tempo, IHW1 é disparada e logo em seguida ela aciona a ISW2; no entanto, a ISW2 só é executada após a IHW1 terminar. No meio da execução de ISW2, IHW2 é acionada; assim, ISW2 é interrompida e IHW2 começa a ser executada. Por sua vez, IHW2 aciona ISW3 que por ter uma prioridade maior que ISW2, ela é executada primeiro. Por fim, ISW3 aciona ISW1; no entanto, ISW1 só vai ser executada após ISW2 e ISW3 ser finalizada.

Figura 5.9 – Escalonamento das threads utilizadas pelo TI-RTOS.

Fonte: Autoria própria

De maneira análoga ao exemplo da Figura 5.9, foi possível desenvolver a partir do TI-RTOS um sistema de monitoramento, que funciona por meio de duas etapas concomitantes. A primeira é executada por meio de uma IHW executada periodicamente, sendo responsável por medir o sinal de entrada e disparar uma ISW. Tal ISW é encarregada de determinar a presença ou não do distúrbio, a partir da análise do sinal medido periodicamente, uma vez que o distúrbio é detectado uma tarefa é então acionada para classificar o sinal detectado.

Assim, a segunda etapa consiste por executar uma tarefa que identifica qual distúrbio estará presente no sinal detectado e, por fim, outra tarefa tem a função de disponibilizar as informações do distúrbio em um canal de comunicação.

O algoritmo de detecção e classificação embarcado no microcontrolador foi proposto no trabalho [67]. Esse trabalho apresenta uma abordagem compacta e eficaz para a detecção e classificação dos distúrbios de qualidade de energia, a partir da análise das características extraídas de uma janela do sinal de tamanho igual a um ciclo e que se desloca com passo de um ponto. O custo computacional do algoritmo depende exclusivamente da quantidade de pontos presentes em uma janela amostrada (1 ciclo).

A seguir são apresentados detalhes de como o algoritmo foi embarcado no microcontrolador a partir da utilização de um TI-RTOS. Destaca-se que a análise apresentada é realizada em uma fase do sinal.

5.3 Algoritmo Embarcado

O hardware deve executar as tarefas de detecção e classificação dentro de um limite de tempo de modo que cada ponto medido pelo conversor A/D seja analisado, por isto, o TI-RTOS deve garantir que todas as funcionalidades sejam executadas dentro de um limite de tempo. Neste contexto, a tarefa mais importante corresponde em armazenar o sinal medido na memória do microcontrolador, para em seguida executar o algoritmo. Deste modo, a execução das tarefas de detecção e classificação não pode interromper a aquisição e armazenamento de um ponto do sinal de tensão.

A Figura 5.10 apresenta em forma de diagrama a estrutura de execução do algoritmo embarcado.

Figura 5.10 – Diagrama esquemático dos passos do algoritmo embarcado.

Fonte: Autoria própria

Conforme ilustrado na Figura 5.10, o sinal de tensão é adquirido por sensores de efeito Hall, e sua saída é condicionada por amplificadores operacionais de modo a fornecer uma tensão de trabalho para o conversor A/D do microcontrolador.

Após a digitalização dos sinais, estes são armazenados (ponto a ponto) em um buffer. Por meio do TI-RTOS é possível implementar um buffer dinâmico que armazena no final da lista um novo ponto medido do sinal de tensão.

O segmento do buffer que representa uma janela de tamanho igual a um ciclo do sinal de tensão é lido pelo bloco que implementa o método de detecção do distúrbio.

O algoritmo de detecção embarcado no hardware compara o grau de dissimilaridade entre a característica RMS ou Distorção Harmônica Total (DHT) de entrada com a característica RMS ou DHT que representa uma janela normal (sem distúrbio), por meio da distância euclidiana entre a característica de entrada e um parâmetro de referência estabelecido com base na média dos valores de RMS e DHT calculados para janelas sem distúrbios.

Quanto mais próximo for o valor da característica de entrada em relação a um parâmetro de uma janela normal, maior será o grau de semelhança; caso contrário, a janela terá maiores chances de apresentar um distúrbio. Na sequência, torna-se possível induzir para cada bloco uma regra de detecção, do tipo “Se $Dist_i \geq limiar$ Então distúrbio detectado” que irá verificar se a distância euclidiana calculada ultrapassa ou não um determinado limiar.

Cada bloco retorna uma saída binária que é utilizada como entrada para um operador lógico do tipo OR. Assim, é criada uma operação de disjunção que resulta em uma saída binária, onde 1 representa a ocorrência da perturbação e 0 a não ocorrência.

O método de detecção é executado periodicamente. Ao final de cada execução o TI-RTOS implementa uma função responsável por eliminar o primeiro ponto do buffer de armazenamento, deslocando assim a janela do sinal com passo de um ponto.

Uma vez que o distúrbio é detectado na janela é então habilitado uma *flag* que cria um novo buffer responsável por armazenar todos os pontos que caracterizam o distúrbio identificado e que serão utilizados pelo método de classificação. Neste contexto, a tarefa de classificação é simplificada, uma vez que a análise será feita apenas nos pontos que caracterizam a perturbação.

Para cada perturbação detectada durante o tempo de funcionamento, um novo buffer é alocado dinamicamente e, por meio do TI-RTOS, estes distúrbios podem ser analisados em *background* toda vez que o microcontrolador estiver ocioso. Dessa forma, a tarefa de classificação tem uma prioridade baixa e será interrompida pelas demais tarefas do sistema. Destaca-se que este buffer é alocado no cartão de memória, economizando assim a memória utilizada pelo algoritmo.

O classificador utilizado foi baseado na árvore de decisão de tipo C4.5 e recebe como entrada as características extraídas do distúrbio armazenado no buffer. Também deve ser observado que este classificador pode ser facilmente embarcado, uma vez que pode ser representado por um conjunto de regras de decisão do tipo “se...então”.

Conforme discutido anteriormente, o método de detecção e classificação de distúrbios desenvolvidos garante um baixo custo computacional. Por esta razão, a maioria das variáveis de entrada é obtida no domínio do tempo e apenas as componentes harmônicas são calculadas usando a Transformada Rápida de *Fourier* (*Fast Fourier Transform* - FFT). Observa-se que ela foi escolhida por causa do baixo custo computacional da ferramenta e porque é usada rotineiramente em aplicações que envolvem hardware.

Assim, após a detecção e classificação da perturbação, as informações são disponibilizadas num canal de comunicação Ethernet que também está integrado no kit de desenvolvimento. É importante ressaltar que toda a arquitetura do protocolo TCP/IP já está implementada no kernel TI-RTOS, meramente exigindo a definição da estrutura de transporte, que, neste caso, corresponde à ocorrência e classe de uma perturbação em cada janela analisada. Assim, os dados podem ser obtidos em um Centro de Controle de Operações, onde os engenheiros de qualidade de energia podem ter feedback imediato sobre os eventos que ocorrem nas instalações do consumidor, o que permite a execução de tarefas corretivas.

5.3.1 Algoritmo de Detecção

A implementação do algoritmo de detecção foi idealizada da seguinte forma: a aquisição de um ponto do sinal será feita por meio de uma IHW, denominada *IHWAquisição*, executada de forma periódica, onde o período de execução é determinado de acordo com a taxa de amostragem do sinal. Essa IHW é responsável

por realizar a leitura do conversor analógico-digital e adicionar seu valor ao final de uma fila dinâmica. Quando esta fila tiver o tamanho maior ou igual a um ciclo do sinal *IHWAquisição* ela irá acionar uma ISW, denominada *ISWDetecção*, encarregada de averiguar se na janela analisada existe ou não pontos que caracterizam o distúrbio.

A Figura 5.11 demonstra como ocorre a relação entre o processo de aquisição de cada ponto e detecção do sinal de acordo com o tempo de aquisição periódico executado por meio da interrupção de hardware chamada de *IHWAquisição*. A *IHWAquisição* é executada em um intervalo de 1,04ms, que corresponde a uma taxa de amostragem de 16 pontos/ciclo. No início da execução do programa, indicado pelo Tempo 0, a fila estará vazia e, após um período, *IHWAquisição* é executada e captura o ponto P1 (Tempo 1). Após um determinado tempo de execução a fila vai possuir um tamanho igual ao tamanho da janela de 1 ciclo do sinal, no caso 16 pontos.

Assim, quando a fila for igual ou maior que o tamanho da janela de 1 ciclo do sinal, *IHWAquisição* irá acionar *ISWDetecção* que será responsável por implementar a rotina de detecção para a janela. Depois de realizados os cálculos de detecção, a *ISWDetecção* remove da memória do microcontrolador o primeiro ponto do sinal, realizando assim um janelamento, sendo que este processo é observado no Tempo 16 e Tempo 17. No momento seguinte (Tempo 17) *IHWAquisição* irá novamente adquirir um ponto do sinal e armazenar no final da fila. Como a fila possui um tamanho de um ciclo do sinal, *IHWAquisição* acionará *ISWDetecção* para realizar novamente a rotina de detecção. Esse processo é realizado durante toda execução do programa.

Ainda pela Figura 5.11 nota-se que o ponto P18 tem características diferentes dos pontos normais. Quando a rotina *ISWDetecção* aplicar o método na janela que contém este ponto o distúrbio será detectado. Deste modo, *ISWDetecção* consegue identificar o primeiro ponto que caracteriza o distúrbio. Uma vez que é detectado este ponto, *ISWDetecção* inicializará uma nova fila responsável por armazenar todos os pontos até ser capturada uma janela que não possui mais distúrbio. Essa fila será posteriormente tratada por duas tarefas, sendo que a primeira é responsável por salvar esse distúrbio no cartão SD e a segunda é responsável pela classificação desse distúrbio e armazenagem das informações do mesmo no cartão SD.

Figura 5.11 – Escalonamento das interrupções de aquisição e detecção.

Fonte: Autoria própria

O processo de detecção é compacto e rápido e a velocidade de processamento do sistema depende exclusivamente da quantidade de pontos presentes em uma janela de 1 ciclo. De modo a melhor exemplificar a velocidade do método, um estudo a respeito do seu custo computacional é realizado. O estudo, em termos da complexidade, visa obter uma função de ordem que determina a taxa de crescimento relacionada ao tempo de execução do algoritmo, ou seja, em função de uma entrada de tamanho n [68]. Um pseudocódigo do método de detecção é apresentado na sequência, relacionando cada linha com sua respectiva complexidade.

De acordo com o pseudocódigo da função detecção, nota-se que a velocidade da função depende exclusivamente das operações que são executadas nas funções RMS e DHT de uma janela. Assim, para obter a complexidade computacional será calculado o esforço computacional das funções que retornam o valor RMS e DHT da

janela de 1 ciclo do sinal com tamanho n . No que segue são apresentados o pseudocódigo das funções RMS e DHT.

Função Detecção		Complexidade
1	detecção (Janela de tamanho n)	
2	ValorRMS = RMS(Janela)	n
3	ValorDHT = DHT (Janela)	$n*\log n$
4	Dist_euclidiana_RMS = raiz(Caracteristica _{referencia} - ValorRMS)	1
5	Dist_euclidiana_DHT = raiz(Caracteristica _{referencia} - Valor DHT)	1
6	se (Dist_euclidiana_RMS > limiar ou Dist_euclidiana_DHT > limiar)	1
7	retorna Distúrbio Detectado	1

Função RMS		Complexidade
1	Função RMS (Janela de tamanho n)	
2	somatório = 0	1
3	para i de 1 até n faça	
4	somatório = somatório + Janela[i] ²	n
5	fim para	
6	retorna raiz(somatório/ N)	1

Função DHT		Complexidade
1	Função DHT (Janela de tamanho n)	
2	somatório = 0	1
3	$X = \text{fft}(\text{janela de tamanho } n)$	$n*\log n$
4	para i de 1 até $n/2$ faça	1
5	somatório = somatório + $X[i]$	$n/2$
6	fim para	
7	retorna raiz(somatório/ N)	1

A função RMS é implementada utilizando uma estrutura de controle repetitivo *loop for*, realizando uma iteração em cada elemento do vetor que compõe a janela de entrada. Com isso, o tempo de execução do algoritmo pode ser expresso como a soma dos tempos gastos em cada execução do corpo do *loop*, no caso a expressão da linha 4. As constantes da linha 2 e 6 são desprezadas. A estrutura de repetição *for* percorre o vetor de entrada de 1 até n ; logo, a eficiência do algoritmo é de complexidade $O(n)$.

Por sua vez, para o cálculo da função DHT, como é uma característica obtida no domínio da frequência, faz-se necessário primeiro obter os componentes harmônicos do sinal utilizando a Transformada Rápida de Fourier, a qual é implementada em hardware a partir da biblioteca de software CMSIS DSP. Essa

biblioteca disponibiliza um conjunto de funções para processamento de sinais a serem empregadas no microcontrolador.

A função FFT recebe como entrada um vetor de dados de tamanho n , onde n varia de 8 a 4096 (em potência de 2) e retorna o espectro de frequência resultante da aplicação do algoritmo da FFT sobre o vetor de entrada.

O algoritmo FFT tem a complexidade $O(n \cdot \log n)$. Assim, a função que calcula o DHT executará um loop de repetição para calcular a soma de componentes harmônicos da FFT, onde o tempo tomado é determinado pela quantidade de vezes que esta operação é realizada. Assim, a eficiência da função DHT será $O(n \cdot \log n + n/2)$. No entanto, é comum escrever a expressão de ordem sem considerar os termos menos significativos e, assim, a complexidade da função DHT pode ser considerada como $O(n \cdot \log n)$.

De acordo com a análise anterior, a complexidade do método de detecção de perturbações pode ser definida de acordo com a maior complexidade obtida, isto é, $O(n \cdot \log n)$. Portanto, a ordem encontrada expressa o comportamento do algoritmo à medida que cresce o número de entradas, ou seja, o custo computacional cresce à medida que aumenta a taxa de aquisição.

Em sistemas embarcados, é necessário estabelecer um equilíbrio entre a taxa de amostragem, o esforço computacional dos algoritmos e o desempenho dos métodos.

Para corroborar a análise da complexidade computacional, é realizado um teste de desempenho do método, ou seja, a velocidade de execução do método após embarcado é medida considerando diferentes taxas de amostragem. A Tabela 5.2 apresenta as velocidades medidas de acordo com taxa de aquisição.

Tabela 5.2 – Velocidade do método de detecção de acordo com a taxa de amostragem.

<i>Taxa de Amostragem</i>	<i>Tempo de aquisição (ms)</i>	<i>Velocidade do método (ms)</i>
16 pontos/Ciclo	1,042	0,0063
32 pontos/Ciclo	0,521	0,093
64 pontos/Ciclo	0,260	0,192
128 pontos/Ciclo	0,130	0,410
256 pontos/Ciclo	0,0065	1,111

Fonte: Autoria própria

De acordo com a Tabela 5.2, observa-se que para janelas adquiridas com uma taxa de amostragem entre 16 e 64 pontos/ciclo, a detecção requer menos tempo

do que a aquisição de uma amostra. Por outro lado, para taxas de amostragem de 128 e 256 amostras/ciclo, o método de detecção apresenta uma velocidade de execução mais alta do que a aquisição de uma amostra.

Faz-se importante ressaltar que o gerenciamento de recursos fornecidos pelo TI-RTOS garante que o método seja executado mesmo utilizando as taxas de amostragem mais alta, onde a aquisição de um ponto ocorre em uma velocidade maior que a rotina de detecção. Neste caso, as rotinas *ISWDetecção* serão interrompidas e alocadas em uma pilha toda vez que uma rotina de *IHWAquisição* for chamada. As rotinas *ISWDetecção* armazenadas na pilha são executadas de acordo com a ordem de entrada e prioridade. Em contrapartida o ponto medido por *IHWAquisição* será armazenado no buffer para posteriormente ser analisado pela interrupção de software *ISWDetecção*. A Figura 5.12 apresenta o escalonamento das rotinas IHW e ISW.

Figura 5.12 – Escalonamento de execução das rotinas IHW e ISW.

Fonte: Autoria própria

Pela Figura 5.12 nota-se que, quando *IHWAquisição* é acionada para medir um ponto do sinal, ela interrompe a execução da *ISWDetecção1* e dispara *ISWDetecção2*. Na sequência, *IHWAquisição* é finalizada e o programa retorna para execução de *ISWDetecção1* e a *ISWDetecção2* responsável por tratar o ponto medido só é executada após *ISWDetecção1* ser finalizada.

Apesar de não ser um problema devido à utilização do RTOS que gerencia esses recursos, notou-se por meio de testes que ao utilizar uma taxa de amostragem maior que 64 pontos/ciclo ocorre uma limitação com relação ao tamanho da memória do microcontrolador. Nesse caso, o buffer de aquisição enche mais rápido do que esvazia; assim, em um determinado instante de tempo ocorrerá um estouro de

memória. A Figura 5.13 exemplifica a alocação de dados para uma taxa de amostragem de 128 pontos/ciclo.

Figura 5.13 – Rotina de detecção para uma taxa de amostragem de 128 pontos/ciclo

Fonte: Autoria própria

De acordo com a Figura 5.13 no tempo 148 o tamanho da fila é igual a 130 e quando a execução atinge o tempo 150 o tamanho da fila é 132, sendo que nesse instante a *ISWDetecção* irá remover o ponto 18 da fila. Assim nesse caso, para cada dois pontos adicionados 1 ponto é removido e, portanto, caso não for tratado esse acúmulo de dados pode ocorrer um estouro de memória. Uma opção para contornar esse problema seria a utilização de uma memória secundária com maior capacidade de armazenamento ou o emprego de um microcontrolador com uma maior velocidade de processamento.

Além de considerar a velocidade de processamento para escolha da taxa de amostragem, também se levou em conta que a norma PRODIST estabelece que as medições no sistema de distribuição (60 Hz) devem assegurar o cálculo dos harmônicos até a ordem 25, isto é, 1,5 kHz. Assim sendo, a taxa de amostragem deve ser de pelo menos 3 kHz. Considerando-se apenas as taxas de amostragem válidas e acima de 3 kHz, têm-se: 64 (3,84 kHz), 128 (7,68 kHz) e 256 (15,36 kHz) pontos /ciclo. Devido a limitações do hardware, as taxas de 128 e 256 pontos/ciclo não podem ser utilizadas. Portanto, a taxa de amostragem utilizada no medidor inteligente é de 64 pontos/ciclo.

Depois de explanadas todas as peculiaridades a respeito da implementação em hardware do método de detecção, pode-se resumir seu comportamento da seguinte forma. Toda vez que a fila que armazena os pontos medidos for maior que o tamanho de uma janela do ciclo do sinal, a rotina de detecção é acionada. Esta rotina realiza uma análise para saber se o último ponto capturado possui ou não uma anomalia. Caso seja positivo, este último ponto é adicionado a uma fila que irá armazenar o vetor que representa o distúrbio. Quando a rotina de detecção determinar o ponto que representa o fim do distúrbio, esta fila será então repassada como entrada para o método de classificação.

5.3.2 Classificação dos Distúrbios de VTCDs

Uma vez que o método de detecção tende a separar as formas de ondas normais das formas de ondas com distúrbios, apenas as janelas que possuem distúrbios são analisadas. Por conseguinte, a complexidade do método de classificação pode ser reduzida, visto que os distúrbios de VTCDs possuem características de amplitudes do sinal diferentes.

Neste contexto, analisando-se o objetivo da metodologia proposta de implementar um sistema compacto a etapa de classificação é ativada, onde se emprega um estágio de extração de características combinado com um classificador baseado em árvore de decisão. Um extrator de característica deve reduzir o vetor padrão de entrada (ou seja, a forma de onda do distúrbio detectado) para uma menor dimensão, preservando todas as informações úteis a partir do vetor original [69]. Adicionalmente, a extração de recursos minimiza esforço computacional utilizado no classificador de padrões, responsável por classificar os distúrbios de VTCDs.

A extração de característica é realizada utilizando cálculos compactos que caracterizam a amplitude de um sinal senoidal. Para esta finalidade são calculadas, além das quatro características (RMS, Valor de Pico, Fator de Pico e Valor Médio) apresentadas no Capítulo 3, as características que correspondem à amplitude do 1º Harmônico, sendo que para o sinal analisado esse valor corresponde a componente fundamental. Ela é utilizada porque não sofre influência com a presença do ruído, sendo definida por meio da Transformada Rápida de Fourier.

A importância da extração de características encontra-se na redução da dimensionalidade do problema. Assim, a partir dela almeja diminuir o esforço

desempenhado na obtenção dos atributos, bem como o gasto no treinamento do classificador. Deste modo, para cada janela de dados d_j é extraído um vetor C_k , onde j representa o índice de cada elemento contido na janela e que varia no intervalo $\{1 \rightarrow 64\}$; e k representa cada característica no intervalo $\{1 \rightarrow 5\}$.

O classificador utilizado é baseado em árvore de decisão, que são ferramentas que utilizam estratégias “dividir para conquistar” para aprendizagem de padrões de um conjunto de dados [70], apresentando como principal vantagem a compilação de estruturas compactas e de grande legibilidade, de modo que seus resultados são facilmente entendíveis [71]. Elas são estruturadas hierarquicamente em um conjunto de nós interconectados, cujos nós internos testam um atributo de entrada com uma constante de decisão e determina qual será o próximo nó descendente. Já os nós folhas classificam as instâncias que os atingem de acordo com o rótulo associado a ele. Portanto, o conhecimento em uma árvore de decisão é representado por cada nó, que ao ser testado conduz a busca para um nó filho, até chegar a um nó folha.

A árvore de decisão possui características relevantes que viabilizam o método, tais como os seguintes:

- Precisão: habilidade do modelo para avaliar ou prever corretamente classes, agrupamentos, regras;
- Velocidade: uma vez construída uma árvore de decisão, seu uso é imediato e sua execução é computacionalmente muito rápida.
- Robustez: habilidade do modelo para avaliar ou prever corretamente, utilizando-se dados ruidosos ou com valores ausentes;
- Escalabilidade: capacidade de construir modelos eficientemente a partir de grandes volumes de dados;
- Interpretabilidade: alto nível de compreensão fornecido pelo modelo;
- Flexibilidade: o espaço das instâncias é particionado em subespaços e cada subespaço é adaptado a diferentes modelos.

O processo de indução de uma árvore pode ser realizado de forma manual. No entanto, quando existe uma grande quantidade de dados, este processo torna-se exaustivo para ser realizado manualmente. Assim sendo, recorre-se para uma

abordagem automática de indução, normalmente, baseada em aprendizado supervisionado. Portanto, o algoritmo passa a determinar os nós e folhas da árvore a partir de um conjunto de dados de treinamento com seus respectivos valores desejados. Neste trabalho, foi utilizado o algoritmo C4.5 [72] para o processo de indução automática das árvores de decisão, e visa à construção de uma árvore por meio de um conjunto de treinamento. Após a construção da árvore, é possível então obter um conjunto de regras que podem ser implementadas no microcontrolador por meio de estruturas do tipo “se...então”.

Para implementação da etapa de classificação em hardware são utilizadas duas tarefas que funcionam durante toda execução do programa. A primeira tem a função de averiguar se algum distúrbio foi detectado na primeira etapa e salvar esse distúrbio em um cartão de memória SD, com objetivo de limpar a memória do microcontrolador. Depois do sinal armazenado a segunda tarefa se encarrega de classificar o distúrbio detectado, sendo, portanto, executada a rotina de classificação.

Quando a tarefa de classificação recebe a forma de onda que representa o distúrbio classificado, ela extrai um vetor de 5 características que é utilizado como entrada para a árvore de decisão, que foi treinada utilizando dados sintéticos.

Após a classificação do distúrbio, as informações do tipo dos distúrbios e também das características extraídas, RMS, Valor de Pico, Fator de Pico e Valor Médio, são armazenadas no cartão de memória SD, para que posteriormente elas sejam enviadas para a central de controle e operação por meio da comunicação Ethernet.

As características RMS, Valor de Pico, Fator de Pico e Valor Médio foram escolhidas porque, segundo os estudos realizados e apresentados no Capítulo 4, observou-se que este conjunto define a propagação do distúrbio, não sendo necessário ocupar o canal de transmissão com outras características que são desnecessárias.

5.4 Considerações Finais do Capítulo

O Capítulo 5 atestou que a partir da utilização de um Sistema Operacional de Tempo Real é possível programar em hardware um método para análise do sinal de tensão que alcança uma boa resolução a respeito da detecção e classificação do distúrbio de VTCD. Com isso, informações a respeito dos distúrbios podem ser

capturadas em vários pontos do sistema e disponibilizadas para a central de controle e processamento e, a partir disto, elas podem ser utilizadas para desenvolver a metodologia proposta para localização dos distúrbios de VTCDs.

A implementação da metodologia utilizando o TI-RTOS permitiu estabelecer prioridades, de modo que a aquisição e detecção de distúrbios têm alta prioridade, enquanto a classificação e troca de dados com o utilitário possuem uma menor prioridade. Devido ao uso de cálculos com baixo custo computacional e, também à implementação em TI-RTOS, foi possível garantir que uma análise seja feita a cada deslocamento da janela com um passo de 1 ponto e um tamanho de ciclo.

Com esse objetivo o próximo capítulo descreve minuciosamente a metodologia proposta nessa tese, detalhando as particularidades de cada ferramental teórico que a metodologia é baseada, assim como a execução de cada uma de suas etapas.

6 Método de Localização Das Fontes Causadoras De VTCDs

Até o presente capítulo foi descrito que o vetor de características RMS, Valor de Pico, Fator de Pico e Valor Médio extraídos dos distúrbios de VTCDs que são evidenciados nos locais de medição conseguem descrever a propagação do distúrbio. De modo complementar, expõem que essas características podem ser disponibilizadas a partir de uma arquitetura de hardware capaz de detectar e classificar os distúrbios de VTCDs. Tais estudos subsidiam a abordagem desenvolvida para localização dos distúrbios que é proposta nessa tese.

Assim, este capítulo tem como objetivo explicar, em detalhes, o método que será utilizado para a localização das fontes causadoras de VTCDs. Para isto, ferramentas de aprendizado de máquinas podem ser utilizadas para analisar as características do sinal advindas dos *smart meters* e, consequentemente, reconhecer um padrão nestes dados, com o intuito de inferir na localização das VTCDs de forma rápida e precisa.

Para isso é idealizado um algoritmo híbrido recursivo baseado no algoritmo *k-means* e conjunto de regras. O ponto fundamental corresponde na aplicação do algoritmo *k-means* responsável por organizar as características de entrada em *clusters*. Para uma maior eficácia em termos de respostas a saída do algoritmo *k-means* é combinada com um sistema de regras de decisão, responsável por apontar qual dos *clusters* agrega a região de origem. O algoritmo desenvolvido é baseado na estratégia “dividir para conquistar”, onde o problema de determinar o local de origem é dividido em problemas menores. Assim, o problema de apontar o local de origem do distúrbio é sintetizado em dois problemas menores.

Com isto, almeja-se encontrar um método compacto que visa inferir na região de origem do distúrbio de VTCD a partir da análise do conjunto de característica, responsável por representar a disseminação do distúrbio no sistema.

Neste contexto, a Seção 6.1 apresenta os fundamentos básicos dos algoritmos de aprendizagem de máquina. A Seção 6.2 exprime a base teórica necessária para compreender a metodologia proposta, destacando as características do algoritmo de agrupamento de dados, e apresentando uma visão geral do algoritmo *k-means* e sua aplicação para análise das características advindas dos medidores. A seção 6.3 apresenta um estudo que aponta que o algoritmo *k-means* pode ser utilizado para agrupar os dados advindos dos *smart meters*. Na Seção 6.4 é apresentada uma visão geral da metodologia que é desenvolvida para localizar os distúrbios de VTCDs; explanando a etapa de tratamento dos dados recebidos na central de controle, e posteriormente, os passos do algoritmo recursivo híbrido. As considerações do capítulo são destacadas na Seção 6.5.

6.1 Aprendizagem de Máquina

Algoritmo de Aprendizagem de Máquina corresponde em um conjunto de técnicas computacionais capazes de aprender e procurar padrões de forma automatizada a partir de vasto conjunto de dados [73].

Estes algoritmos conseguem construir um modelo a partir do conjunto de amostras de entrada e podem ser divididos em várias categorias, destacando-se os algoritmos de aprendizagem supervisionada e os algoritmos de aprendizagem não supervisionada. Os algoritmos que compõem a primeira categoria recebem um conjunto de dados de treinamento, onde cada dado é associado a um valor de saída. A partir deste conjunto de treinamento o algoritmo supervisionado constrói um modelo que é capaz de produzir uma saída adequada a partir de uma nova entrada.

Na categoria não supervisionada os exemplos de treinamento não possuem rótulos e, portanto, não existe uma saída desejada. Para este, os algoritmos tendem a analisar os dados de entrada de modo a organiza-los em estruturas, descrevendo similaridades nos dados que possam vir a ser úteis. Esta abordagem é muito utilizada na tarefa de exploração de dados não rotulados.

Os algoritmos de aprendizagem de máquina são capazes de executar tarefas de classificação, regressão, associação e clusterização. A classificação visa relacionar uma entrada a uma classe pré-estabelecida, por meio da relação entre os registros de entrada com o conjunto de registro fornecido no treinamento. A predição visa definir o valor futuro de um determinado dado por meio da análise dos atributos

que influenciam o valor futuro do atributo desejado. Associação é a descoberta de correlação entre duas ou mais variáveis. Por último, a tarefa de agrupamento tem o objetivo de aproximar os registros semelhantes em *cluster* de acordo com medidas de similaridades.

Diante do exposto observa-se que as ferramentas que seguem os princípios dos algoritmos de aprendizagem de máquina estão cada vez mais presentes em várias áreas do conhecimento, principalmente em sistemas que envolvem enorme volume de dados como é o caso das redes elétricas inteligentes ou *smart grid*. Assim, a utilização destes algoritmos pode aumentar as funcionalidades providas por esta arquitetura de rede.

Neste contexto, estes algoritmos podem ser utilizados para descoberta de padrões nas características do sinal de tensão advindas dos *smart meters* e, conseqüentemente, apontar de forma automática o ponto no sistema onde o distúrbio de VTCD é originado.

A utilização de algoritmos supervisionados para apontar a origem do distúrbio de VTCD corresponde a uma abordagem complexa, visto que a propagação do evento em relação à sua origem depende de vários fatores como: topologia da rede, intensidade do distúrbio e localização da fonte causadora em relação à subestação, sendo que a cada nova configuração um novo padrão de propagação é evidenciado, fato este que dificulta a idealização de um algoritmo simples que consiga generalizar todos esses fatores.

Por sua vez, na abordagem não supervisionada, os algoritmos tendem a analisar os dados de entrada de modo a organiza-los em estruturas, descrevendo similaridades nos dados que possam vir a ser úteis. Assim, a partir da utilização de algoritmos pertencentes a essa classe, faz-se possível inferir a cada novo padrão de características de modo a correlaciona-las de acordo com o grau de similaridade entre elas.

Fundamentado nessas características, o algoritmo *k-means* pode ser utilizado para agrupar os nós do sistema sem o conhecimento prévio do padrão de característica de entrada, analisando somente as similaridades das características fornecidas em um determinado instante, não sendo influenciado por fatores externos.

Isso significa organizar estes dados em *clusters* de modo que cada grupo é formado por padrões mais simples ou mais organizados descrevendo similaridades nos dados que possam vir a ser úteis. Com isto, almeja-se que estes grupos possam

ser formados de acordo com o perfil de propagação, sendo então possível separar os dados de entrada em duas zonas distintas.

6.2 Algoritmo de Agrupamento *k-means*

Algoritmos de agrupamento correspondem a classe de aprendizagem não supervisionada e têm o objetivo de agrupar um conjunto de objetos de entrada em *clusters*/grupos homogêneos de acordo com as similaridades obtidas entre os atributos que representam cada objeto. A definição dos grupos é realizada sem o conhecimento prévio da classe de entrada [74].

De forma geral, estes algoritmos tendem a organizar um conjunto de dados de entrada do tipo $X = \{X_1, X_2, X_3, \dots, X_n\}$ de tamanho n em k *clusters* disjuntos, onde X é um vetor que armazena os atributos dos dados do conjunto de entrada. Portanto, eles utilizam somente as informações das variáveis de entrada para definir os *clusters*. Ao final da execução os objetos que apresentarem características semelhantes (alta similaridade) irão pertencer ao mesmo *cluster*, do contrário (baixa similaridade) irão ser agregados em *clusters* distintos. Portanto, o objetivo principal dos algoritmos de agrupamento de dados é descobrir padrões naturais em um conjunto de dados, sendo empregados para exploração de dados [75].

Os algoritmos de *clusterização* têm sido altamente explorados e aplicados em vários problemas como: obter informações e gerar informações; reconhecimento de padrões, resumir e organizar informações de um conjunto.

Um exemplo gráfico do objetivo dos algoritmos de agrupamento é representado na Figura 6.1, a qual ilustra um conjunto de dados de entrada não rotulados (Figura 6.1a) e, por conseguinte, destaca os 7 padrões que podem ser obtidos nesses dados, sendo caracterizados de acordo com a disposição espacial dos objetos (Figura 6.1b).

Os algoritmos de agrupamento disponíveis na literatura agrupam os dados de forma automática com base em heurísticas que são responsáveis por encontrar as melhores partições. Cada técnica é baseada em um princípio, a qual é capaz de revelar *cluster* de acordo com uma estrutura específica.

Figura 6.1 – Dados de entrada (a) e Padrões descobertos de acordo com a forma, tamanho e densidade (b)

Fonte: [75]

A tarefa de agrupar os dados de entrada em k grupos corresponde a um problema do tipo NP-difícil, uma vez que um *cluster* pode ser definido de acordo com a forma, tamanho ou densidade dos dados de entrada. Assim, dependendo do conjunto de dados, a tarefa de encontrar grupos ótimos é intratável ou não computável em um tempo razoável.

Portanto, os algoritmos desenvolvidos fornecem apenas uma aproximação do resultado ótimo, sendo praticamente impossível revelar toda a variedade de estruturas presentes no conjunto de dados. Os métodos de *clusterização* podem ser divididos de acordo com os seguintes aspectos [74], [76], [77]:

- **Método hierárquico:** Esse método aglomera os dados de acordo com uma hierarquia utilizando uma estrutura do tipo árvore, fornecendo uma visão descritiva do relacionamento entre os potenciais *clusters*. Eles podem ser do tipo divisivo ou algomerativo. Nos métodos hierárquicos divisivos o *cluster* inicial formado por todos os elementos é dividido gradualmente em *cluster* menores. Nos métodos algomerativos, a princípio, cada objeto do conjunto de entrada representa um *cluster*; em seguida, cada ponto é agrupado hierarquicamente em conjunto de dados maiores, até formarem o conjunto de dados de entrada. Como exemplo, tem-se os algoritmos Cure e Diana.
- **Métodos particionais:** dividem o conjunto de objetos de entrada em um número k de grupos, obtendo várias partições de dados. Esta classe de

algoritmo realiza uma busca iterativa no espaço de dados, procurando os k melhores grupos que dividem os dados. Geralmente, o número k de partições é definido como parâmetro de entrada. Os principais algoritmos que pertencem a esta classe correspondem ao algoritmo *k-means* e algoritmo *k-medoids*.

- Método baseado em densidade: os *clusters* são definidos baseados em uma função de densidade probabilística. Assim, cada *cluster* corresponde à região densa e são separados por regiões menos densas. A densidade de cada ponto está intimamente relacionada com o vizinho mais próximo. Os algoritmos baseados em densidades são capazes de descobrir *cluster* de formas arbitrárias como: superfícies elípticas, cilíndricas, etc., as quais crescem em qualquer direção. Como exemplo, tem-se os algoritmos *Dbscan* e *Denclue*.
- Método baseado em modelo: estes métodos supõem que os dados são gerados por uma mistura de distribuição probabilística e, por isso, utilizam modelos matemáticos pré-definidos, sendo que os dados do conjunto de entrada se encaixam nestes modelos. Estes métodos são decompostos em várias abordagens, tais como: modelos estatísticos, modelos de redes neurais e modelos de densidade de mistura.
- Método baseado em grupamento *fuzzy*: neste método cada objeto pode pertencer a mais de um *cluster* com certo grau de pertinência. Esta associação ajuda a definir melhor as relações entre os *clusters*, entretanto é difícil definir a melhor configuração das funções *fuzzy*, as quais determinam as relações entre grupos. O algoritmo *Fuzzy C-means* é o mais difundido neste tipo de método.

Considerando-se cada classe, fica claro que o tipo de algoritmo utilizado influencia diretamente na estrutura de *cluster* induzido. De forma a melhor representar esta influência a **Figura 6.2** compara como os *clusters* podem ser descobertos em 4 modelos de entradas diferentes, a partir da aplicação do algoritmo *k-means* com duas partições, algoritmo de densidade DBSCAN e algoritmo de *clusterização* hierárquico BIRCH.

Figura 6.2 – Comparação da saída obtida de diversos algoritmos de *clusterização* a partir de diferentes entradas.

Fonte: Adaptado de [75]

Dado a **Figura 6.2** fica claro que o algoritmo Birch [78] e *k-means* [79] são utilizados para agrupar dados que podem ser separados por um fronteira e apresentam problemas para identificar *cluster* com formato não esférico. Por sua vez, o algoritmo DBSCAN [80] associa as instâncias de acordo com uma função de densidade. Assim sendo, este algoritmo é capaz de encontrar *clusters* com formato não esférico, entretanto, a escolha dos parâmetros deste algoritmo é de difícil determinação.

O método proposto nesta tese utiliza um algoritmo de *clusterização k-means*, proposto por [79], sendo responsável por separar a superfície dos dados de entrada, formado a partir das características advindas dos medidores em grupos distintos. O *k-means* corresponde a um dos algoritmos de *clusterização* mais utilizados devido a sua simplicidade de implementação, rápida convergência para uma configuração estável, eficiência e sucesso empírico [74].

O algoritmo *k-means* é um método de *clusterização* baseado em particionamento que utiliza um critério de realocação iterativa. O objetivo deste tipo de agrupamento é encontrar os k pontos do espaço de busca que minimizem uma

função erro ou função objetivo, a qual determina a similaridade global entre os objetos dos *clusters*. A função objetivo no algoritmo *k-means* é definida por (6.1).

$$E = \sum_{j=1}^k \sum_{x_i \in C_j} d(x_i, X^{(j)})^2 \quad (6.1)$$

onde a função $d(x_i, X^{(j)})$ retorna à distância entre um objeto x_i ao ponto centróide $X^{(j)}$ do *cluster* j . Um centróide é o ponto responsável por resumir as informações contidas em cada um dos k *clusters* definindo um centro de cada grupo, geralmente corresponde à média das amostras pertencentes a um grupo.

Portanto, quanto menor for a distância dos objetos que compõem um *cluster* em relação ao seu centróide menor será o valor da sua função de erro. O relacionamento entre cada objeto do conjunto de dado pode ser descrito por meio de uma matriz de dissimilaridade d , expressa em (6.2).

$$d = \begin{bmatrix} 0 & d(1,2) & d(1,j) \\ M & 0 & M \\ d(1,j) & L & 0 \end{bmatrix} \quad (6.2)$$

onde $d(i,j)$ representa um valor resultante da métrica de similaridade entre o objeto de índice i e o objeto de índice j do conjunto de dados de entrada. Não existe uma métrica genérica que pode ser utilizada em todo tipo de problema, sendo que a sua escolha depende dos dados de entrada e do contexto do problema [77]. A métrica mais utilizada para descrever a similaridade entre dois elementos são as medidas de Distância Euclidiana, Manhattan e Mahalanobis.

O funcionamento do algoritmo *k-means* pode ser dividido em 4 passos que são descritos na sequência, os quais são também representados na Figura 6.3.

k-means

1. Escolher os k valores que representam os centros de cada *cluster*
 2. Relacionar cada ponto do conjunto de entrada ao centro k mais próximo
 3. Recalcular o centro de cada grupo
 4. Repetir o passo 2 e 3 até nenhum objeto mudar de grupo.
-

Assim, o primeiro passo do algoritmo consiste em especificar o número de *clusters* que serão encontrados. Este é o parâmetro k e no exemplo corresponde a 2. Logo, k pontos são escolhidos aleatoriamente determinando os centróides iniciais (Figura 6.3a). Em seguida, cada objeto de entrada é atribuído ao *cluster* que possui o centróide mais próximo de acordo com a métrica de distância (cor azul e vermelho

apresentada na Figura 6.3b). O terceiro passo consiste em determinar novos centróides para cada k *cluster*, por meio da média aritmética das amostras que compõem o *cluster* (Figura 6.3c) e, por conseguinte, as instâncias são realocadas ao novo centro mais próximo (Figura 6.3d). Por fim, o segundo e terceiro passo são repetidos até que não ocorra mudança dos objetos pertencentes aos *clusters* entre uma iteração e outra [70].

Figura 6.3 - Ilustração do algoritmo *K-means*. (a) Dados de entrada bidimensionais com dois pontos iniciais que definem os centróides; (b) definição dos objetos que compõem cada *cluster*; (c) atualização dos centróides; (d)—(h) iterações intermediárias atualizando rótulos de *cluster* e seus centros; (i) agrupamento final

Fonte: [81]

O algoritmo *k-means* requer que o projetista determine a priori os seguintes parâmetros: número de *clusters* k ; forma de inicialização do centróide e o tipo da métrica de distância. Estes parâmetros influenciam na descoberta do *cluster*, sendo que a escolha mais crítica corresponde ao número de *clusters* k .

Destaca-se que a inicialização dos centros dos *clusters* afeta a convergência da função objetivo para diferentes mínimos locais e para descobrir os melhores centros o algoritmo pode ser executado n vezes com k diferentes pontos iniciais, sendo que o resultado que fornecer o menor valor será considerado. Adicionalmente,

a métrica de distância euclidiana é a mais utilizada para calcular a distância entre dois pontos, pois possui uma fácil interpretação e é a mais utilizada para atributos contínuos.

Por conseguinte, após a divisão dos dados de entrada em *clusters*, cada grupo pode ser avaliado, destacando as similaridades entre objetos pertencentes ao mesmo *cluster* e diferenças entre objetos pertencentes a *cluster* diferentes [76]. Com isto, é possível definir se um grupo encontrado é estável, ou seja, se ele consegue maximizar as dissimilaridades.

Para avaliar se os *clusters* encontrados são validos três critérios podem ser utilizados, os quais correspondem:

- Critério Interno: utiliza os dados de cada *cluster* para avaliar a estrutura do grupo. Em geral, usa uma matriz de distâncias;
- Critério Relativo: compara duas ou mais características dos grupos que foram gerados;
- Critério Externo: avalia o desempenho com base em um conhecimento a priori que é esperado.

A maioria das medidas utilizadas para quantificar a estabilidade dos *clusters* obtidos pelo algoritmo *k-means* são determinadas de acordo com as métricas de distâncias.

Para tanto, a distância entre os centróides de dois *clusters* pode ser utilizada, para determinar quão distinto um *cluster* é dos demais.

A média das somas das distâncias obtidas entre cada elemento e o elemento centróide pode ser utilizado para quantificar a coesão de cada *cluster*, determinando se os elementos que o compõem estão mais densos ou não.

Outra métrica bastante utilizada para validação de *clusters* corresponde à largura de silhueta [82], sendo um parâmetro que combina coesão e separação. A silhueta é calculada para cada objeto de entrada e determina se o objeto está bem posicionado dentro de um *cluster* [83]. Assim sendo, a silhueta de um objeto pode ser expressa por:

$$s(i) = \frac{(b_i - a_i)}{\max(b_i - a_i)} \quad (6.3)$$

onde a_i corresponde à distância média do ponto i aos demais objetos do mesmo *cluster* e b_i é a mínima distância média do ponto i aos objetos dos outros *clusters*. O

valor da silhueta de um objeto varia no intervalo entre $[-1, 1]$. Um valor de silhueta próximo de um, significa que o objeto i está mais adaptado ao seu cluster k .

Assim, a silhueta de um objeto i pertencente ao *cluster* k está relacionada entre a proximidade do objeto i e as demais amostras que constituem o *cluster* k e também é influenciada pela distância média entre o objeto i e os demais elementos do *cluster* mais próximo.

Dessa maneira, quando um *cluster* for constituído de objetos que possuem uma baixa silhueta, então o agrupamento não será bem avaliado. Esta avaliação pode ser quantificada a partir da largura média de silhueta (SWC) expressa por:

$$SWC = \frac{1}{N} \sum_{i=1}^N s(i) \quad (6.4)$$

onde *SWC* relaciona a distância média dos objetos para seu *cluster* com a distância média para outros *clusters*.

Diante do exposto, observa-se que o algoritmo *k-means* apresenta uma série de vantagens que permitem sua aplicação para exploração de dados. Assim, faz-se necessário averiguar sua aplicação na tarefa de exploração dos dados de características advindas dos *smart meters*.

6.3 Aplicação do *k-means* para Análise das Características dos Distúrbios de VTCDs.

O distúrbio de VTCD originado em um determinado ponto do sistema de distribuição é disseminado na rede elétrica com diferentes características. O algoritmo *k-means* pode ser utilizado para fim de analisar as características *in loco* fornecidas pelos medidores em um dado instante de tempo. Neste sentido, ele pode organizar os objetos de entrada em grupos de dados distintos e mais simples ou mais organizados, facilitando na descoberta do local de origem do distúrbio.

No entanto, antes de aplicar o algoritmo *k-means*, deve-se determinar a quantidade de *clusters* que são descobertos e, preferivelmente, analisar se os dados de entrada têm uma tendência de agrupamento [75], [84] e se os *clusters* que possam vir a ser descobertos são válidos. A validade de agrupamento refere-se a procedimentos formais que avaliam os resultados da análise de *cluster* de forma quantitativa e objetiva [85].

De acordo com o problema de localização de origem do distúrbio de VTCD, a quantidade de *clusters* pode ser previamente estabelecida, pois já se sabe a priori que

os dados de entrada serão divididos em dois grupos, os quais correspondem aos medidores que estão próximos da origem do distúrbio e aos medidores que estão distantes. Assim, a desvantagem do método, em ter que fornecer a priori o número de *cluster* k que o conjunto de dados deve ser particionado, é contornada.

Por sua vez, a validade diz respeito se as características de entradas possuem tendências para agrupar os dados de acordo com o objetivo do problema. No contexto do trabalho, para destacar a validade e tendência de formar *clusters*, o conjunto de características RMS, Valor de Pico, Fator de Pico e Valor Médio destacadas nas simulações são confrontados para que se possa determinar se os elementos próximos a origem apresentam similaridades entre si e dissimilaridades entre as barras que formam regiões distintas.

Caso tal condição seja verdade, significa então que o problema pode ser tratado por algoritmos de agrupamento. Nessa perspectiva, este estudo é baseado em quatro simulações de curto-circuito trifásico, onde se variou a localização da origem do evento. A partir do comportamento exemplificado nessas simulações pretende-se generalizar para todo o comportamento do sistema.

A primeira análise é feita sobre os dados resultantes de um curto-circuito envolvendo o nó 802, o qual está localizado próximo à subestação, por consequência, o comportamento identificado nesse caso é generalizado para situações que evidenciam os distúrbios nas barras vizinhas. De modo análogo, o curto-circuito aplicado sobre as barras 850 e 852 sintetiza a propagação de um curto-circuito localizado na zona intermediária do sistema e próximo a um regulador de tensão. Por último, é avaliado o comportamento das barras localizadas ao final do sistema, por meio do curto-circuito envolvendo o nó 846.

A situação de curto-circuito modelado foi a mesma para cada estudo de caso e consiste em um curto-circuito trifásico com duração de falta de 4 ciclos e impedância de 10Ω , com ângulo de incidência de 0° . Para destacar a correlação entre duas ou mais características em torno do local de origem do distúrbio é utilizado gráfico de dispersão. Esse gráfico exprime a distribuição espacial dos valores extraídos das características RMS, Fator de Pico e Valor Médio obtidos em cada nó do sistema de distribuição.

Cada ponto do gráfico é relacionado com o valor das características extraídas em um nó resultante da simulação analisada. Caso o conjunto de dois ou mais pontos formem uma região densa significa dizer que a região delimitada por eles apresenta

uma boa correlação, do contrário estabelece uma baixa correlação. Com isto, é possível obter visualmente relações entre uma variável X e uma variável Y, destacando as similaridades dos distúrbios que foram evidenciados em torno de uma região.

De modo a enfatizar as similaridades em torno do local de origem do distúrbio, para cada ponto do gráfico é atribuído uma cor e um tamanho específico. Tais parâmetros determinam a distância da barra em relação ao local da falta. Pontos menores e de coloração escura representam as barras perto da origem do distúrbio, de modo contrário, pontos maiores e de coloração clara destacam as barras longe da região que ocorreu o distúrbio.

Assim, a Figura 6.4, Figura 6.6 – Gráfico Dispersão e Distribuição das características RMS e Fator de Pico extraídas a partir de um curto-circuito trifásico no nó 852. Figura 6.5, Figura 6.6 e Figura 6.7 apresentam, respectivamente, os gráficos de dispersão dos valores extraídos das características RMS, Fator de Pico e Valor Médio obtidos em cada nó do sistema de distribuição durante a presença de uma falta trifásica envolvendo os nós 802, 850, 852 e 846. A barra de cor em cada gráfico exprime a distância de cada ponto em relação ao local de origem. Adicionalmente, a partir do eixo das abscissas e ordenadas são ilustrados gráficos de distribuição, os quais representam como os valores de características estão distribuídos.

Figura 6.4 – Gráfico Dispersão e Distribuição das características RMS e Valor Médio extraídas a partir de um curto-circuito trifásico no nó 802.

Fonte: Autoria própria

Figura 6.5 – Gráfico Dispersão e Distribuição das características RMS e Valor Médio calculados a partir de um curto-circuito trifásico no nó 850.

Fonte: Autoria própria

Figura 6.6 – Gráfico Dispersão e Distribuição das características RMS e Fator de Pico extraídas a partir de um curto-circuito trifásico no nó 852.

Fonte: Autoria própria

Figura 6.7 – Gráfico Dispersão e Distribuição das características RMS e Fator de Pico extraídas a partir de um curto-circuito trifásico no nó 846.

Fonte: Autoria própria

A partir destes 4 gráficos, é possível visualizar que as barras que estão próximas dos distúrbios (pontos menores e de coloração escura), possuem características semelhantes, determinando uma região de similaridade com propriedades diferentes da região composta pelas barras distante da origem do distúrbio (coloração mais clara e pontos maiores).

Nessa mesma perspectiva, os gráficos de barras destacam um padrão de dispersão e distribuição diferentes com relação aos valores das características observados em cada simulação.

Conclui-se daí que um distúrbio ocasionado por um curto-circuito no nó 802 (próximo à subestação) se propaga ao longo de todas as barras do sistema com características de amplitude bem próximas, onde o valor mínimo e máximo da característica RMS para o afundamento de tensão corresponde, respectivamente, em 0,23 e 0,26. Convém observar que para este caso os valores RMS estão concentrados em 0,25.

O gráfico da Figura 6.5 que sintetiza os valores obtidos a partir de um curto-circuito no nó 850 destaca uma distribuição um pouco diferente. Nota-se que para a característica RMS a faixa de valor é mais densa, situando em torno do intervalo [0,1;

0,2]; no entanto, observa-se que as barras longínquas extrapolam este intervalo, demonstrando uma maior distribuição de valores quando comparados com os valores obtidos na simulação envolvendo o nó 802.

Cabe, pois, concluir que de acordo com essa distribuição, quanto mais distante o ponto de origem em relação à subestação maior será a variação dos dados. Apesar disso, observa-se que os atributos relacionados com as barras localizadas próximas ao local de falta apresentam valores equivalentes.

Neste sentido, o gráfico representado na Figura 6.7 denota que os valores da característica Fator de Pico estão compreendidos entre dois intervalos distintos. O primeiro intervalo está situado entre [1,4; 1,5] e corresponde a região distante do local de origem do distúrbio. O segundo intervalo está localizado entre [1,7; 1,8], e destaca a região próxima do local de origem da falta. Somando esta informação com a informação fornecida pelo vetor RMS, torna-se mais fácil, para esse caso, idealizar uma fronteira entre estas duas regiões.

Logo, quando o distúrbio é originado mais distante da subestação, mais simples será a descoberta dos grupos. Por sua vez, em relação ao distúrbio originado na barra 802, nota-se que os pontos são mais densos e a diferença entre os valores máximos e mínimos em cada caso são bastante próximos, dificultando a visualização da fronteira entre as duas regiões.

A partir da visualização dos gráficos de dispersão, tornou-se possível observar que os dados das características fornecidas pelos medidores podem subsidiar a utilização de métodos de agrupamentos, uma vez que é possível evidenciar uma fronteira que divide os dados de entrada em dois conjuntos de acordo com as similaridades entre os atributos fornecidos por cada medidor.

O algoritmo *k-means* pode ser empregado para agrupar, de forma automática, os elementos de entrada em dois *clusters* distintos. Em seguida, faz-se necessário determinar em qual *cluster* está localizada a região de origem do distúrbio. Todavia, como os dados estão organizados de acordo com o grau de similaridade, torna-se mais simples destacar, por meio das propriedades que definem cada grupo, qual deles engloba a região de origem.

6.4 Metodologia proposta

Seguindo a contextualização apresentada no decorrer da tese o método desenvolvido tem por objetivo apontar a região, no sistema de distribuição, de origem do distúrbio de VTCD sendo, portanto, executado a partir de duas fases concomitantes. A primeira corresponde ao tratamento dos dados e a segunda está relacionada com a aplicação e execução do algoritmo híbrido recursivo baseado no *k-means* e regras de decisão. A estrutura desta abordagem pode ser visualizada por meio do diagrama de blocos da Figura 6.8.

Figura 6.8 – Estrutura geral da metodologia empregada para localização da origem dos distúrbios de VTCDs.

Fonte: Autoria própria

Em linhas gerais, o primeiro passo do método consiste em realizar um tratamento dos dados das características fornecidas por cada *smart meter* no instante de tempo que ocorre um evento de VTCD. Essa etapa tem como objetivo eliminar os dados redundantes e inconsistentes que não agregam informações para resolução do problema. Com isto, almeja-se analisar somente os dados relevantes resultando em uma região de interesse com formato adequado para que o algoritmo recursivo possa vir a ser aplicado.

Posteriormente, os dados que compõem a região de interesse são utilizados como entrada do método Híbrido Recursivo baseado no algoritmo *k-means* e Regras de Decisão. O algoritmo desenvolvido utiliza uma estratégia de dividir para conquistar

com a finalidade de apontar uma pequena região que abrange o local de origem do distúrbio.

Neste caso, o problema de determinar o local de origem é dividido em problemas menores que corresponde, a partir das regras de decisões, determinar qual dos dois *clusters* agrega a barra que o distúrbio foi originado.

Assim, o algoritmo de *k-means* é responsável por agrupar os elementos de entrada, relacionado com cada medidor, em dois grupos de dados distintos e mais simples ou mais organizados, facilitando na descoberta do local de origem do distúrbio.

Há de se convir que nem sempre a região de localização será composta pelos medidores que sentiram o distúrbio com mais intensidade. Entretanto, como os dados são organizados de acordo com o grau de similaridade entre os objetos, as propriedades que descrevem cada grupo podem ser confrontadas por meio de regras de decisão, de modo a definir qual das regiões agrega o local de origem. O ponto fundamental nesta premissa é que o algoritmo irá analisar o todo e as partes para inferir qual grupo abrange o local de origem.

Uma vez que o *cluster* escolhido representar uma região composta por vários nós, o algoritmo híbrido é executado recursivamente sobre os dados que compõem o *cluster* escolhido com o intuito de refinar a região de interesse em uma região menor.

O algoritmo desenvolvido é bem compacto e visa expor a região de origem do distúrbio a partir da análise da disseminação do distúrbio em vários pontos do sistema, sendo a aplicação do algoritmo *k-means* o ponto fundamental na metodologia. Após esta breve contextualização sobre o método proposto, no que segue é apresentado em detalhes os conceitos relacionados a cada uma de suas etapas.

6.4.1 Tratamento e Agregação dos Dados

A primeira etapa consiste em analisar e transformar os dados que foram recebidos dos medidores durante o intervalo de tempo que o distúrbio de VTCD foi evidenciado. Assim, nos trabalhos envolvendo análise e mineração de dados o processo de transformação ou pré-processamento de dados deve ser capaz de eliminar os atributos redundantes e inconsistentes, alterando os dados de entrada em um formato apropriado para aplicação do algoritmo [86]. Portanto, essa fase é de

extrema importância, uma vez que pode influenciar diretamente na eficiência do algoritmo desenvolvido.

Considerando-se a ocorrência e propagação do distúrbio no sistema de distribuição, cada medidor é responsável por detectar e transmitir as características e informações sobre o distúrbio detectado. Uma vez que todas estas características são disponibilizadas em um centro de controle, torna-se então possível realizar o tratamento dos dados recebidos e obter as seguintes informações:

- Determinar o tipo do distúrbio que foi classificado em cada medidor;
- Determinar em quais fases o distúrbio foi caracterizado;
- Destacar os dados inconsistentes, relacionados com os nós que não fornecem informações úteis;
- Apontar em qual medidor o distúrbio foi evidenciado com maior intensidade.

O tratamento dos dados resulta em região de interesse e que delimita os dados que como entrada do algoritmo recursivo. Para isto, algumas tarefas podem ser aplicadas para fim de obter os vetores de características que compõem essa região.

Nessa perspectiva, a primeira tarefa diz respeito a detecção de quais das três fases do sistema de distribuição o distúrbio foi evidenciado. Com isto é possível excluir dos dados agregados informações relacionadas com as barras, onde o distúrbio não foi caracterizado. Este passo pode ser executado pela seguinte regra:

Regra #1

Se $RMS_{ij} = NULO$ então excluir dados relacionados a Barra $_i$, Fase j

O RMS_{ij} corresponde ao valor RMS extraído do sinal de tensão medido na barra i e na fase j . Caso este valor seja NULO, significa que não foi detectado distúrbio no nó i fase j , durante o instante de tempo que o distúrbio esteve presente no sistema. De modo a retratar sua importância, a Tabela 6.1 apresenta as características que são fornecidas a partir de um afundamento de tensão ocasionado por um curto-circuito bifásico aplicado na barra 852 envolvendo a fase A e fase B.

Por meio dos valores apresentados na Tabela 6.1 conclui-se pela inferência produzida pela Regra#1 que o distúrbio é sentido nas Fases A e B; logo, corresponde a um curto-circuito bifásico e, conseqüentemente, ele não pode ter sido originado nas barras que não apresentam uma destas fases. Assim, neste caso, as linhas da Tabela 6.1 relacionadas às barras 810, 818, 820, 822, 826, 856, 864 e 838 são excluídas. De

maneira análoga, destaca-se que caso o distúrbio estivesse presente somente em uma fase ou nas três fases, seriam então desprezadas as barras compostas pelas fases onde o distúrbio não é evidenciado.

Tabela 6.1 – Dados resultantes dos pontos de medição para simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicado no nó 852.

Barras	Fase A			Fase B			Fase C		
	RMS	Fator de Pico	Valor Médio	RMS	Fator de Pico	Valor Médio	RMS	Fator de Pico	Valor Médio
802	0,6079	1,4055	0,0130	0,5673	1,4084	-0,0038	NULO	NULO	NULO
806	0,6025	1,4056	0,0129	0,5627	1,4084	-0,0037	NULO	NULO	NULO
808	0,5022	1,4069	0,0110	0,4768	1,4071	-0,0035	NULO	NULO	NULO
810	NULO	NULO	NULO	0,4767	1,4071	-0,0035	NULO	NULO	NULO
812	0,3856	1,4111	0,0081	0,3772	1,4018	-0,0042	NULO	NULO	NULO
814	0,2934	1,4138	0,0068	0,2982	1,3969	-0,0034	NULO	NULO	NULO
816	0,3096	1,4138	0,0071	0,3064	1,3968	-0,0034	NULO	NULO	NULO
818	0,3094	1,4142	0,0073	NULO	NULO	NULO	NULO	NULO	NULO
820	0,3022	1,4234	0,0120	NULO	NULO	NULO	NULO	NULO	NULO
822	0,3013	1,4247	0,0125	NULO	NULO	NULO	NULO	NULO	NULO
824	0,2718	1,4139	0,0052	0,2726	1,3942	-0,0030	NULO	NULO	NULO
826	NULO	NULO	NULO	0,2725	1,3943	-0,0030	NULO	NULO	NULO
828	0,2688	1,4142	0,0050	0,2698	1,3939	-0,0029	NULO	NULO	NULO
830	0,1955	1,4184	0,0012	0,2039	1,3833	-0,0015	NULO	NULO	NULO
832	0,1012	1,4353	-0,0075	0,1050	1,2849	0,00004	NULO	NULO	NULO
834	0,1020	1,4367	-0,0050	0,1046	1,2211	-0,0028	NULO	NULO	NULO
836	0,1021	1,4391	-0,0048	0,1046	1,2220	-0,0030	NULO	NULO	NULO
838	NULO	NULO	NULO	0,1046	1,2230	-0,0031	NULO	NULO	NULO
840	0,1021	1,4393	-0,0048	0,1046	1,2221	-0,0030	NULO	NULO	NULO
842	0,1021	1,4365	-0,0049	0,1046	1,2192	-0,0029	NULO	NULO	NULO
844	0,1022	1,4355	-0,0047	0,1045	1,2101	-0,0031	NULO	NULO	NULO
846	0,1024	1,4305	-0,0046	0,1044	1,1934	-0,0033	NULO	NULO	NULO
848	0,1024	1,4298	-0,0046	0,1043	1,1909	-0,0033	NULO	NULO	NULO
850	0,3108	1,4138	0,0072	0,3074	1,3969	-0,0035	NULO	NULO	NULO
852	0,0924	1,4353	-0,0069	0,0981	1,2850	0,0000	NULO	NULO	NULO
854	0,1937	1,4185	0,0011	0,2023	1,3828	-0,0015	NULO	NULO	NULO
856	NULO	NULO	NULO	0,2023	1,3829	-0,0013	NULO	NULO	NULO
858	0,1016	1,4375	-0,0063	0,1048	1,2564	-0,0013	NULO	NULO	NULO
860	0,1021	1,4382	-0,0049	0,1046	1,2214	-0,0029	NULO	NULO	NULO
862	0,1021	1,4391	-0,0048	0,1046	1,2221	-0,0030	NULO	NULO	NULO
864	0,1016	1,4379	-0,0063	NULO	NULO	NULO	NULO	NULO	NULO
888	0,1001	1,4899	-0,0023	0,1047	1,2993	-0,0056	NULO	NULO	NULO
890	0,0990	1,5678	0,0194	0,1091	1,3305	-0,0225	NULO	NULO	NULO

Fonte: Autoria própria

Após a exclusão das linhas, a próxima tarefa consiste em diminuir o tamanho do vetor de características analisadas. Como pode ser visto na Tabela 6.1, dependendo da natureza da fonte que originou o distúrbio, cada medidor pode transmitir pelo canal de comunicação um vetor formado por até nove características, os quais corresponde aos valores RMS, Fator de Pico e Valor Médio extraído dos distúrbios evidenciados em cada fase. Uma maior quantidade de dados analisada a cada instante aumenta o custo computacional da metodologia e consequentemente pode também influenciar na sua resposta final.

De modo a reduzir esse vetor de dado e preservar as informações úteis, para cada barra são escolhidas as características relacionadas com a fase que sentiu o distúrbio com mais intensidade, resumindo de um vetor de 9 posições para um vetor de 3 posições. Para afundamento de tensão e interrupção de tensão, adota-se a fase que possui o menor RMS; de modo contrário, para eventos de elevação de tensão seleciona-se a fase que possui maior valor RMS. A Tabela 6.2 destaca os valores de cada barra resultante da etapa de agregação das fases que é aplicada nos dados da Tabela 6.1.

Tabela 6.2 – Dados resultantes após etapa de agregação de Fase para simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicando no nó 852.

Barras	RMS	Fator de Pico	Valor Médio
802	0,567338	1,408401	-0,003764
806	0,562701	1,408394	-0,003727
808	0,476762	1,407109	-0,003521
812	0,377165	1,401800	-0,004151
814	0,293425	1,413802	0,006763
816	0,306401	1,396821	-0,003448
824	0,271847	1,413903	0,005180
828	0,268762	1,414206	0,005024
830	0,195463	1,418413	0,001178
832	0,101179	1,435322	-0,007503
834	0,102045	1,436688	-0,004974
836	0,102063	1,439145	-0,004802
840	0,102063	1,439261	-0,004794
842	0,102065	1,436509	-0,004927
844	0,102164	1,435530	-0,004706
846	0,102358	1,430545	-0,004601
848	0,102386	1,429765	-0,004585
850	0,307422	1,396875	-0,003464
852	0,092419	1,435331	-0,006855
854	0,193659	1,418523	0,001075
858	0,101561	1,437482	-0,006329
860	0,102058	1,438190	-0,004853
862	0,102063	1,439142	-0,004803
888	0,100079	1,489923	-0,002332
890	0,099038	1,567826	0,019435

Fonte: Autoria própria

Após a eliminação das barras que não determinaram o distúrbio e posteriormente o agrupamento das fases, o próximo passo consiste em delimitar as barras que compõem a região de interesse. Sendo esse um fator fundamental para eficácia do método, uma vez que segundo o estudo apresentado no Capítulo 4 ficou claro que o transformador de linha altera o padrão de propagação do distúrbio na rede de distribuição. Assim, essa etapa visa determinar se a região de interesse é composta pelas barras localizadas à jusante ou a montante do transformador de linha, garantindo uma maior caracterização da propagação do distúrbio.

A obtenção da região de interesse consiste na aplicação de uma regra simples que analisa a assimetria do conjunto de característica RMS fornecidas durante a ocorrência do distúrbio. Pela análise estatística, observou-se que quando o distúrbio é originado após o transformador os valores da característica RMS extraídas em cada nó se concentram em uma faixa maior que a média, resultando em uma assimetria muito negativa. Por outro lado, em casos onde o distúrbio é originado à montante do transformador a dispersão do conjunto RMS resultante é simétrica ou apresenta uma assimetria positiva. A partir desta heurística é possível derivar a seguinte regra:

Regra#2

Se $Assimetria_{RMS} < -0.94$ Então Região Interesse $\leftarrow (Nós[888,890])$

Se Não Região Interesse $\leftarrow (Todos\ Nós - [888,890])$

Assim de acordo com a *Regra#2*, se a Assimetria do conjunto RMS for menor que -0,94 a *Região de Interesse* é constituída pelas barras 888 e 890 (jusante do transformador). Caso contrário, a região de interesse é formada pelos nós localizados a montante, os quais no sistema IEEE 34-nós possuem o valor de tensão nominal de 24,9kV, analisando assim um outro perfil de propagação. Aplicando a *Regra#2* nos dados apresentados na Tabela 6.2, obtêm-se que a Assimetria do conjunto de característica RMS é igual à 1,2057. Como o valor calculado é maior que -0,94 logo a região de interesse é representada por todos os nós, exceto as barras 888 e 890. A Tabela 6.3 apresenta a região de interesse resultante de um curto-circuito bifásico entre a Fase A e Fase B envolvendo o nó 852.

O próximo passo da fase de tratamento e agregação dos dados consiste em normalizar os valores de cada característica que compõem a região de interesse. A normalização associa o valor de cada característica com o local que sentiu o distúrbio com mais intensidade, discriminando assim a distribuição dos valores em relação a esse nó.

Há de se considerar também que a normalização é de extrema importância em algoritmos que utilizam métricas de similaridades baseadas na distância entre dois pontos, como no caso o algoritmo *k-means*. Para este tipo de algoritmo é necessário que todos os atributos de entrada estejam na mesma escala, de modo que exista uma comparação justa entre eles.

Tabela 6.3 – Região de Interesse obtida a partir da simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicado no nó 852.

Barras	RMS	Fator de Pico	Valor Médio
802	0,567338	1,408401	-0,003764
806	0,562701	1,408394	-0,003727
808	0,476762	1,407109	-0,003521
812	0,377165	1,401800	-0,004151
814	0,293425	1,413802	0,006763
816	0,306401	1,396821	-0,003448
824	0,271847	1,413903	0,005180
828	0,268762	1,414206	0,005024
830	0,195463	1,418413	0,001178
832	0,101179	1,435322	-0,007503
834	0,102045	1,436688	-0,004974
836	0,102063	1,439145	-0,004802
840	0,102063	1,439261	-0,004794
842	0,102065	1,436509	-0,004927
844	0,102164	1,435530	-0,004706
846	0,102358	1,430545	-0,004601
848	0,102386	1,429765	-0,004585
850	0,307422	1,396875	-0,003464
852	0,092419	1,435331	-0,006855
854	0,193659	1,418523	0,001075
858	0,101561	1,437482	-0,006329
860	0,102058	1,438190	-0,004853
862	0,102063	1,439142	-0,004803

Fonte: Autoria própria

A normalização implementada tem por finalidade escalonar os dados de entrada em um intervalo entre [0,1]. O maior valor de característica fornecida pelos *smarts meters* no decorrer do tempo de ocorrência do distúrbio assumirá valor máximo igual a 1 e o menor valor de característica calculado será igual a 0. Com isto, é possível transladar os dados de modo que os elementos de entrada do sistema de clusterização apresentem sempre o mesmo intervalo. Os valores agregados das características RMS, Fator de Pico e Valor Médio são normalizados, respectivamente, por:

$$normalizacaoRMS_i = \frac{RMS_{\max} - RMS_i}{RMS_{\max} - RMS_{\min}} \quad (6.5)$$

$$normalizacaFatorPico_i = \frac{FatorPico_{\max} - FatorPico_i}{FatorPico_{\max} - FatorPico_{\min}} \quad (6.6)$$

$$normalizacaValorMédio_i = \frac{ValorMédio_{\max} - ValorMédio_i}{ValorMédio_{\max} - ValorMédio_{\min}} \quad (6.7)$$

onde, os valores máximo e mínimos são obtidos após a agregação das características fornecidas durante a ocorrência do distúrbio e i corresponde ao índice da barra normalizada.

Convém ressaltar que nesta etapa também é inserido, em cada elemento do dado agregado, um parâmetro que define a distância do nó que o medidor é instalado e a subestação. Esta característica é utilizada para auxiliar na tarefa de agrupamento. Sendo assim, os *clusters* descobertos são influenciados tanto pelos valores de características calculadas como também pela posição relativa de cada medidor. A Tabela 6.4 expõe os valores das características apresentadas na Tabela 6.1 após a fase de remoção, agregação e normalização.

Tabela 6.4 – Representação dos dados resultantes da simulação de um curto-circuito bifásico entre a Fase A e Fase B aplicando no nó 852 após os passos de remoção, agregação e normalização

Barras	RMS	Fator de Pico	Valor Médio	Distância
802	1,00000	0,27287	0,2621	0,00000
806	0,99024	0,27269	0,2647	0,00900
808	0,80928	0,24241	0,2791	0,17669
812	0,59957	0,11731	0,2350	0,37180
814	0,42324	0,40012	1,0000	0,52648
816	0,45057	0,00000	0,2843	0,52815
824	0,37781	0,40251	0,8891	0,58127
828	0,37131	0,40963	0,8781	0,60140
830	0,21697	0,50877	0,6085	0,70775
832	0,01844	0,90719	0,0000	0,90213
834	0,02027	0,93937	0,1773	0,95791
836	0,02031	0,99727	0,1893	0,98236
840	0,02031	1,00000	0,1899	0,98684
842	0,02031	0,93517	0,1806	0,95937
844	0,02052	0,91210	0,1961	0,97830
846	0,02093	0,79464	0,2034	0,99724
848	0,02099	0,77624	0,2046	1,00000
850	0,45272	0,00127	0,2832	0,52653
852	0,00000	0,90740	0,0454	0,90208
854	0,21317	0,51136	0,6013	0,71046
858	0,01925	0,95809	0,0823	0,92758
860	0,02029	0,97478	0,1857	0,96842
862	0,02031	0,99720	0,1893	0,98382

Fonte: Autoria própria

Os dados apresentados na Tabela 6.4 são submetidos como entrada do algoritmo híbrido recursivo baseado no *k-means* e em regras de decisão. Tal algoritmo é capaz de destacar as similaridades entre este conjunto de dados e apontar uma região que indica a zona de localização do distúrbio.

6.4.2 Algoritmo Híbrido Recursivo Baseado no Algoritmo *K-means* Combinado com Regras de Decisão

O algoritmo híbrido recursivo é responsável por analisar o conjunto de dados que compõem a região de interesse. Estes dados são analisados recursivamente, de modo que a cada iteração resulta em uma nova região composta pelos nós, cada vez,

mais próximos do local de origem. Essa nova região é denominada região de interesse reduzida. Uma vez que a região de interesse reduzida atende ao critério de parada, o algoritmo é finalizado e a região de interesse reduzida de saída compreende a zona que o distúrbio foi originado.

A partir da utilização deste método torna-se plausível determinar os responsáveis pela ocorrência do distúrbio e, dessa forma, possíveis normalizações poderiam ser discutidas. A Figura 6.9 apresenta o fluxograma das etapas do algoritmo recursivo.

Figura 6.9 – Diagrama de blocos do sistema de localização Híbrido Recursivo baseado no algoritmo *K-means* e Regras de decisão.

Fonte: Autoria própria.

Por conseguinte, de acordo com a Figura 6.9, o algoritmo *k-means* irá analisar os vetores das 3 características (RMS, Fator de Pico e Valor Médio) recebidas dos n medidores que compõem a região de interesse, dividindo essa região de entrada em dois grupos distintos, de acordo com o grau de similaridade entre os dados.

O algoritmo *k-means* é implementado utilizando a métrica distância euclidiana para quantificar a similaridades entre as barras. De modo complementar, para cada rotina de iteração, ele é executado 5 vezes sobre a mesma região de entrada, onde em cada execução são utilizados dois novos pontos que definem os centróides

iniciais. Desse modo, o conjunto inicial escolhido, dentre os cinco, corresponde ao que retorna o menor valor da função objetivo.

Nesse sentido, considerando que os pontos próximos à origem do distúrbio apresentam características semelhantes, presume-se que o algoritmo de agrupamento separe as barras de acordo com a região de origem do distúrbio. Logo, nós pertencentes a um mesmo *cluster* possuem padrões semelhantes entre si e diferentes dos nós que são inseridos no outro *cluster*.

Após a agrupação dos dados, torna-se possível ressaltar os padrões similares que estavam intrínsecos nos dados de entrada. Fundamentado nesse raciocínio, é possível confrontar as métricas que resumem as particularidades e validam cada *cluster*, para fim de apontar em qual grupo o nó de origem do distúrbio está localizado. O grupo escolhido corresponde a região de interesse reduzida.

Para isto, é aplicado um sistema baseado em regras de decisões, o qual faz uso de um conjunto de estruturas do tipo “se...então”, sendo capaz de inferir sobre a região de interesse reduzida por meio de regras compacta e de fácil interpretação e também expressar o conhecimento do especialista de forma bem próxima à linguagem natural.

Destaca-se também que a inferência por regras é uma etapa importante, pois de acordo com as simulações realizadas é observado que nem sempre a região de localização será composta pelos medidores que sentiram o distúrbio com mais severidade. As regras são modeladas de forma empírica conforme os objetivos que se espera alcançar. Logo, elas tendem a confrontar as características dos dados que compõem o *cluster #1* com as características dos dados que compõem o *cluster #2*.

Para padronizar e consequentemente facilitar o processo de indução das regras, o método realiza uma normatização de acordo com a distância euclidiana calculada entre os centróides dos dois *clusters* e o centróide da região de interesse de entrada, sendo essa formada pela união dos dados que compõem os *clusters*. Assim, o *cluster* que possui o valor de centróide mais próximo do centro da região de interesse será rotulado como *cluster #1*. Já o *cluster #2* é composto pelos medidores que possuem o ponto que representa o centro mais distante do centróide global.

Após a normatização, para cada um dos *clusters* são obtidas características que resumem o conjunto dos dados. Nesse sentido, apenas a dimensão relacionada com a característica RMS é levada em conta, uma vez que de acordo com a análise explanada no Capítulo 4 a distribuição dos valores de características RMS foi a que

melhor evidenciou a propagação do evento, sofrendo pouca interferência das propriedades da fonte geradora do distúrbio. Logo, os nós próximos ao local da fonte, sempre definirão o padrão de valor RMS condizente com a origem do distúrbio.

Por outro lado, as características Fator de Pico e Valor Médio são influenciadas tanto pelo local de origem do distúrbio como também pela natureza da fonte geradora e, conseqüentemente, não exprimem uma boa generalização em relação à propagação do distúrbio, tornando o processo de indução das regras mais complexo.

Assim, as métricas estatísticas média, desvio padrão, amplitude, assimetria e curtose são calculadas para os dados do conjunto de características RMS referentes às barras que compõem o *cluster#1* e o *cluster#2* e também do conjunto de dados que formam a região de interesse de entrada. Além das métricas estatísticas, são calculados para cada um dos dois *clusters* as medidas silhueta média e distância média entre todos os elementos e os pontos centróides, as quais quantificam a sua validade.

Torna-se evidente que o principal objetivo do conjunto de regras é analisar a distribuição dos dados da região de interesse de entrada, relacionando-os com a distribuição dos dados do *cluster#1* e a distribuição de dados do *cluster#2*.

Para confrontar a distribuição dos dados de cada *cluster*, as características estatísticas de cada um são representadas por variáveis categóricas e, portanto, essa categorização define qual dos dois *clusters* possui um maior valor de característica. Assim, essa categorização facilita no conjunto de regras compactas e de fácil interpretação responsável por determinar o grupo que contém a região de origem, de modo a generaliza-las para vários casos.

Como exemplo, tem-se que um determinado caso a média obtida do vetor de característica RMS do *cluster#1* (menor distância do centro) é igual a 0,5 e a média do vetor de característica RMS para o *cluster#2* (mais distante do centro) possui um valor igual 0,4. Neste caso, o *cluster#1* será rotulado como Maior_MédiaRMS e o rótulo Menor_MédiaRMS será atribuído ao *cluster#2*. Há de se convir que os valores categóricos do *cluster#2* correspondem ao inverso dos valores atribuídos ao *cluster#1*.

Em suma, para construção da base de regras, são analisadas 21 características, sendo as métricas estatísticas do *cluster#1* representada por valores categóricos, métricas extraídas da região de interesse de entrada e, por fim, os valores que avaliam cada *cluster*, ambas representadas por valores numéricos. A Tabela 6.5

resume todas as características que são calculadas, e que serão analisadas para indução do conjunto de regras de decisão.

Para facilitar a indução do conjunto de regras, optou-se por aplicar um algoritmo PART, responsável por definir as regras de forma automática a partir da análise de um conjunto de dados formados pelas características apresentadas na Tabela 6.5 e obtidos a partir das simulações que ocasionam distúrbios de VTCDs.

Tabela 6.5 – Vetor das características analisadas para induzir o conjunto de Regras de Decisão.

	Dados analisados	Característica	Métrica	Tipo
Características 1	Dados formados pela união dos <i>clusters</i> 1 e 2 (Região entrada)	RMS	Média	Numérico
Características 2			Desvio Padrão	Numérico
Características 3			Amplitude	Numérico
Características 4			Assimetria	Numérico
Características 5			Curtoses	Numérico
Características 6	Dados compõem o <i>Cluster</i> 1	RMS	Média	[Maior média Menor Média]
Características 7			Desvio Padrão	[Maior Desvio, Menor Desvio]
Características 8			Amplitude	[Maior Ampl, Menor Ampl]
Características 9			Assimetria	[Maior Assim, Menor Assim]
Características 10			Curtoses	[Maior Curt, Menor Curt]
Características 11		Silhueta		[Maior Silhueta, Menor Silhueta]
Características 12	Distância Absoluta dos elementos <i>Cluster</i> 1 em relação ao centróide do <i>cluster</i> 1			Numérico
Características 13	Distância Absoluta dos elementos <i>Cluster</i> 2 em relação ao centróide do <i>cluster</i> 2			Numérico
Características 14	Distância Média dos elementos <i>Cluster</i> 1 em relação ao centróide do <i>cluster</i> 1			Numérico
Características 15	Distância Média dos elementos <i>Cluster</i> 2 em relação ao centróide do <i>cluster</i> 2			Numérico
Características 16	Distâncias entre o centróide 1 e centróide global			Numérico
Características 17	Distâncias entre o centróide 2 e centróide global			Numérico
Características 18	Distâncias entre o centróide 1 e centróide 2			Numérico
Características 19	Silhueta média do <i>Cluster</i> 1			Numérico
Características 20	Silhueta média do <i>Cluster</i> 2			Numérico
Características 21	Silhueta média Total			Numérico

Fonte: Autoria própria

O algoritmo PART (*Partial Decision Trees*) obtém regras de decisão a partir dos nós de uma árvore de decisão que é induzida utilizando os dados analisados. Assim, a cada iteração o algoritmo PART constrói uma árvore de decisão e transforma em uma regra o caminho do nó raiz da árvore até o nó folha que melhor separa o conjunto dos dados de entrada [87]. À medida que uma regra é induzida as instâncias cobertas por esta regra são removidas, continuando a criar regras recursivamente para as instâncias restantes

Logo, o passo seguinte consiste em construir uma nova árvore a partir dos dados restantes que o nó folha anterior não conseguiu analisar. As regras são

induzidas até que todas as instâncias sejam analisadas. A saída deste algoritmo corresponde a um conjunto de regras de fácil interpretação.

A principal vantagem do algoritmo PART corresponde à sua simplicidade, uma vez que elimina a necessidade de realizar um processo de otimização para fim de escolher as melhores regras [87]. Isso é possível, pois o algoritmo PART é baseado no algoritmo j48 e, portanto, cada regra é induzida com base na análise da entropia do conjunto de dados.

A entropia é responsável por quantificar o grau de informação de um conjunto de dados com base na incerteza calculada. A incerteza está relacionada com o grau de pureza do conjunto analisado. A árvore de decisão calcula as melhores partições que retornam o melhor ganho de entropia, ou seja, o conjunto de dados com melhor grau de pureza. Portanto, ao final do PART, têm-se as melhores regras que separam os dados de entrada.

As regras induzidas por este algoritmo dependem de dois parâmetros de entrada que correspondem ao *minNumObj* e ao *ConfidenceFactor*. O primeiro define o número mínimo de instâncias por classes que irá dividir o conjunto de entrada. Isso indica que o conjunto de entrada será dividido até que cada nó da árvore responsável por definir uma regra possua um número mínimo de instâncias igual ao valor definido para o parâmetro *minNumObj* [88]. O segundo parâmetro corresponde ao fator de confiança, e define a precisão de cada regra gerada. Torna-se evidente que quanto menor o valor destes dois parâmetros, maior o conjunto de regras e melhor a resposta; entretanto, um baixo valor pode acarretar em um problema de *overfitting*. Nesse caso, o algoritmo retorna um erro pequeno na fase de indução e expõem uma alta taxa de erros para novas amostras.

Assim, para definir as regras, o algoritmo PART é aplicado em algumas simulações que ocasionam distúrbios de afundamento de tensão, elevação de tensão e interrupção de tensão. Os dados utilizados para indução das regras são obtidos a partir da análise de alguns cenários de simulações que foram modelados; logo, cada simulação utilizada para indução é resumida por meio de um vetor composto das 21 características exemplificadas na Tabela 6.5 e por um rótulo que define se o local de origem do distúrbio está presente no *cluster#1* ou no *cluster#2*, determinando assim uma classe para cada instância do conjunto.

A metodologia faz uso de um sistema específico para cada distúrbio a partir da indução de 3 bases especialistas. Sendo assim, cada base é empregada para interpretar os seguintes casos:

1. Base de Regras para Afundamento de Tensão;
2. Base de Regras para Elevação de Tensão;
3. Base de Regras para Interrupção de Tensão.

As regras que compõem cada conjunto são apresentadas no Capítulo 7. Importante destacar que, em cada caso, procurou-se induzir regras de acordo com diferentes dados das simulações. Desta forma, diferentes tipos de conjunto de treinamento e valores dos parâmetros *minNumObj* e *ConfidenceFactor* foram testados com o objetivo de obter em um conjunto de regras com capacidade de generalizar o problema de localização do distúrbio de VTCDs, evitando um *overfitting*.

Por fim, após induzidas cada conjunto de regras, a região de interesse reduzida pode ser obtida e um critério de parada define se essa região é aceitável ou não. Ele é definido de acordo com a quantidade de barras que formam a região de interesse reduzida. Caso, ela apresente um número menor ou igual a 4 barras, a região de interesse reduzida corresponde à região de localização do evento. Caso contrário, a região de interesse reduzida não é condizente e será utilizada como entrada, novamente, do algoritmo de clusterização combinado com regra de decisão, com objetivo de determinar uma região menor.

6.5 Considerações Finais do Capítulo.

O capítulo apresentou a metodologia desenvolvida que é responsável por localizar no sistema de distribuição a região de origem do distúrbio de VTCD. Para isto, ela é explanada a partir de uma ordem lógica partindo da descrição das ferramentas que abordam o aprendizado de máquinas até a descrição das etapas que constituem o método proposto.

A metodologia pode ser dividida em duas partes complementares, onde a primeira é responsável por tratar os dados advindos dos medidores inteligentes e a segunda corresponde na aplicação do algoritmo híbrido recursivo sobre os dados obtidos na primeira etapa.

O algoritmo desenvolvido segue a estratégia de “dividir para conquistar”, onde o problema maior, de apontar a região que o distúrbio está localizado, é dividido em

problemas menores que equivale em aplicar o algoritmo *k-means* para dividir os dados em dois grupos distintos, onde um deles abrange o nó de origem. Em seguida, regras de decisão são utilizadas para determinar em qual *cluster* está localizada a região de origem do distúrbio.

Todo ferramental teórico foi apresentado de modo a clarificar o algoritmo e determinar que ele pode ser utilizado para localizar a origem dos distúrbios de VTCDs. Nessa perspectiva, o Capítulo 7 é encarregado de apresentar os resultados obtidos do método proposto sobre diferentes fatores.

7 Resultados

Neste capítulo são avaliados os resultados que foram encontrados a partir da metodologia proposta. Assim, destaca-se a eficácia do algoritmo embarcado na plataforma de medição, responsável por detectar e classificar os distúrbios de VTCDs e, também, os resultados encontrados a partir da aplicação da metodologia de localização, sobre as simulações do sistema de distribuição IEEE 34-nós.

Com relação ao algoritmo embarcado, os testes foram conduzidos para fim de averiguar a sua viabilidade e confiabilidade. Neste sentido, antes de ser embarcado, o algoritmo é testado *off-line*, utilizando os sinais sintéticos obtidos por meio de equações paramétricas. A partir destes dados, torna-se possível estabelecer os valores dos parâmetros do método de detecção e induzir a estrutura de árvore que será utilizada para classificar o distúrbio. Após comprovada a eficácia do algoritmo com dados *off-line*, ele então é embarcado em hardware e a validação é feita por meio de uma bancada experimental.

É preciso ressaltar que valores definidos de cada parâmetro nos testes *off-line* são utilizados tanto no algoritmo embarcado, como também na rotina de testes responsável por averiguar a metodologia por completo.

Dessa maneira, após averiguada a eficácia do hardware, a abordagem proposta para localização pode ser validada. Para isso, uma rotina de programação desenvolvida no ambiente MATLAB é implementada, a qual é constituída de dois blocos. O primeiro emula a aplicabilidade do algoritmo de detecção e classificação para medição dos sinais de tensão provenientes das simulações no sistema IEEE 34-nós. Assim, essa etapa retorna como saída o conjunto de características que evidenciam a propagação do sinal. O segundo bloco se encarrega de aplicar a metodologia para localizar a região de origem do distúrbio, emulando as funções executadas na central de controle e operação.

Com isso, nesse capítulo são apresentados inicialmente os testes que analisam o método de detecção (Seção 7.1) e, em seguida, são apontados os testes

obtidos do sistema de classificação (Seção 7.2). Depois de obtidos os resultados para o método de detecção e classificação, a rotina de teste desenvolvida no MATLAB é contextualizada (Seção 7.3). O fechamento do capítulo parte da apresentação dos resultados obtidos a partir da implementação do sistema completo de localização da região de origem dos distúrbios de VTCDs (Seção 7.4). Por fim, são comentadas as conclusões sobre os resultados obtidos (Seção 7.5).

7.1 Resultados do Método de Detecção

A detecção dos distúrbios é realizada pela análise das características *Root Mean Square* (RMS) e Distorção Harmônica Total (DHT). Cada característica é utilizada como entrada de um bloco, responsável por determinar, a partir de uma regra de decisão, se a distância euclidiana calculada entre o parâmetro de referência e o valor de entrada se encontra dentro de um limiar de valor que caracteriza uma janela com distúrbio.

O parâmetro de referência e o limiar de cada bloco são obtidos de forma empírica de acordo com a análise da característica RMS e DHT das janelas sem distúrbios. Respectivamente, os valores definidos para o bloco 1, responsáveis por analisar a característica RMS, são 0,0375 e 0,7079 e para o bloco 2, encarregado de analisar a característica DHT, são 0,1033 e 0,0305. Depois de encontrado os valores dos parâmetros de cada bloco o método de detecção pode ser avaliado.

Desse modo, a Tabela 7.1 ilustra os resultados do método para as janelas dos sinais obtidas a partir de equações paramétricas. As janelas dos sinais são obtidas deslocando-se uma janela de dados com tamanho de um ciclo do sinal (64 pontos/ciclo) e com passo de 1 ponto em cada um dos distúrbios que compõem o banco de dados. Estes resultados são apresentados por meio de uma matriz de confusão, tendo como objetivo mostrar o número de identificações corretas em relação às esperadas.

Tabela 7.1 - Resultado da Detecção para janelas adquiridas com taxa de amostragem de 64 amostras/ciclo.

	Janela Normal	Janela com Distúrbio	Total	%
<i>Janela Normal</i>	702464	0	702464	100%
<i>Janela com Distúrbio</i>	23521	485715	509236	95,3%

Fonte: Autoria própria

Pelos resultados exibidos na Tabela 7.1, observar-se que a técnica apresentou um resultado promissor, apontando uma taxa de acerto de 100% para janelas sem distúrbios. Observa-se também que os erros são mais relevantes na situação que as janelas possuem distúrbios e, no entanto, elas são classificadas como sinais normais.

Com o intuito de melhor compreender o motivo que leva essa classificação errônea, foram realizados alguns testes utilizando somente janelas de transição. Tais janelas se caracterizam por apresentarem transição entre um sinal normal e um sinal com distúrbio. Logo, essas janelas apresentam tanto os pontos que caracterizam um sinal normal como os pontos que representam o distúrbio.

Desse modo, pretende-se analisar a taxa de acerto do método para as primeiras janelas do distúrbio, sendo que estas possuem características mais próximas das janelas normais e, conseqüentemente, os distúrbios presentes são mais difíceis de serem detectados. Assim, para as janelas que possuem taxa de amostragem de 64 amostras/ciclo, foram analisadas as janelas de transição que possuem até 63 pontos que caracterizam o distúrbio. A Figura 7.1 apresenta esses resultados em forma de um gráfico de barras, onde cada barra caracteriza a taxa de acertos de acordo com o número de pontos, evidenciando o sinal que está presente na janela.

Figura 7.1 – Desempenho do método de detecção para as janelas de transição sintéticas adquiridas sobre uma taxa de amostragem de 64 amostras/ciclo.

Fonte: Autoria própria

De acordo com os gráficos que foram apresentados na Figura 7.1, observa-se que o método de detecção tem uma baixa taxa de acerto para as primeiras janelas que caracterizam o distúrbio. Esse fato ocorre porque tais janelas apresentam características mais próximas das janelas normais, e então o método não consegue detectar o distúrbio. Adicionalmente, nota-se que o método se torna estável em relação à taxa de acertos, pois, para as janelas que possuem mais de 25 pontos que caracterizam o distúrbio, obteve-se uma taxa de acerto superior a 90%.

Após comprovada a eficácia do método utilizando distúrbios sintéticos, o algoritmo foi embarcado em hardware e os testes foram então realizados utilizando dados obtidos em laboratório. Para realização destes testes, os dados armazenados no banco de dados são repassados como entrada do equipamento DOUBLE F6150 que obtém como saída uma forma de onda real com as mesmas características dos sinais sintéticos de entrada. O distúrbio real de saída é fornecido como entrada ao *hardware*.

Para medir a eficácia do método embarcado, os resultados adquiridos pelo microcontrolador são armazenados em um cartão de memória SD, para que posteriormente eles possam ser comparados, em termos de acertos com os sinais presentes no banco de dados.

Devido à simplicidade e rapidez da metodologia de detecção proposta, cada janela do sinal capturado pelo hardware desenvolvido pode ser analisado com deslocamento de um ponto, como pode ser comprovado pela Tabela 5.2.

Desse modo, toda vez que o hardware capturar um ponto do sinal, a janela é deslocada de modo que este ponto seja adicionado ao final do vetor. E então, é realizado o cálculo para aferir se naquela janela medida possui ou não um distúrbio relacionado a VTCDs. O resultado da detecção desta janela e também o número que identifica o índice desta janela são armazenados no cartão de memória.

Seguindo a metodologia previamente apresentada, cada um dos 700 sinais que compõem a base de dados, formada de dados normais e ruidosos, foi gerado pela fonte e introduzido ao hardware. Pelos resultados observou-se que o sistema desenvolvido conseguiu detectar todos os distúrbios presentes nas 700 formas de onda, no entanto, em algumas delas o sistema não conseguiu detectar com precisão o início e o fim do distúrbio. Os percentuais de classificação correta de acordo com a quantidade de pontos que caracteriza o distúrbio presente no sinal são apresentados por meio da Figura 7.2

Figura 7.2 – Desempenho do método de detecção para as janelas de transição obtidas em laboratório adquiridas sobre uma taxa de amostragem de 64 amostras/ciclo.

Fonte: Autoria própria

Observa-se pela Figura 7.2 que o método embarcado teve comportamento semelhante ao método desenvolvido *off-line*, onde apresentou uma menor taxa de acertos para as janelas que possuem menos pontos que caracterizam o distúrbio, podendo ser considerado estável para janelas que possuem mais de 20 pontos que caracterizam o distúrbio, pois a taxa de acerto para essas janelas é superior a 90%. Com isso, conclui-se que a obtenção dos parâmetros utilizando dados sintéticos conseguiu generalizar a detecção dos distúrbios.

7.2 Resultados do Método de Classificação

Na sequência são apresentados os resultados obtidos utilizando a árvore de decisão como ferramenta de classificação. Inicialmente, a árvore de decisão é induzida e testada utilizando os dados sintéticos, ou seja, o treinamento da árvore é feito *off-line*. Após comprovada a eficácia da árvore obtida, ela é então embarcada em hardware e os testes são conduzidos para validar a metodologia utilizando todos os sinais detectados pelo algoritmo embarcado.

O processo de indução da árvore de decisão foi realizado utilizando a ferramenta computacional WEKA (*Waikato Environment Knowledge for Analysis*) fornecida pela Universidade de Waikato [70]. Para isto, é definido um conjunto de

treinamento composto pelos sinais que apresentam distúrbios sem ruído e distúrbios com níveis de relação sinal/ruído (SNR) de 45 dB, 35 dB e 20 dB.

Para cada um desses distúrbios é obtido um vetor de 4 posições, sendo composto pelas características RMS, Valor de Pico, Componente fundamental e Valor Médio e cada vetor é relacionado a um rótulo que identifica o distúrbio presente no sinal.

A partir deste procedimento é gerado o arquivo de treinamento, o qual é utilizado para realizar o processo de indução da árvore. A estrutura da árvore obtida é apresentada na Figura 7.3.

Figura 7.3 – Árvore de Decisão obtida pelo WEKA.

Fonte: Autoria própria

Pela Figura 7.3 observa-se que a partir das 4 características é possível obter uma árvore de decisão que apresenta um tamanho igual a 17 nós, sendo que 9 nós são do tipo folha. Esta estrutura pode ser facilmente implementada em hardware,

onde cada nó, não folha, corresponde a uma estrutura do tipo “se...então” e os nós folhas identificam o distúrbio.

Após o processo de indução da árvore de decisão ter sido concluído, os sinais que possuem uma relação sinal/ruído de 40 dB, 30 dB e 25 dB e que não foram utilizados no treinamento, foram empregados aos testes. Os resultados para esta etapa são apresentados de forma sumarizada na Tabela 7.2.

Tabela 7.2 - Resultado do método de Classificação para distúrbios sintéticos.

	Afundamento	Elevação	Interrupção	Total	(%)
<i>Afundamento</i>	293	0	7	300	97,66%
<i>Elevação</i>	0	300	0	300	100,00%
<i>Interrupção</i>	11	0	289	300	96,33%

Fonte: Autoria própria

Pelos resultados observados na Tabela 7.2, verifica-se que o desempenho do classificador é satisfatório. As janelas que apresentam os distúrbios de elevação foram classificadas com uma taxa de acerto de 100% e as janelas de afundamento e interrupção foram classificadas, respectivamente, com uma taxa de 97,66% e 96,33%.

A classificação errônea de algumas janelas de afundamento e interrupção de tensão está intimamente relacionada ao fato destes distúrbios possuírem características semelhantes em suas formas de onda. Assim, como já foi citado anteriormente, ambos são fenômenos caracterizados pela redução da variação de tensão, visto que as interrupções apresentam valores de tensão abaixo de 0,1 p.u. e os afundamentos constroem-se entre 0,9 p.u e 0,1 p.u., sendo que a faixa localizada em torno de 0,1 p.u. foi onde se evidenciou a contradição observada no classificador.

Visto que os resultados obtidos durante a etapa de validação foram bastante satisfatórios, os classificadores puderam então ser submetidos à etapa de validação em hardware, onde a etapa de extração de características e os classificadores foram embarcados no hardware. Assim, são utilizados os sinais identificados na fase de detecção. Os resultados obtidos para estas janelas são apresentados por meio da Tabela 7.3.

Tabela 7.3 – Resultado do método de Classificação para distúrbios obtidos em laboratório.

	Afundamento	Elevação	Interrupção	Total	(%)
<i>Afundamento</i>	293	5	2	300	97,6%
<i>Elevação</i>	0	300	0	300	100,00%
<i>Interrupção</i>	15	0	285	300	95%

Fonte: Autoria própria

Após a análise dos resultados mostrados na Tabela 7.3, novamente é possível verificar que a extração de características é promissora, visto que os classificadores apresentaram taxas de acerto maior que 95%. A alta taxa de acerto evidencia a eficácia do método, pois, foram utilizados sinais adquiridos a partir da plataforma de medição, o qual também possui erros devido à precisão de seus componentes eletrônicos e dos transdutores de efeito *Hall*.

7.3 Rotina de Testes Implementada para Validar o Método de Localização de Origem de VTCDs.

Como destacado ao longo da tese, o sistema completo pode ser concebido a partir de um sistema de monitoramento distribuído, o qual objetiva fornecer informações a respeito do distúrbio ocasionado no sistema de distribuição a partir de vários medidores instalados nos nós do sistema. As informações advindas destes medidores são agregadas na central de controle e, conseqüentemente, o método responsável por inferir o local de origem do distúrbio pode ser executado.

O algoritmo responsável por detectar e classificar o distúrbio é embarcado em hardware e os resultados comprovam sua eficácia. Sendo assim, o algoritmo de monitoramento pode ser incorporado com a abordagem proposta para localização dos distúrbios de VTCDs.

Com o intuito de averiguar o desempenho do método proposto de localização, desenvolve-se uma rotina computacional que tem como finalidade emular o algoritmo de detecção e classificação de distúrbios de VTCDs no sistema de distribuição IEEE 34-nós e, também, executar sobre os dados das simulações a metodologia de localização. Essa rotina é implementada no ambiente de programação do MATLAB® e é descrita conforme diagrama de blocos apresentado na Figura 7.4.

De acordo com a Figura 7.4, a rotina de teste dar-se início definindo, a partir do banco de dados, os parâmetros que são utilizados para executar uma simulação, a qual é implementada a partir da linguagem descritiva ATP. Este conjunto de parâmetros define as características do evento modelado como: tipo, duração, barra de origem e intensidade do distúrbio que será evidenciado. Nesta etapa, ocorre também a escolha de em quais barras os medidores são alocados.

Figura 7.4 – Diagrama de blocos que representa a rotina implementada para testes.

Fonte: Autoria própria

Com isto, o MATLAB® estabelece uma comunicação com software ATPDraw, possibilitando que uma simulação seja executada de acordo com os parâmetros de entrada definidos no MATLAB®. Assim, o método pôde ser validado em diferentes casos que originam eventos de afundamento de tensão, de elevação de tensão e de interrupção de tensão com diferentes características.

Ao fim da simulação, os sinais de tensões obtidos nas barras onde cada medidor é instalado são armazenados e importados para o MATLAB®. Em seguida, eles são utilizados como entrada do bloco que emula os medidores. Dessa maneira, ele implementa o método de detecção, a árvore de decisão e a tarefa de extração de características dos sinais detectados, por meio da execução das funções *detectar_Distúrbio*, *classificar_Distúrbio* e, adicionalmente, a função *extrair_Características*.

A saída desse bloco fornece qual evento de VTCD é detectado em cada medidor, assim como as características RMS, Fator de Pico e Valor Médio extraídas dos distúrbios.

Posteriormente, os dados de cada medidor são enviados para o último bloco que simula as funções realizadas na central de controle e operação, fornecendo como saída a região de localização do distúrbio. Nesse bloco, as características são agregadas e normalizadas por meio da função *agregar_Normalizar_Características*, obtendo a região de interesse com base na implementação das Regra#1 e Regra#2. Por fim, os dados que compõem a região de interesse são utilizados como entrada do método híbrido recursivo baseado no algoritmo *k-means* e regra de decisão.

A indução do conjunto de regra de decisão é desenvolvida também no ambiente MATLAB®, a partir de uma biblioteca Java denominada *weka.Java*, sendo disponibilizada pelo grupo de aprendizado de máquina da Universidade de *Waikato* [69]. Essa biblioteca fornece um conjunto de algoritmos de aprendizagem de máquina, cujas funções podem ser executadas no ambiente do MATLAB®.

Nesse contexto é possível chamar, a função responsável por induzir o conjunto de regras a partir de uma entrada que representa o conjunto de dados de inferência e os valores dos parâmetros de configurações do algoritmo PART (*minNumObj* e *ConfidenceFactor*). Após encontrado o conjunto de regras ótimo a sintaxe de cada regra é implementada na rotina de teste

No que se segue são discutidos os resultados obtidos a partir da execução da rotina de teste nos cenários de simulações que ocasionam distúrbios de afundamento de tensão, elevação de tensão e interrupção de tensão.

7.4 Resultados da Abordagem Proposta para Localização dos Distúrbios de Variações de Tensões de Curta Duração

A fim de comprovar a eficácia e viabilidade da metodologia proposta os resultados tendem a apresentar, em primeira instância, a importância da fase de agregação, destacando principalmente a influência da Regra#2 responsável por determinar a região de interesse.

Para concluir, apresenta-se os resultados obtidos a partir da aplicação da rotina nos dados das simulações que ocasionam eventos de afundamento de tensão, elevação de tensão e interrupção de tensão, considerando-se também, em cada caso,

a obtenção de uma base de regra compacta que consiga generalizar a propagação de cada evento de acordo com a natureza da fonte geradora.

7.4.1 Resultados Fase Agregação

A fase de agregação resulta em uma região de interesse a partir da análise do conjunto de características advindo de todos os medidores instalados no sistema, sendo esse conjunto utilizado como entrada do algoritmo híbrido recursivo baseado no *k-means* e conjunto de regras. Para isso, essa etapa irá remover dados redundantes, normalizar, agregar e por fim aplicar uma inferência (Regra#2) responsável por determinar se o distúrbio foi originado nos nós localizados a montante ou jusante do transformador de linha presente no sistema IEEE 34-nós.

Para fim de averiguar a eficácia da Regra#2 ela é aplicada sobre os 1905 casos que compõem o banco de simulações e a região de interesse inferida é analisada de modo a determinar se ela agrega o local de origem. Pela análise dos resultados observou-se que a etapa de agregação utilizando a inferência da Regra#2 determinou em apenas 34 casos uma região de interesse errônea, sendo que todos esses casos são referentes a simulação que ocasionam eventos de afundamento de tensão.

A Tabela 7.4 descreve cada um destes casos, destacando o ponto de origem do distúrbio em relação ao transformador, o ângulo de incidência, o valor da resistência e o local inferido.

A partir da Tabela 7.4, observa-se que os casos errôneos, em sua maioria, correspondem aos cenários onde o distúrbio de afundamento de tensão é originado próximo da subestação e apresentam um alto valor de resistência. Destaca-se que nessas condições o distúrbio é propagado com características semelhantes em todos os nós, sendo que tal fato dificulta a descoberta de uma fronteira linear estabelecida pelo parâmetro limiar (-0,94) empregado na Regra#2. Todavia, os casos de erros correspondem apenas 1,78% do total de situações analisadas, logo conclui-se que a fronteira delimitada pela regra consegue uma boa generalização.

Tabela 7.4 – Casos de simulação errôneas detectados na fase de agregação.

Nó de Origem (Local em Relação Transformador)	Valor da Resistencia de Curto-Circuito (Ω)	Ângulo Incidência	Local Inferido
802 (Montante)	40	0°	Jusante
806 (Montante)	40	0°	Jusante
802 (Montante)	50	0°	Jusante
806 (Montante)	50	0°	Jusante
802 (Montante)	40	90°	Jusante
806 (Montante)	40	90°	Jusante
802 (Montante)	50	90°	Jusante
806 (Montante)	50	90°	Jusante
802 (Montante)	30	0°	Jusante
806 (Montante)	30	0°	Jusante
802 (Montante)	40	0°	Jusante
806 (Montante)	40	0°	Jusante
802 (Montante)	50	0°	Jusante
806 (Montante)	50	0°	Jusante
802 (Montante)	20	90°	Jusante
802 (Montante)	30	90°	Jusante
806 (Montante)	30	90°	Jusante
802 (Montante)	40	90°	Jusante
806 (Montante)	40	90°	Jusante
802 (Montante)	50	90°	Jusante
806 (Montante)	50	90°	Jusante
802 (Montante)	40	0°	Jusante
806 (Montante)	40	0°	Jusante
802 (Montante)	50	0°	Jusante
806 (Montante)	50	0°	Jusante
802 (Montante)	30	90°	Jusante
802 (Montante)	40	90°	Jusante
806 (Montante)	40	0°	Jusante
802 (Montante)	50	0°	Jusante
806 (Montante)	50	0°	Jusante
888 (Jusante)	20	0°	Montante
888 (Jusante)	10	90°	Montante
888 (Jusante)	20	90°	Montante
888 (Jusante)	30	90°	Montante

Fonte: Autoria própria.

Considerando-se que a região de interesse simplifica o conjunto de dados advindos dos medidores inteligentes, faz-se necessário, além de determinar sua eficácia, também averiguar sua influência em relação a resposta final e complexidade do método.

Para analisar tal situação duas rotinas de testes são implementadas, onde a Rotina#1 configura-se por não implementar a Regra#2 na fase de agregação. Por sua vez a Rotina#2 executa a Regra#2. Dessa forma é possível mensurar a importância dessa regra sobre os resultados do algoritmo híbrido recursivo tanto em termos de acerto, como também em termos do tamanho do conjunto de regras.

Importante comentar que em ambas as rotinas foram utilizados o mesmo conjunto de treinamento e de teste e a base de regras é induzida utilizando os valores

0,2 e 2 para os parâmetros *minNumObj* e *ConfidenceFactor* que correspondem aos valores padronizados pelo WEKA. Logo, a resposta de ambos os testes é influenciada somente pelos dados de entrada, determinados na fase de agregação. A Tabela 7.5 descreve os resultados encontrados para as duas rotinas de testes confrontando o número de regras e a taxa de acertos em cada um destes casos.

Tabela 7.5 –Comparação entre a taxa de acerto e número de regras para Rotina#1 e Rotina#2.

Base Analisada	Número de Regras (Rotina#1)	Número de Regras (Rotina#2)	Acertos (Rotina#1)	Acertos (Rotina#2)
Afundamento de Tensão	70	56	85,25%	90,98%
Interrupção de Tensão	2	2	100,0%	100,0%
Elevação de Tensão	9	12	40,00%	60,00%

Fonte: Autoria própria.

Como pode ser observado pela Tabela 7.5 os resultados demonstram que a Rotina#2 que implementa a Regra#2 possui, em alguns casos, uma menor quantidade de regras e, apesar disso, consegue uma acurácia melhor que a Rotina#1. Fica claro que a Regra#2 determina uma região de interesse composta por dados que melhor representam a propagação do distúrbio, tornando mais fácil a descoberta de clusters e obtenção de um conjunto de regras menor.

7.4.2 Resultados do Método de Localização dos Distúrbios para Eventos de Afundamento de Tensão

Nesta seção são destacados os resultados computacionais obtidos, para as simulações que originam afundamento de tensão. A base de dados para teste se constitui dos casos de simulação que ocasionam afundamento de tensão, sendo formada por: 1) simulações de curto-circuito trifásico 2) simulações de curto-circuito bifásico 3) simulações de curto-circuito monofásico, onde, para cada tipo, variou-se a resistência entre os valores 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω e o ângulo de incidência entre os valores 0° e 90°. Esses dados são divididos em dois conjuntos, sendo o primeiro responsável por realizar a indução do conjunto de regras e outro é utilizado para testar a metodologia.

O treinamento da regra de decisão foi desenvolvido no ambiente MATLAB®, a partir de uma biblioteca Java denominada *weka.Java*, sendo disponibilizada pelo grupo de aprendizado de máquina da Universidade de Waikato [70]. Essa biblioteca

fornece um conjunto de algoritmos de aprendizagem de máquina, cujas funções podem ser executadas no ambiente do MATLAB.

Nesse contexto, é possível chamar a função responsável por induzir o conjunto de regras a partir de uma entrada que representa o conjunto de treinamento e os parâmetros de configurações do algoritmo PART.

Desse modo, o conjunto de regras é construído a partir da análise de 80% dos casos que compõem o banco de dados da simulação. Os 20% restantes são utilizados para testar a metodologia e, portanto, não são utilizados no treinamento. Ao total, são 1830 casos de simulação que ocasionam afundamento de tensão, sendo aproximadamente 1464 casos utilizados para indução das regras e 366 casos são aplicados para validar e generalizar a metodologia.

O próximo passo consiste em avaliar qual o melhor valor dos parâmetros *minNumObj* e *ConfidenceFactor* que alcançam uma boa generalização das soluções para o conjunto de teste. A biblioteca do WEKA determina como padrão que os valores destes dois parâmetros sejam respectivamente 0,25 e 2.

Na busca para encontrar um conjunto de regras mais simples e que retornem uma boa taxa de acertos, esses valores são progressivamente alterados e os resultados de cada novo conjunto de regra induzido são avaliados em termos da quantidade de regras e também da taxa de acerto.

Na medida que foram testados diferentes valores desses dois parâmetros é possível determinar que o valor do parâmetro *minNumObj* influencia significativamente a acurácia do método e também a quantidade de regras induzidas, sendo que o valor do parâmetro *ConfidenceFactor* refina a taxa de acerto.

Diante de tal situação, a Tabela 7.6 confronta o número de regras, a taxa de acerto do conjunto de treinamento e a taxa de acertos do conjunto de testes, obtidos para cada variação do parâmetro *minNumObj*.

Dentre os testes apresentados na Tabela 7.6, observa-se que ao aumentar o valor do parâmetro *minNumObj*, tanto a acurácia obtida para o conjunto de treinamento como também o número de regras diminui. Entretanto, fica claro que em alguns casos mesmo utilizando um conjunto de regras reduzido a taxa de acertos para o conjunto de testes continua estável. Portanto, nessa situação é lícito afirmar que as regras induzidas conseguem generalizar o problema.

Tabela 7.6 – Desempenho da Regra de Decisão para simulação de afundamento de tensão em relação ao parâmetro *minNumObj* utilizando 80% dos casos para treinamento.

Teste	<i>minNumObj</i>	<i>ConfidenceFactor</i>	Número de regras	Acertos Treinamento	Acertos Testes
1	2	0,2	56	99,66%	90,98%
2	3	0,1	49	99,39%	89,62%
3	4	0,15	41	99,12%	89,07%
4	5	0,2	35	99,46%	89,89%
5	6	0,3	37	98,58%	85,52%
6	7	0,35	33	98,99%	90,71%
7	8	0,2	30	98,58%	86,61%
8	9	0,45	25	98,65%	86,07%
9	10	0,3	24	98,52%	87,70%
10	11	0,2	27	98,45%	86,34%
11	12	0,2	24	97,91%	86,61%
12	13	0,4	25	98,25%	87,43%
13	14	0,2	21	98,18%	84,97%
14	15	0,25	18	98,04%	86,61%
15	16	0,2	18	98,02%	86,61%
16	17	0,2	22	98,22%	88,25%
17	18	0,2	13	97,75%	85,25%
18	19	0,2	13	97,75%	85,79%
19	20	0,2	15	97,75%	85,25%

Fonte: Autoria própria.

Para implementação da rotina de testes assume-se os valores dos parâmetros utilizados no Teste#16, pois foi o que alcançou o melhor equilíbrio entre a quantidade de regras e a taxa de acertos. A sintaxe de cada regra obtida é apresentada na Tabela 7.7.

A partir da implementação dessas regras na rotina de testes, pode-se descrever, em função do conjunto de teste, que a metodologia proposta fornece em 323 casos uma região reduzida de saída condizente com o local de origem do distúrbio de afundamento de tensão. Em contrapartida, cerca de 43 casos de testes a resposta do sistema aponta uma região diferente do local de origem.

De acordo com os resultados errôneos, observou-se que em 7 casos o erro da localização ocorre na fase de agregação e tratamento dos dados, onde a Regra#2 define uma região de interesse composta por barras que não abrange o local da falta. A Tabela 7.8 descreve cada um destes casos, destacando o ponto de origem do distúrbio, o tipo do curto-circuito, a resistência, a intensidade da falta e as barras que formam a região reduzida de saída.

Tabela 7.7 –Base de Regras para localização dos distúrbios de Afundamento de Tensão induzida a partir dos parâmetros definidos no Teste#16

Número	<Antecedente>		Consequente
1	Distância elementos cluster#2 ao centróide2 > 8,060 E Distância elementos cluster#1 ao centróide1 <= 2,0071	Então	Escolher Cluster 2
2	Média RMS Cluster#1 = Menor média RMS E Desvio Padrão RMS região entrada> 0,224678 E Assimetria RMS região entrada> 0,660569 E Curtoses RMS região entrada<= 6,799729	Então	Escolher Cluster 1
3	Silhueta média Cluster#1 > 0,474879 E Rótulo Média RMS Cluster#1= Maior média RMS E Assimetria RMS região entrada<= 1,917083 E Distância elementos cluster#2 ao centróide2 > 0,351901	Então	Escolher Cluster 2
4	Distância elementos cluster#1 ao centróide1 <= 10,08 E Curtoses RMS região entrada> 1,17279 E Media RMS região entrada <= 0,445992	Então	Escolher cluster 2
5	Distância elementos cluster#1 ao centróide1<= 10,088 E Assimetria RMS região entrada> 1,853632 E Distância elementos cluster#2 ao centróide2<= 2,01186	Então	Escolher Cluster 1
6	Distância elementos cluster#1 ao centróide1<= 10,088 E Distância média elementos Cluster#1 Centro1 > 0,6852 E silhueta Média Cluster2 > 0,973809	Então	Escolher Cluster 1
7	Distância elementos cluster#1 ao centróide1 <= 10,0884 E Rótulo Média RMS Cluster#1= Maior média RMS E Curtoses RMS região entrada > 2,356284 E silhueta média Total > 0,643452	Então	Escolher Cluster 2
8	Distância elementos cluster#1 ao centróide1 <= 8,82863 E Dist. entre Centróide#2 centróide global<= 1,423 E Assimetria RMS região entrada<= -1,05574 E Rotulo Cluster1 silhueta = Menor Silhueta	Então	Escolher Cluster 1
9	Distância elementos cluster#1 ao centróide1 <= 8,828634 E Dist. entre Centróide#2 e centróide global<= 1,42 E Distância elementos cluster#2 ao centróide2> 0,754754 E Rotulo Cluster1 Amplitude RMS = Maior Amplitude E Desvio Padrão RMS região entrada<= 0,413668 E Media RMS região entrada <= 0,628849	Então	Escolher Cluster 2
10	Distância elementos cluster#1 ao centróide1 > 8,828634	Então	Escolher Cluster 1
11	Dist. entre Centróide#2 e centróide global 1,3895	Então	Escolher Cluster 1

Número	<Antecedente>		Consequente
12	Distância média elementos Cluster#1 Centro1 $\leq 0,97144$ E Distância elementos cluster#2 ao centróide2 $\leq 0,117238$ E Assimetria RMS região entrada $\leq 0,543046$	Então	Escolher Cluster 2
13	Dist. média elementos Cluster#1 Centróide1 $\leq 0,97145$ E Distância elementos cluster#2 ao centróide2 $\leq 2,097673$ E Media RMS região entrada $> 0,344645$ E Distância elementos cluster#2 ao centróide2 $\leq 0,262088$	Então	Escolher Cluster 1
14	Rótulo Média RMS Cluster#1= Menor média RMS E Assimetria RMS região entrada $> -0,699235$ E Rotulo Cluster1 Amplitude RMS=Cluster1_maiorRange_RMS	Então	Escolher Cluster 1
15	Dist. média elementos Cluster#1 Centróide1 $\leq 0,93844$ E Desvio Padrão RMS região entrada $\leq 0,255635$ E Distância Centróide#1 e centróide global $> 0,094063$	Então	Escolher Cluster 1
16	Dist. média elementos Cluster#1 Centróide1 $\leq 0,93844$ E Rotulo Cluster1 silhueta = Cluster1_maiorSilhueta E Dist entre Centróide#2 e centróide global $> 0,6726$ E Rotulo Cluster1 Amplitude RMS= Menor Amplitude RMS E Dist. média elementos Cluster#2 Centróide2 $\leq 0,800668$	Então	Escolher Cluster 2
17	Dist. média elementos Cluster#1 Centróide1 $\leq 0,93844$ E Rotulo Assimetria RMS = Maior Assimetria RMS E Assimetria RMS região entrada $\leq 1,358259$	Então	Escolher Cluster 2
18	Dist. média elementos Cluster#1 Centróide1 $\leq 0,93844$ E Rotulo Cluster1 silhueta = Menor Silhueta E silhueta média Total $\leq 0,537732$	Então	Escolher Cluster 1
19	Assimetria RMS região entrada $\leq -0,201398$ E Curtoses RMS região entrada $\leq 1,858512$	Então	Escolher Cluster 2
20	Dist. entre Centróide#2 e centróide global $> 0,672$ E Rotulo Cluster1 Amplitude RMS = Menor Amplitude RMS	Então	Escolher Cluster 1
21	Dist. média elementos Cluster#1 Centróide1 $> 0,589142$	Então	Escolher Cluster 1
22	Se Não	Então	Escolher Cluster 2

Fonte: Autoria própria

Tabela 7.8 – Casos de simulação com erro.

Nó de Origem	Tipo do Curto-circuito	Valor da Resistencia de Curto-Circuito (Ω)	Região Reduzida de Saída
802	Monofásico Fase B	40	[888,890]
806	Monofásico Fase B	40	[888,890]
802	Monofásico Fase C	50	[888,890]
806	Monofásico Fase C	50	[888,890]
888	Monofásico Fase C	20	[814,816,824,828]
802	Bifásico Fase BC	40	[888,890]
806	Bifásico Fase BC	40	[888,890]

Fonte: Autoria própria.

Outro fato importante de analisar com base nas respostas fornecidas pelo método é se a distância estimada pelo método nos casos errôneos é próxima do local de aplicação da falta. A Figura 7.5, Figura 7.6 e Figura 7.7 realizam uma comparação, por meio de um gráfico de barras, dos valores de distâncias esperados com o valor de distância estimado pela região de saída obtidas, respectivamente, para os casos de curto-circuito Trifásico, Bifásico e Monofásico. Destaca-se que a distância estimada é calculada a partir da média das distâncias das barras que compõem a região de saída.

Figura 7.5 – Comparação dos valores de distâncias estimadas com a distância esperada para curto-circuito trifásico.

Fonte: Autoria própria.

Figura 7.6 – Comparação dos valores de distâncias estimadas com a distância esperada para curto-circuito monofásico na Fase A (a), Fase B(b) e Fase C(c).

(a)

(b)

(c)

Fonte: Autoria própria.

Figura 7.7– Comparação dos valores de distâncias estimadas com a distância esperada para curto-circuito Bifásico na Fase AB (a), Fase AC(b) e Fase BC(c).

Fonte: Autoria própria.

Os gráficos apresentados na Figura 7.5, Figura 7.6 e Figura 7.7 destacam que a metodologia proposta estima na maioria dos casos errôneos uma distância bem

próxima do local da falta. O maior erro é observado nos casos onde o curto-circuito está localizado nas barras próximas a subestação, o qual representa uma região mais robusta do sistema, resultando um comportamento em termos de propagação do distúrbio bastante discrepante quando comparado com os demais casos.

Os resultados ilustram que é possível obter uma metodologia para localizar os distúrbios de afundamento de tensão por meio de regras que são induzidas por um conjunto formado por 80% dos casos de simulação. Com isto, o sistema completo é capaz de mapear o padrão dos *clusters*, destacando o nó de origem do distúrbio.

7.4.3 Resultados do Método de Localização dos Distúrbios para Eventos de Interrupção de Tensão

Esta análise consiste em investigar a resposta do método de localização para os distúrbios de interrupção de tensão. Para isto, são considerados os casos de simulação de curto-circuito trifásicos com resistência de $1\ \Omega$. Assim, 80% destes casos são utilizados para indução das regras e 20% são utilizados para verificar a capacidade de generalização da metodologia. Diante dessa nova composição de dados, o conjunto de regras específico para analisar os distúrbios de interrupção de tensão foi induzido de forma a obter resultados com alta taxa de acertos. Para tanto, foi observado que, independentemente dos valores dos parâmetros *minNumObj* e *ConfidenceFactor*, o conjunto de regras induzidas é formado sempre por duas regras, as quais são apresentadas na Tabela 7.9.

Tabela 7.9 –Base de Regras induzida para localização dos distúrbios de Interrupção de Tensão.

Número	<Antecedente>		<Consequente>
1	Se <i>MédiaRMSCluster1</i> = Menor Média RMS	Então	Escolher <i>Cluster 1</i>
2	Se não	Então	Escolher <i>Cluster 2</i>

Fonte: Autoria própria

Como pode ser observado na Tabela 7.9 o conjunto de regras determina que o cluster escolhido será sempre aquele que apresentar menor média da característica RMS. Diante de tal situação, pode-se concluir que quando o curto-circuito apresenta um valor de resistência muito baixo, o distúrbio é propagado com características diferentes ao longo do sistema de distribuição, sendo que nos nós localizados próximos da origem do distúrbio, o mesmo é evidenciado de forma mais severa, ou seja, com baixo valor RMS.

Assim, os dois clusters que são induzidos em cada simulação que provoca distúrbio de interrupção de tensão apresentam padrões opostos e, portanto, torna-se mais fácil determinar qual deles abrange a região de origem. Nesse sentido, os testes para a localização desses eventos apresentaram uma taxa de acerto igual a 100%.

7.4.4 Resultados do Método de Localização dos Distúrbios para Eventos de Elevação de Tensão

Esta análise visa detalhar a resposta da metodologia de localização de distúrbios de VTCDs para identificar o ponto de origem do distúrbio de elevação de tensão. Neste contexto, considera-se para testes as simulações que modelam a comutação de banco de capacitores constituindo uma base de dados de 25 casos, onde em cada simulação altera-se o local de origem do distúrbio de elevação, sendo aplicado em todas as barras trifásicas do sistema.

Com relação a esta base de dados, nota-se que existe somente um padrão por local de aplicação e, portanto, não fornece uma quantidade razoável de padrões para que se alcance uma boa generalização do método.

De forma a aumentar a quantidade de padrões, adotou-se a estratégia de dividir os sinais trifásicos, onde em cada simulação são retornados 3 padrões, sendo um por fase. Isso é possível, pois distúrbio de elevação de tensão é evidenciado nas três fases. Dessa forma, os 25 casos de testes são desmembrados em 75 casos. Adicionalmente, como o sistema é desbalanceado, cada caso constitui um novo padrão de análise.

O conjunto de treinamento e teste analisado nesta etapa apresenta a seguinte configuração: 50 são empregados para indução das regras, sendo formados pelos distúrbios evidenciados nas fases A e B; 25 casos referentes aos distúrbios evidenciados na fase C são utilizados para testar a metodologia. Os detalhes do desempenho de cada regra de acordo com os valores dos parâmetros *minNumObj* e *ConfidenceFactor* são apresentados na Tabela 7.10.

Tabela 7.10 – Desempenho da Regra de Decisão de acordo com o valor do parâmetro *minNumObj* e *ConfidenceFactor* para localização dos eventos de Elevação de Tensão.

Teste	<i>minNumObj</i>	<i>ConfidenceFactor</i>	Número de regras	Acertos Treinamento	Acertos Teste(%)
1	2	0,2	11	100,0%	60,00%
2	3	0,2	8	93,6%	60,00%
3	4	0,2	7	77,9%	84,00%
4	5	0,2	7	78,0%	84,00%
5	6	0,15	6	74,0%	64,00%
6	7	0,3	8	82,0%	76,00%
7	8	0,15	6	72,0%	56,00%
8	9	0,25	6	72,0%	56,00%
9	10	0,25	4	66,0%	80,00%
10	11	0,15	4	66,0%	80,00%
11	12	0,2	4	66,0%	80,00%
12	13	0,2	4	66,0%	80,00%
13	14	0,4	5	76,0%	68,00%
14	15	0,2	4	62,0%	80,00%
15	16	0,1	4	62,0%	40,00%

Fonte: Autoria própria.

De acordo com a Tabela 7.10 observa-se que quanto maior o valor do parâmetro *minNumObj* menor a taxa de acerto para o conjunto de treinamento. Observa-se que alguns casos, apesar da alta taxa de acertos do conjunto de treinamento, o conjunto de regras induzido não foi capaz de mapear os dados que compõem o conjunto de teste. Nesse sentido, escolheu os parâmetros determinados no Teste#3, uma vez que o conjunto de regras induzidos nesse teste foi o que melhor generalizou os dados que compõem o conjunto de teste e, também, apresenta um resultado satisfatório para o conjunto de treinamento. A sintaxe de cada regra obtida por meio dos parâmetros definidos no Teste#3 é apresentada na Tabela 7.11.

Tabela 7.11 –Base de Regras induzida no Teste#3

Número	<Antecedente>		<Consequente>
1	Se <i>MédiaRMSCluster1</i> = Menor Média RMS E <i>Silhueta média Cluster#1</i> > 0,354071	Então	Escolher <i>Cluster 2</i>
2	<i>DistânciaAbsolutaElementosCluster1</i> = MaiorDistância	Então	Escolher <i>Cluster 1</i>
3	<i>Distâncias centróide 1 centróide global</i> > 0,524687	Então	Escolher <i>Cluster 1</i>
4	<i>DesvioRMSCluster1</i> = Menor Desvio E <i>DistânciaMediaCluster1_Centro1</i> <= 0,139835	Então	Escolher <i>cluster 2</i>
5	<i>DesvioRMSCluster1</i> = Menor Desvio	Então	Escolher <i>Cluster 2</i>
6	<i>Distâncias centróide 1 centróide global</i> <= 0,256829	Então	Escolher <i>Cluster 2</i>
7	Se Não	Então	Escolher <i>Cluster 1</i>

Fonte: Autoria própria

Implementando a rotina de teste a partir das regras obtidas no Test#3 obtêm-se um erro em apenas 4 cenários de simulação. Para melhor elucidar os resultados errôneos, a Tabela 7.12 descreve cada um destes casos, destacando nas duas primeiras colunas o ponto de origem do distúrbio e as barras que formam a região reduzida de saída. As duas últimas colunas da tabela comparam a distância do ponto de origem do distúrbio com a distância média calculada das barras que compõem a região sensibilizada reduzida.

Tabela 7.12 – Instancias errôneas para localização dos eventos de Elevação de Tensão.

Origem do Distúrbio	Região de Saída	Distância Origem em Relação Subestação (km)	Distância Média (km)
812	[832 852 858]	36,37	87,07
814	[816 850]	50,86	51,02
834	[836 840 844]	91,57	93,82
842	[844 846 848]	91,73	94,79

Fonte: Autoria própria

De acordo com a Tabela 7.12 observa-se que, embora a região de saída não agregue o local exato de origem, na maioria dos casos o método estima uma distância próxima do local de origem do distúrbio. Assim como ocorre nos casos de afundamento de tensão e interrupção de tensão os maiores erros são encontrados nos distúrbios originados nos nós próximos da subestação, uma vez que para este caso o distúrbio de elevação de tensão é propagado com padrões semelhantes em todo o sistema, dificultando a tomada de decisões por meio das regras.

7.5 Considerações Finais do Capítulo

O trabalho apresentado nessa tese tem como objetivo principal apresentar um método para localização da origem dos eventos de VTCDs. Para tanto, esse capítulo apresentou os resultados obtidos a partir da utilização de tal abordagem.

Assim, o método proposto é concebido a partir de uma infraestrutura de medição distribuída e, portanto, fez-se necessário desenvolver uma arquitetura de medição capaz de detectar os distúrbios de afundamento de tensão, elevação de tensão e interrupção de tensão. Os testes em hardware apresentaram que o método embarcado conseguiu uma taxa de acerto acima de 95%. Os resultados observados podem ser considerados relevantes, uma vez que o hardware foi testado com uma base de dados heterogênea que é composta tanto de sinais normais como também de sinais com ruído. Os medidores oferecem baixo custo e alta precisão na detecção

e classificação de distúrbios e permite a troca de dados com a utilidade. Por último, deve salientar-se que a utilização do TI-RTOS permitiu a coordenação das tarefas realizadas pelo medidor inteligente.

Os dados provenientes por esses medidores podem então ser utilizados para implementar o sistema responsável por localizar os distúrbios de VTCDs. Devido à impossibilidade de se obter dados de um sistema de distribuição real, uma rotina de teste foi então implementada para fim de validar o método de localização.

Tal rotina emula tanto as tarefas executadas pelos medidores como também as tarefas que são executadas na central de controle de operação. Os dados utilizados para validar a metodologia correspondem aos cenários de simulações que foram modelados no Sistema IEEE 34-nós.

Pelos resultados, a metodologia conseguiu uma taxa de acerto acima de 80% para os três tipos de distúrbios analisados que são: afundamento de tensão, elevação de tensão e interrupção de tensão. Os erros encontrados foram principalmente em relação aos eventos de afundamento de tensão. Em alguns casos esses eventos se propagam no sistema com características bastante semelhantes o que dificulta a abordagem analisada, visto que ela é baseada na similaridade entre os distúrbios medidos em vários nós do sistema de distribuição.

8 Considerações Finais

O objetivo deste capítulo é apresentar as conclusões finais do trabalho e também as perspectivas para trabalhos futuros que possam ser realizados a partir da utilização dos equipamentos e métodos que foram discutidos na tese.

8.1 Conclusões

Uma vez presentes no sistema de distribuição, os distúrbios de VTCDs podem acarretar problemas tanto para o consumidor final como também para a concessionária de energia. Logo, o desenvolvimento de metodologias para localizar a origem destes distúrbios na rede de distribuição corresponde a um ponto importante para garantir uma boa qualidade de energia da rede.

Assim, procurou-se, por meio de um breve apanhado das publicações citadas, apresentar uma síntese das mais significativas que auxiliam no desenvolvimento desta pesquisa. Pelo exposto, verificou-se que esta linha de pesquisa tem despertado um grande interesse na comunidade técnico-científica pelo fato desses distúrbios serem dos mais importantes no contexto da QEE, devido principalmente à sua frequência de ocorrência.

O problema de localização é complexo, visto que estes distúrbios são evidenciados em um curto intervalo de tempo e disseminados com características iguais ao longo do sistema de distribuição. Para contornar tais problemas, grandes avanços podem ser alcançados a partir da utilização da estrutura de comunicação provida pelas redes *smart grids*.

Assim, a partir da estrutura de comunicação das redes *smart grids* torna-se possível realizar o monitoramento dos sistemas de distribuição em tempo real em vários pontos do sistema. De acordo com este contexto, o distúrbio evidenciado em um ponto pode ser medido em vários nós do sistema, originando dados importantes que podem ser utilizados para inferir o local de origem do distúrbio.

Fundamentado nessa abordagem, essa tese apresentou uma metodologia responsável por apontar o local de origem do distúrbio de VTCD a partir da aplicação de um método recursivo baseado no algoritmo *k-means* combinado com um conjunto de regras de decisão sobre os dados advindos da tecnologia de medição distribuída providas das redes *smart grids*.

Para isto, primeiro comprovou-se por meio de medidas estatísticas e ferramentas de visualização de dados que as características RMS, Valor de Pico, Fator de Pico e Valor Médio extraídas do distúrbio detectado no sistema de distribuição conseguem evidenciar o padrão de propagação do evento, sendo possível obter heurísticas importantes para confecção da metodologia proposta.

Posteriormente, a aplicação do algoritmo recursivo híbrido só é possível mediante a utilização de medidor que consiga detectar e classificar o distúrbio na rede de distribuição e fornecer informações sobre eles por meio de um canal de comunicação. Assim, foi necessário averiguar uma plataforma de medição com essas características.

O desenvolvimento foi realizado utilizando um sistema operacional de tempo real fornecido pela *Texas Instruments*, denominado TI-RTOS. Com isso, permitiu-se que prioridades fossem estabelecidas. As tarefas de aquisição e detecção dos sinais têm prioridade alta e, por sua vez, a classificação, comunicação e envio da informação têm menor prioridade.

Neste sentido, a arquitetura desenvolvida pode ser aplicada sobre o contexto das redes *smart grids*, visto que é possível implementar um código que detecte e classifique o distúrbio, garantindo que as análises sejam feitas a cada deslocamento da janela que possui passo de 1 ponto e tamanho de 1 ciclo. Adicionalmente, as características dos distúrbios classificados podem ser enviadas por meio de um canal de comunicação

Pelos resultados obtidos, pôde-se constatar que o desempenho do hardware foi considerado relevante para a análise da Qualidade de Energia, já que o medidor desenvolvido oferece um baixo custo e alta precisão na detecção e classificação de distúrbios e permite a troca de dados com a concessionária. Por último, deve salientar-se que a utilização do TI-RTOS permitiu a coordenação das tarefas realizadas pelo medidor inteligente.

Após comprovada a eficácia do algoritmo de detecção e classificação embarcado em hardware, o sistema de localização das fontes causadoras de VTCDs

foi idealizado. Nesse caso, a metodologia visou inferir sobre os padrões das características advindos dos *smart meters*, de modo a relacionar os objetos de entrada a uma provável localização da fonte causadora de VTCDs.

A abordagem foi desenvolvida sobre duas etapas complementares. A primeira foi responsável por agregar, normalizar e tratar os vetores de características advindos dos medidores inteligentes. A segunda fez uso de um algoritmo que utiliza ferramentas de aprendizado de máquinas para determinar uma região de localização. Especificamente, o algoritmo utiliza uma estratégia de dividir para conquistar, onde o problema maior de apontar o local de origem é dividido em problemas menores que corresponde em dividir os dados em dois grupos e apontar qual deles abrange o local da origem.

O algoritmo *k-means* foi utilizado para analisar o conjunto de características fornecidas pelos medidores, de modo a agrupá-las, de acordo com as similaridades em dois conjuntos, sendo que um deles abrange o local de falta.

A grande vantagem de aplicar o *k-means* é que ele corresponde à abordagem não supervisionada e, portanto, consegue explorar dados não rotulados, onde a escolha dos *clusters* será influenciada somente pelos dados fornecidos no instante de tempo, tornando possível destacar dois grupos distintos.

Por sua vez, regras de decisão foram utilizadas para inferir sobre as características dos dois grupos e apontar em qual deles está localizado o local de origem do distúrbio.

Por fim, uma rotina de testes é implementada para medir a eficácia do sistema completo, sendo este validado sobre diferentes cenários de simulações que ocasionam distúrbios de afundamento de tensão, elevação de tensão e interrupção de tensão.

Os resultados que foram obtidos comprovam que o sistema conseguiu apontar o local de origem do evento de maneira satisfatória, mesmo em situações onde a propagação do distúrbio é menos evidente, como por exemplo, nos cenários onde a origem do evento está próxima da subestação. Adicionalmente, a análise é feita somente com os dados de tensão, não sendo averiguada qualquer outra informação do sistema; logo a metodologia é bem compacta.

8.2 *Trabalhos Futuros*

As diretrizes de trabalhos futuros desta pesquisa consistem em explorar o hardware desenvolvido por meio de um sistema operacional de tempo real e também aprimorar a metodologia proposta para localização dos distúrbios de VTCDs. Nesse contexto, os seguintes tópicos são sugeridos para a continuidade da pesquisa:

- Desenvolver e testar novos métodos que possam ser embarcados no hardware construído, visando sua aplicação em diferentes problemas.
- Averiguar outras características que sejam relevantes à localização da origem dos distúrbios de VTCDs.
- Testar a metodologia proposta em um sistema elétrico real.
- Analisar o efeito da geração distribuída sobre o método de localização dos distúrbios de VTCDs.
- Analisar o comportamento da técnica de localização em termos de equilíbrio entre o número de medidores utilizados.
- Analisar outros algoritmos de agrupamento a serem empregados para agrupar as características advindas dos *smart meters*, de modo a escolher o algoritmo que melhor destaque a propagação do distúrbio, agrupando-se os medidores de maneira correta.

Referências

- [1] R. C. Dugan, M. F. Mc Granagh, S. Santoso, e H. W. Beaty, *Electrical Power Systems Quality*, 3rd ed. New York, 2002.
- [2] D. Committee, *IEEE Std 1159™-2009, IEEE Recommended Practice for Monitoring Electric Power Quality*, vol. 2009, no. June. IEEE, 2009.
- [3] ANEEL, “PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) – Módulo 8: Qualidade da Energia Elétrica.” pp. 1–69, 2012.
- [4] F. C. V. Malange, “Rede Neuro-Fuzzy-Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência,” Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2010.
- [5] A. S. 446-1987, “IEEE Recommended Practice for Emergency e Standby Power Systems for Industrial and Commerical Applications,” 446-1987, *ANSI/IEEE Std*, p. 1,272, 1995.
- [6] “ITI (CBEMA) CURVE APPLICATION NOTE,” (ITI), *Information Technology Industry Council*, 2000. [Online]. Available: <http://microblog.routed.net/wp-content/uploads/2007/09/iticurv.pdf>.
- [7] A. C. Parsons, W. M. Grady, E. J. Powers, e J. C. Soward, “A direction finder for power quality disturbances based upon disturbance power and energy,” *IEEE Trans. Power Deliv.*, vol. 15, no. 3, pp. 1081–1086, 2000.
- [8] A. K. Pradhan, A. Routray, e S. Madhan Gudipalli, “Fault direction estimation in radial distribution system using phase change in sequence current,” *IEEE Trans. Power Deliv.*, vol. 22, no. 4, pp. 2065–2071, 2007.
- [9] Y. Yan, Y. Qian, H. Sharif, e D. Tipper, “A survey on smart grid communication infrastructures: Motivations, requirements and challenges,” *IEEE Commun. Surv. Tutorials*, vol. 15, no. 1, pp. 5–20, Jan. 2012.
- [10] X. Fang, S. Misra, G. Xue, e D. Yang, “Smart Grid — The New and Improved Power Grid: A Survey,” *IEEE Commun. Surv. Tutorials*, vol. 14, no. 4, pp. 944–980, 2012.
- [11] M. Erol-kantarci e H. T. Mouftah, “Energy-Efficient Information and Communication Infrastructures in the Smart Grid : A Survey on Interactions and Open Issues,” vol. 17, no. 1, pp. 179–197, 2015.
- [12] C. Muscas, M. Pau, P. A. Pegoraro, e S. Sulis, “Smart Electric Energy Measurements in Power Distribution Grids,” *IEEE Instrum. Meas. Mag.*, vol. 18, no. 1, pp. 17–21, 2015.
- [13] S. S. S. R. Depuru, L. Wang, e V. Devabhaktuni, “Smart meters for power grid: Challenges, issues, advantages and status,” *Renew. Sustain. Energy Rev.*, vol. 15, no. 6, pp. 2736–2742, Mar. 2011.
- [14] F. C. L. Trindade and W. Freitas, “Low Voltage Zones to Support Fault Location in Distribution Systems With Smart Meters,” *IEEE Transactions on Smart Grid*, vol. PP, no. 99, pp. 1–10, 2016.

- [15] G. Chang e J. Chao, "On tracking the source location of voltage sags and utility shunt capacitor switching transients," *IEEE Trans. Power Deliv.*, vol. 23, no. 4, pp. 2124–2131, 2008.
- [16] D. Granados-Lieberman, R. J. Romero-Troncoso, R. a. Osornio-Rios, a. Garcia-Perez, e E. Cabal-Yepez, "Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review," *IET Gener. Transm. Distrib.*, vol. 5, no. 4, p. 519, 2011.
- [17] M. a. S. Masoum, S. Jamali, e N. Ghaffarzadeh, "Detection and classification of power quality disturbances using discrete wavelet transform and wavelet networks," *IET Sci. Meas. Technol.*, vol. 4, no. 4, p. 193, 2010.
- [18] J. G. M. S. Decanini, M. S. Tonelli-Neto, F. C. V Malange, e C. R. Minussi, "Detection and classification of voltage disturbances using a Fuzzy-ARTMAP-wavelet network," *Electr. Power Syst. Res.*, vol. 81, no. 12, pp. 2057–2065, Dec. 2011.
- [19] H. Erişti, A. Uçar, e Y. Demir, "Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines," *Electr. Power Syst. Res.*, vol. 80, no. 7, pp. 743–752, Jul. 2010.
- [20] P. H. and M. L. J. Skea, D. Anderson, T. Green, R. Gross, "Intermittent renewable generation and the cost of maintaining power system reliability," *Gener. Transm. Distrib. IET*, vol. 1, no. 2, p. 324, 2007.
- [21] N. Huang, D. Xu, X. Liu e L. Lin, "Power quality disturbances classification based on S-transform and probabilistic neural network," *Neurocomputing*, vol. 98, pp. 12–23, Dec. 2012.
- [22] A. Rodríguez, J. A. Aguado, F. Martín, J. J. López, F. Muñoz, aend J. E. Ruiz, "Rule-based classification of power quality disturbances using S-transform," *Electr. Power Syst. Res.*, vol. 86, pp. 113–121, May 2012.
- [23] C.-Y. Lee e Y.-X. Shen, "Optimal Feature Selection for Power-Quality Disturbances Classification," *IEEE Trans. Power Deliv.*, vol. 26, no. 4, pp. 2342–2351, Oct. 2011.
- [24] T. Y. Ji, Q. H. Wu, L. Jiang, e W. H. Tang, "Disturbance detection, location and classification in phase space," *IET Gener. Transm. Distrib.*, vol. 5, no. 2, p. 257–265, 2011.
- [25] A. Kazemi e A. Mohamed, "Review of voltage sag source identification methods for power quality diagnosis," *Prz. ELEKTROTECHNICZNY*, no. 8, pp. 143–149, 2013.
- [26] C. Li, T. Tayjasanant, W. Xu e X. Liu, "Method for voltage-sag-source detection by investigating slope of the system trajectory," *IEE Proc. - Gener. Transm. Distrib.*, vol. 150, no. 3, p. 367, 2003.
- [27] N. Hamzah, A. Mohamed e A. Hussain, "A new approach to locate the voltage sag source using real current component," *Electr. Power Syst. Res.*, vol. 72, no. 2, pp. 113–123, Dec. 2004.
- [28] T. Tayjasanant, C. Li e W. Xu, "A Resistance Sign-Based Method for Voltage Sag," *IEEE Trans. Power Deliv.*, vol. 20, no. 4, pp. 2544–2551, 2005.
- [29] A. K. Pradhan and A. Routray, "Applying Distance Relay for Voltage Sag Source Detection," *IEEE Trans. Power Deliv.*, vol. 20, no. 1, pp. 529–531, Jan. 2005.

- [30] R. C. Leborgne and D. Karlsson, "Voltage Sag Source Location Based on Voltage Measurements Only," *Electr. Power Qual. Util.*, vol. XIV, no. 1, pp. 25–30, 2008.
- [31] S. J. Ahn, D. J. Won, I. Y. Chung e S. Il Moon, "A method to determine the relative location of voltage sag source for power quality diagnosis," *IFAC Proc. Vol.*, vol. 16, pp. 163–168, 2005.
- [32] S. Ahn, D. Won, I. Chung e S. Moon, "A New Approach to Determine the Direction and Cause of Voltage Sag," *J. Electr. Eng. Technol.*, vol. 3, no. 3, pp. 300–307, 2008.
- [33] D. J. Won, I. Y. Chung, J. M. Kim, S. Il Moon, J. C. Seo e J. W. Choe, "A new algorithm to locate power-quality event source with improved realization of distributed monitoring scheme," *IEEE Trans. Power Deliv.*, vol. 21, no. 3, pp. 1641–1647, 2006.
- [34] D. Won and S. Moon, "Optimal number and locations of power quality monitors considering system topology," *Power Deliv. IEEE Trans.*, vol. 23, no. 1, pp. 288–295, 2008.
- [35] H. Shareef and A. Mohamed, "An alternative voltage sag source identification method utilizing radial basis function network," in *22nd International Conference on Electricity Distribution*, 2013, no. 370, pp. 10–13.
- [36] A. Kazemi, A. Mohamed, H. Shareef e H. Raihi, "Accurate voltage sag-source location technique for power systems using GACp and multivariable regression methods," *Int. J. Electr. Power Energy Syst.*, vol. 56, pp. 97–109, Mar. 2014.
- [37] Y. Hong and B. Chen, "Locating switched capacitor using wavelet transform and hybrid principal component analysis network," *IEEE Trans. Power Deliv.*, vol. 22, no. 2, pp. 1145–1152, 2007.
- [38] M. F. Faisal and A. Mohamed, "Identification of sources of voltage sags in the Malaysian distribution networks using SVM based S-transform," in *TENCON 2009 - 2009 IEEE Region 10 Conference*, 2009, pp. 1–6.
- [39] G. W. Chang, J. P. Chao, S. Y. Chu e C. Y. Chen, "A new procedure for tracking the source location of voltage sags," in *2007 IEEE Power Engineering Society General Meeting, PES*, 2007, no. 3.
- [40] K. Mets, J. A. Ojea e C. Develder, "Combining Power and Communication Network Simulation for Cost-Effective Smart Grid Analysis," *IEEE Communications Surveys & Tutorials*, vol. 16, no. 3, pp. 1771–1796, 2014.
- [41] T. Strasser, F. Andrén, J. Kathan, C. Cecati, C. Buccella, P. Siano, P. Leitão, G. Zhabelova, V. Vyatkin, P. Vrba e V. Mařík, "A Review of Architectures and Concepts for Intelligence in Future Electric Energy Systems," *IEEE Transactions on Industrial Electronics*, vol. 62, no. 4. pp. 2424–2438, 2015.
- [42] S. S. S. R. Depuru, L. Wang e V. Devabhaktuni, "Smart meters for power grid: Challenges, issues, advantages and status," *Renew. Sustain. Energy Rev.*, vol. 15, no. 6, pp. 2736–2742, Mar. 2011.
- [43] J. Spiess, Y. T. Joens, R. Dragnea e P. Spencer, "Using Big Data to Improve Customer Experience and Business Performance," *Bell Labs Tech. J.*, vol. 18, no. 4, pp. 3–17, 2014.
- [44] V. C. Gungor, D. Sahin, T. Kocak, S. Ergut, C. Buccella, C. Cecati e G. P.

- Hancke, "A Survey on smart grid potential applications and communication requirements," *IEEE Trans. Ind. Informatics*, vol. 9, no. 1, pp. 28–42, 2013.
- [45] P. K. Lee and L. L. Lai, "Smart metering in micro-grid applications," in *2009 IEEE Power & Energy Society General Meeting*, 2009, pp. 1–5.
- [46] F. C. L. Trindade, "Desenvolvimento de Metodologias para Localização de Defeitos em Sistemas de Distribuição com Medidores Inteligentes," Tese (doutorado) Universidade de Estadual de Campinas, 2013.
- [47] D. T. Feeders, "IEEE PES Distribution System Analysis Subcommittee's Distribution Test Feeder Working Group," 2010. [Online]. Available: <http://ewh.ieee.org/soc/pes/dsacom/testfeeders/index.html>.
- [48] IEEE, "No Title," *IEEE PES Distribution System Analysis Subcommittee's Test Feeder Working Group, 13-bus*, 2013. [Online]. Available: <http://ewh.ieee.org/soc/pes/dsacom/testfeeders/index.html>. [Accessed: 20-Aug-2015].
- [49] S. Deckmann and J. Pomilio, "Avaliação da Qualidade da Energia Elétrica," *UNICAMP/FEEC/DSE*, 2017. [Online]. Available: <http://www.dsce.fee.unicamp.br/~antenor/it012.html>. [Accessed: 20-Aug-2015].
- [50] S. M. B. Correia, *Probabilidade e estatística*, 2nd ed. Belo Horizonte: PUC Minas Virtual, 2003.
- [51] W. Sindelar, S. M. de Conto e L. Ahlert, *Teoria e prática em estatística para cursos de graduação*, 1st ed. Editora da Univates, 2014.
- [52] E. M. da Silva and E. M. da Silva, *Estatística*. Editora Atlas, 1997.
- [53] H.-M. Wu, S. Tzeng e C. Chen, "Handbook of Data Visualization," *Handbook of Data Visualization*, no. Chapter 8. pp. 681–708, 2008.
- [54] N. Iliinsky and J. Steele, "Designing Data Visualizations," *Practitioner*. p. 93, 2011.
- [55] J. Cooling, *Real-time Operating Systems*, 1 edition. Lindentree Associates, 2013.
- [56] C. De Capua and E. Romeo, "A smart THD meter performing an original uncertainty evaluation procedure," *IEEE Trans. Instrum. Meas.*, vol. 56, no. 4, pp. 1257–1264, 2007.
- [57] C. M. R. de Oliveira, "Controle Vetorial da Máquina de Indução por Modos Deslizantes Integral Utilizando Método de Anti-windup," Dissertação de Merstrado Universidade de São Paulo, 2016.
- [58] M. Biswal and P. K. Dash, "Measurement and Classification of Simultaneous Power Signal Patterns With an S-Transform Variant and Fuzzy Decision Tree," *IEEE Transactions on Industrial Informatics*, vol. 9, no. 4. pp. 1819–1827, 2013.
- [59] P. K. Ray, S. R. Mohanty e N. Kishor, "Classification of Power Quality Disturbances Due to Environmental Characteristics in Distributed Generation System," *IEEE Transactions on Sustainable Energy*, vol. 4, no. 2. pp. 302–313, 2013.
- [60] S. He, K. Li e M. Zhang, "A Real-Time Power Quality Disturbances Classification Using Hybrid Method Based on S-Transform and Dynamics," *IEEE Transactions on Instrumentation and Measurement*, vol. 62, no. 9. pp. 2465–2475, 2013.

- [61] M. Valtierra-Rodriguez, R. de J. Romero-Troncoso, R. A. Osornio-Rios e A. Garcia-Perez, "Detection and Classification of Single and Combined Power Quality Disturbances Using Neural Networks," *IEEE Transactions on Industrial Electronics*, vol. 61, no. 5. pp. 2473–2482, 2014.
- [62] M. S. Manikandan, S. R. Samantaray e I. Kamwa, "Detection and Classification of Power Quality Disturbances Using Sparse Signal Decomposition on Hybrid Dictionaries," *IEEE Transactions on Instrumentation and Measurement*, vol. 64, no. 1. pp. 27–38, 2015.
- [63] M. Uyar, S. Yildirim e M. T. Gencoglu, "An effective wavelet-based feature extraction method for classification of power quality disturbance signals," *Electr. Power Syst. Res.*, vol. 78, no. 10, pp. 1747–1755, Oct. 2008.
- [64] P. K. Ray, S. R. Mohanty, N. Kishor e J. P. S. Catalão, "Optimal Feature and Decision Tree-Based Classification of Power Quality Disturbances in Distributed Generation Systems," *IEEE Transactions on Sustainable Energy*, vol. 5, no. 1. pp. 200–208, 2014.
- [65] M. H. Neishaburi, M. Daneshtalab, M. R. Kakoei e S. Safari, "Improving robustness of Real-Time operating systems (RTOS) services related to soft-errors," *2007 IEEE/ACS Int. Conf. Comput. Syst. Appl. AICCSA 2007*, pp. 528–534, 2007.
- [66] T. Instruments, "TI-RTOS: A Real-Time Operating System for TI Devices," p. 2, 2012.
- [67] F. A. S. Borges, "Extração de características combinadas com árvore de decisão para detecção e classificação dos distúrbios de qualidade da energia elétrica". 2013. Dissertação (Mestrado em Sistemas Dinâmicos) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.
- [68] T. H. Cormen, C. E. Leiserson, R. Rivest e C. Stein, *Algoritmos: Teoria e Prática*. MIT Press, 1989.
- [69] M. Uyar, S. Yildirim e M. T. Gencoglu, "An expert system based on S-transform and neural network for automatic classification of power quality disturbances," *Expert Syst. Appl.*, vol. 36, no. 3, pp. 5962–5975, Apr. 2009.
- [70] I. H. Witten and E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques*, 3rd ed. 2005.
- [71] C. Halmenschlager, "Um algoritmo para indução de árvores e regras de decisão," Universidade Federal do Rio Grande do Sul, 2002.
- [72] R. J. Quinlan, *C4.5: Programs for Machine Learning*, 1st ed. San Mateo, 1993.
- [73] H. Brink, J. W. Richards e M. Fetherolf, *Real-World Machine Learning*, 1st ed. Manning Publications, 2016.
- [74] R. Xu and D. Wunsch, "Survey of clustering algorithms," *IEEE Transactions on Neural Networks*, vol. 16, no. 3. pp. 645–678, 2005.
- [75] A. K. Jain, "Data clustering: 50 years beyond K-means," *Pattern Recognit. Lett.*, vol. 31, no. 8, pp. 651–666, Jun. 2010.
- [76] A. Fahad, N. Alshatri, Z. Tari, A. Alamri, I. Khalil, A. Y. Zomaya, S. Foufou e A. Bouras, "A Survey of Clustering Algorithms for Big Data: Taxonomy and Empirical Analysis," *IEEE Transactions on Emerging Topics in Computing*, vol. 2, no. 3. pp. 267–279, 2014.

- [77] A. Jain, M. Murty e P. Flynn, "Data clustering: A review," *ACM Comput. Surv.*, vol. 31, 1999.
- [78] T. Zhang, R. Ramakrishnan e M. Livny, "BIRCH: An Efficient Data Clustering Method for Very Large Databases," in *Proceedings of the 1996 ACM SIGMOD International Conference on Management of Data*, 1996, pp. 103–114.
- [79] J. MacQueen, "Some methods for classification and analysis of multivariate observations," in *Proc. Fifth Berkeley Sympos. Math. Statist. and Probability (Berkeley, Calif., 1965/66)*, Univ. California Press, Berkeley, Calif., 1967, p. Vol. I: Statistics, pp. 281--297.
- [80] M. Ester, H.-P. Kriegel, J. Sander e X. Xu, "A Density-based Algorithm for Discovering Clusters a Density-based Algorithm for Discovering Clusters in Large Spatial Databases with Noise," in *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, 1996, pp. 226–231.
- [81] C. M. Bishop, *Pattern Recognition and Machine Learning*. Spring, 2007.
- [82] P. N. Tan, *Introduction To Data Mining*. Pearson Education, 2006.
- [83] P. J. Rousseeuw, "Silhouettes: A graphical aid to the interpretation and validation of cluster analysis," *J. Comput. Appl. Math.*, vol. 20, pp. 53–65, 1987.
- [84] S. P. Smith and A. K. Jain, "Testing for uniformity in multidimensional data.," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 6, no. 1, pp. 73–81, Jan. 1984.
- [85] A. K. Jain and R. C. Dubes, *Algorithms for Clustering Data*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1988.
- [86] U. M. Fayyad, G. Piatetsky-Shapiro e P. Smyth, "Advances in Knowledge Discovery and Data Mining," American Association for Artificial Intelligence, 1996, pp. 1–34.
- [87] E. Frank, I. H. Witten., *Generating Accurate Rule Sets Without Global Optimization*. Department of Computer Science, University of Waikato, 1998.
- [88] I. H. Witten, E. Frank e M. A. Hall, *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier Science, 2011.