



Universidade Federal
de Campina Grande

CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

IDENTIFICAÇÃO DE FONTES DE DESCARGAS
PARCIAIS POR ATRIBUTOS EXTRAÍDOS DA
ENVOLTÓRIA DO SINAL

ITAIARA FELIX CARVALHO, M. SC.

Campina Grande, Paraíba

Agosto de 2024.

ITAIARA FELIX CARVALHO

IDENTIFICAÇÃO DE FONTES DE DESCARGAS
PARCIAIS POR ATRIBUTOS EXTRAÍDOS DA
ENVOLTÓRIA DO SINAL

Tese submetida à Coordenadoria do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande, em cumprimento às exigências do Programa de Doutorado em Ciências no Domínio da Engenharia Elétrica.

ORIENTADORES:

PROF. EDSON GUEDES DA COSTA, D. SC.

PROF. LUIZ AUGUSTO MEDEIROS MARTINS NOBREGA, D. SC.

Campina Grande, Paraíba

Agosto de 2024

**IDENTIFICAÇÃO DE FONTES DE DESCARGAS PARCIAIS POR ATRIBUTOS
EXTRAÍDOS DA ENVOLTÓRIA DO SINAL**

ITAIARA FELIX CARVALHO

TESE APROVADA EM 26/09/2024

**EDSON GUEDES DA COSTA, D.Sc., UFCG
Orientador(a)**

**LUIZ AUGUSTO MEDEIROS MARTINS NÓBREGA, D.Sc., UFCG
Orientador(a)**

**GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG
Examinador(a)**

**RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr., UFCG
Examinador(a)**

**IVAN JOSÉ DA SILVA LOPES, Ph.D., UFMG
Examinador(a)**

**ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI
Examinador(a)**

CAMPINA GRANDE - PB



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
POS-GRADUACAO EM ENGENHARIA ELETRICA
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

REGISTRO DE PRESENÇA E ASSINATURAS

1. **ATA DA DEFESA PARA CONCESSÃO DO GRAU DE DOUTOR EM CIÊNCIAS, NO DOMÍNIO DA ENGENHARIA ELÉTRICA, REALIZADA EM 26 DE SETEMBRO DE 2024 (Nº 386)**

CANDIDATO(A): **ITAIARA FELIX CARVALHO**. COMISSÃO EXAMINADORA: GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG - Presidente da Comissão e Examinador Interno, EDSON GUEDES DA COSTA, D.Sc., UFCG - Orientador, LUIZ AUGUSTO MEDEIROS MARTINS NÓBREGA, D.Sc., UFCG - Orientador, RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr. UFCG - Examinador Interno, este por motivos superiores não participou de modo remoto da referida tese, entretanto enviou o parecer por escrito para o Presidente da Comissão, bem como os questionamentos e sugestões, explicitando que considera o trabalho de tese aprovado. IVAN JOSÉ DA SILVA LOPES, Dr., UFMG - Examinador Externo, ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI - Examinador Externo. TÍTULO DA TESE: Identificação de Fontes de Descargas Parciais Por Atributos Extraídos da Envoltória do Sinal. ÁREA DE CONCENTRAÇÃO: Processamento da Energia. HORA DE INÍCIO: **14h00** – LOCAL: **Sala Virtual, conforme Art. 5º da PORTARIA SEI Nº 01/PRPG/UFCG/GPR, DE 09 DE MAIO DE 2022**. Em sessão pública, após exposição de cerca de 45 minutos, o(a) candidato(a) foi arguido(a) oralmente pelos membros da Comissão Examinadora, tendo demonstrado suficiência de conhecimento e capacidade de sistematização, no tema de sua tese, obtendo conceito APROVADO. Face à aprovação, declara o presidente da Comissão, achar-se o examinado, legalmente habilitado a receber o Grau de Doutor em Ciências, no domínio da Engenharia Elétrica, cabendo a Universidade Federal de Campina Grande, como de direito, providenciar a expedição do Diploma, a que o(a) mesmo(a) faz jus. Na forma regulamentar, foi lavrada a presente ata, que é assinada por mim, Leandro Ferreira de Lima, e os membros da Comissão Examinadora. Campina Grande, 26 de Setembro de 2024.

LEANDRO FERREIRA DE LIMA

Secretário

GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG

Presidente da Comissão e Examinador Interno

EDSON GUEDES DA COSTA, D.Sc., UFCG

Orientador

LUIZ AUGUSTO MEDEIROS MARTINS NÓBREGA, D.Sc., UFCG

Orientador

RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr. UFCG
Examinador Interno

IVAN JOSÉ DA SILVA LOPES, Dr., UFMG
Examinador Externo

ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI
Examinador Externo

ITAIARA FELIX CARVALHO
Candidata

2 - APROVAÇÃO

2.1. Segue a presente Ata de Defesa de Tese de Doutorado da candidata **ITAIARA FELIX CARVALHO**, assinada eletronicamente pela Comissão Examinadora acima identificada.

2.2. No caso de examinadores externos que não possuam credenciamento de usuário externo ativo no SEI, para igual assinatura eletrônica, os examinadores internos signatários **certificam** que os examinadores externos acima identificados participaram da defesa da tese e tomaram conhecimento do teor deste documento.



Documento assinado eletronicamente por **LEANDRO FERREIRA DE LIMA, SECRETÁRIO (A)**, em 27/09/2024, às 14:41, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **GEORGE ROSSANY SOARES DE LIRA, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 27/09/2024, às 15:49, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **EDSON GUEDES DA COSTA, PROFESSOR 3 GRAU**, em 27/09/2024, às 15:57, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **RAIMUNDO CARLOS SILVERIO FREIRE, PROFESSOR 3 GRAU**, em 29/09/2024, às 19:34, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **LUIZ AUGUSTO MEDEIROS MARTINS NOBREGA, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 30/09/2024, às 09:50, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Itaiara Felix Carvalho, Usuário Externo**, em 03/10/2024, às 15:57, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **4836416** e o código CRC **72D6C775**.

Referência: Processo nº 23096.065741/2024-03

SEI nº 4836416



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CNPJ nº 05.055.128/0001-76
POS-GRADUACAO EM ENGENHARIA ELETRICA
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

DECLARAÇÃO

Processo nº 23096.065741/2024-03

DECLARAMOS para fins de comprovação que, os Professores GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG - Presidente da Comissão e Examinador Interno, EDSON GUEDES DA COSTA, D.Sc., UFCG - Orientador, LUIZ AUGUSTO MEDEIROS MARTINS NÓBREGA, D.Sc., UFCG - Orientador, RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr. UFCG - Examinador Interno, este por motivos superiores não participou de modo remoto da referida tese. Entretanto enviou o parecer por escrito para o Presidente da Comissão, bem como os questionamentos e sugestões, explicitando que considera o trabalho de tese aprovado, IVAN JOSÉ DA SILVA LOPES, Dr., UFMG - Examinador Externo, ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI - Examinador Externo, participaram da Banca de Defesa Final da Tese de Doutorado, do Programa de Pós-Graduação em Engenharia Elétrica da UFCG, intitulada TÍTULO DA TESE: **Identificação de Fontes de Descargas Parciais Por Atributos Extraídos da Envolvória do Sinal**, de autoria da doutoranda **ITAIARA FELIX CARVALHO**, no dia 25 de setembro de 2024.



Documento assinado eletronicamente por **ALEXANDRE JEAN RENE SERRES, COORDENADOR(A)**, em 27/09/2024, às 16:09, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **4836419** e o código CRC **4CC497E9**.

Caro Professor
Alexandre Jean Rene Serres
Coordenador do PPgEE/UFMG.

Eu, **IVAN JOSÉ DA SILVA LOPES, Dr., UFMG**, na qualidade de membro da comissão examinadora da defesa de tese intitulada “IDENTIFICAÇÃO DE FONTES DE DESCARGAS PARCIAIS POR ATRIBUTOS EXTRAÍDOS DA ENVOLTÓRIA DO SINAL.”, de **ITAIARA FELIX CARVALHO**, da qual participei por videoconferência, no dia 26 de Setembro de 2024, declaro ter recebido cópia da ata, que consta nos autos do processo nº [23096.065741/2024-03](#) como documento nº ([4836416](#)), a qual li e, embora não tenha podido assinar, é para todos os efeitos como se eu tivesse, pois está em perfeita conformidade com o que foi deliberado pela comissão e, portanto, estou de pleno acordo com seus termos.



IVAN JOSÉ DA SILVA LOPES, Dr., UFMG.

Caro Professor
Alexandre Jean Rene Serres
Coordenador do PPgEE/UFMG.

Eu, **ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI**, na qualidade de membro da comissão examinadora da defesa de tese intitulada “IDENTIFICAÇÃO DE FONTES DE DESCARGAS PARCIAIS POR ATRIBUTOS EXTRAÍDOS DA ENVOLTÓRIA DO SINAL.”, de **ITAIARA FELIX CARVALHO**, da qual participei por videoconferência, no dia 26 de Setembro de 2024, declaro ter recebido cópia da ata, que consta nos autos do processo nº [23096.065741/2024-03](#) como documento nº ([4836416](#)), a qual li e, embora não tenha podido assinar, é para todos os efeitos como se eu tivesse, pois está em perfeita conformidade com o que foi deliberado pela comissão e, portanto, estou de pleno acordo com seus termos.

Documento assinado digitalmente
 ESTACIO TAVARES WANDERLEY NETO
Data: 27/09/2024 16:10:46-0300
Verifique em <https://validar.iti.gov.br>

ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI.

C331i

Carvalho, Itaiara Felix.

Identificação de fontes de descargas parciais por atributos extraídos da envoltória do sinal / Itaiara Felix Carvalho. – Campina Grande, 2024.
158 f. : il. color.

Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2024.

"Orientação: Prof. Dr. Edson Guedes da Costa, Prof. Dr. Luiz Augusto Medeiros Martins Nóbrega".

Referências.

1. Processamento da Energia. 2. Descargas Parciais (DP).
3. Classificação e Monitoramento de Descargas Parciais. I. Costa, Edson Guedes da. II. Nóbrega, Luiz Augusto Medeiros Martins. II. Título.

CDU 621.311(043)

Dedico esta tese a minha mãe, Maria Mirian Felix Ribeiro, *in memoriam*, que sempre foi a minha maior incentivadora.

AGRADECIMENTOS

Agradeço a Deus pelo dom da vida, pela saúde e pela força nos momentos de fraqueza e dificuldades.

À minha família, em especial à minha mãe, Maria Mirian, por todo o amor, dedicação, força e confiança, sempre tão generosamente entregues. Ao meu pai, Itamar Carvalho, e irmãs Itamara Felix e Itaiana Felix, por todo amor e incentivo.

Ao meu esposo, Francisco Neto, pelo companheirismo, paciência e amor. Agradeço também por ser, por diversas vezes, meu criterioso revisor.

Aos meus orientadores, Professores Edson Guedes e Luiz Augusto, por todos os ensinamentos, direcionamentos e pela confiança depositada em mim.

Ao Professor Edson Guedes, pela oportunidade de realização de estágio à docência, o que me trouxe muito aprendizado e expectativas para iniciar a carreira docente.

Agradeço a todos do Laboratório de Alta Tensão, em especial, aos meus amigos Allan David e Igor Monteiro, por todo o auxílio prestado e pelos momentos de descontração que trouxeram leveza aos dias de preocupação. Aos colegas Higor Costa, Alisson Teles, Lenilson Andrade, Almir Carlos, Vandilson Barbosa, Antonio Leite e João Victor, pelo apoio prestado para a conclusão deste trabalho.

Por fim, agradeço à Universidade Federal de Campina Grande, à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo financiamento e provimento de bolsas de estudo, e ao apoio da Eletrobras FURNAS no âmbito do projeto “Desenvolvimento de um Sistema Inteligente de Monitoramento Online para Transformadores de Corrente” financiado pelo Programa de P&D do Setor Elétrico Brasileiro, regulado pela Agência Nacional de Energia Elétrica (ANEEL).

RESUMO

As técnicas para diagnóstico de descargas parciais (DP) utilizando o método radiométrico requerem a amostragem dos sinais na ordem de nanosegundos. Em razão disso, é necessária uma alta taxa de amostragem do sistema de aquisição para obtenção da acurácia necessária do método e uma elevada capacidade de armazenamento de dados dos dispositivos de aquisição. A fim de reduzir os requisitos de *hardware* do sistema de aquisição e aumentar a aplicabilidade do método radiométrico no monitoramento de DP em subestações, foi proposta a utilização de um sistema de condicionamento de sinais entre a antena e o sistema de aquisição. Neste trabalho foi projetado, desenvolvido, e avaliado um sistema capaz de adquirir sinais radiométricos de DP, captar as envoltórias dos sinais, extrair os atributos mais relevantes e separar e classificar as DP, permitindo uma redução significativa na taxa de amostragem necessária para aquisição. Inicialmente, a suavização dos sinais foi realizada e avaliada por meio do método de suavização de densidade por Kernel. Posteriormente, um sistema de condicionamento de sinal foi desenvolvido e validado em medições realizadas em laboratório e em subestações. Os atributos representativos das envoltórias dos sinais foram extraídos, selecionados e aplicados a algoritmos de agrupamento como K-means, Gaussian Mixture Model (GMM) e Mean-shift, e a modelos de aprendizado de máquina supervisionados como Support Vector Machine (SVM), Random Forest e Regressão logística. Os resultados demonstram que o sistema proposto classifica e separa sinais de DP de maneira eficaz, com redução dos requisitos de hardware para os sistemas de aquisição, ampliando o potencial do método radiométrico para uso em subestações.

Palavras-chave: Descargas parciais, sinais radiométricos, detecção, classificação, envoltórias.

ABSTRACT

The techniques for diagnosing partial discharges (PD) using the radiometric method require signal sampling in the order of nanoseconds. Therefore, a high sampling rate of the acquisition system is required to obtain the required accuracy of the method and a high data storage capacity of the acquisition devices. In order to reduce the hardware requirements of the acquisition system and increase the applicability of the radiometric method in PD monitoring in substations, the use of a signal conditioning system between the antenna and the acquisition system was proposed. In this work, a system capable of acquiring radiometric PD signals, capturing the signal envelopes, extracting the most relevant attributes and separating and classifying the PDs was designed, developed, and evaluated, allowing a significant reduction in the sampling rate required for acquisition. Initially, signal smoothing was performed and evaluated using the Kernel density smoothing method. Subsequently, a signal conditioning system was developed and validated in measurements performed in the laboratory and in substations. The representative features of the signal envelopes were extracted, selected and applied to clustering algorithms such as K-means, Gaussian Mixture Model (GMM) and Mean-shift, and to supervised machine learning models such as Support Vector Machine (SVM), Random Forest and Logistic Regression. The results demonstrate that the proposed system classifies and separates PD signals effectively, reducing the hardware requirements for the acquisition systems, expanding the potential of the radiometric method for use in substations.

Keywords: Partial discharges, radiometric signals, detection, classification, envelopes.

LISTA DE ABREVIATURAS E SIGLAS

AGD	Análise de Gases Dissolvidos
AM	Modulação em Amplitude (do inglês: <i>Amplitude Modulation</i>)
ARI	Índice de Rand Ajustado (do inglês: <i>Adjusted Rand Index</i>)
AOA	Ângulo de Chegada (do inglês: <i>Angle of Arrival</i>)
CIGRÉ	Conselho Internacional dos Grandes Pesquisadores em Engenharia Elétrica (do francês: <i>Conseil International des Grands Réseaux Électriques</i>)
DP	Descarga Parcial
EA	Emissões Acústicas
GIS	Subestação Isolada a Gás (do inglês: <i>Gas Insulated Substation</i>)
GMM	Modelo de Mistura de Gaussianas (do inglês: <i>Gaussian Mixture Model</i>)
HART	Via de Dados Endereçável por Transdutor Remoto (do inglês: <i>Highway Addressable Remote Transducer</i>)
HFCT	Transformador de Corrente de Alta Frequência (do inglês: <i>High Frequency Current Transformer</i>)
IEC	Comissão Eletrotécnica Internacional (do inglês: <i>International Electrotechnical Commission</i>)
KDE	Estimação de Densidade por Kernel (do inglês: <i>Kernel Density Estimation</i>)
LAT	Laboratório de Alta Tensão
LNA	Amplificador de Baixo Ruído (do inglês: <i>Low Noise Amplifier</i>)
MCU	Unidade de Microcontrolador (do inglês: <i>Microcontroller Unit</i>)
PRPD	Descarga Parcial Resolvida em Fase (do inglês: <i>Phase-Resolved Partial Discharge</i>)
RF	Radiofrequência
RFE	Eliminação Recursiva de Atributos (do inglês: <i>Recursive Feature Elimination</i>)
RSS	Intensidade de Sinal Recebido (do inglês: <i>Received Signal Strength</i>)
SBC	Computador de placa única (SBC, do inglês: <i>Single Board Computer</i>)
SDR	Rádio Definido por Software (do inglês: <i>Software Defined Radio</i>)
SEP	Sistema Elétrico de Potência
TDOA	Diferença de Tempo de Chegada (do inglês: <i>Time Difference of Arrival</i>)

TOA	Tempo de Chegada (do inglês: <i>Time of Arrival</i>)
TC	Transformador de Corrente
TP	Transformador de Potencial
UHF	Frequência Ultra Alta (do inglês: <i>Ultra High Frequency</i>)
VTH	Tensão de Limiar (do inglês: <i>Threshold Voltage</i>)
WSN	Rede de Sensores sem Fio (do inglês: <i>Wireless Sensor Network</i>)

LISTA DE SÍMBOLOS

C	Capacitor
E_s	Energia do sinal
E_n	Energia do sinal normalizado
En_i	Componente suavizado da envoltória na i -ésima amostra
f_c	Frequência da portadora
f_{max}	Frequência máxima do sinal mensagem
F_c	Fator de crista
F_F	Fator de forma
F_I	Fator de impulso
F_L	Fator de liberação
H_z	Hertz
kV	Quilovolt
K	Função de suavização Kernel Guassiana
K_u	Curtose
ms	Milissegundos
mV	Milivolt
N	Número total de pontos
ns	Nanossegundos
pC	Picocoulomb
R	Resistor
RF	Radiofrequência
S_k	Assimetria
t	Tempo
T_t	Duração do sinal
T_d	Tempo de descida
T_s	Tempo de subida
t_i	Amostras de tempo no i -ésimo ponto
t_j	Amostras de tempo no J -ésimo ponto
V_{med}	Amplitude Média

V_p	Valor de pico
V_{RMS}	Valor RMS
V_{r2}	Amplitude da raiz quadrada
VS_j	Tensão instantânea ao quadrado na j-ésima amostra
x	Ponto de amostras de um sinal
μ	Média de x
σ	Desvio padrão de x
μs	Microssegundos

LISTA DE ILUSTRAÇÕES

Figura 1.1 - Gráfico de análise do modo de falhas de um grupo de 964 grandes falhas.....	11
Figura 1.2 - Fotografia do Transformador de corrente tipo CESU 110 kV (925011/1979)	11
Figura 1.3 – Fotografia de medição de DP por meio do método radiométrico em subestação.....	14
Figura 1.4 - Esquemático do processo de separação e identificação de fontes DP e/ou ruído.....	16
Figura 2.1 - Exemplo de isolamento com falhas que podem causar descargas parciais.	23
Figura 2.2 - Representação de descarga parcial superficial.	23
Figura 2.3 - Esquemático representativo de descarga corona.....	24
Figura 2.4 – Modelo representativo do fenômeno de descargas parciais.	24
Figura 2.5 - Circuito elétrico equivalente para o modelo de descargas parciais.....	25
Figura 2.6 - Gráfico representativo do processo de descargas parciais em um dielétrico.	25
Figura 2.7 - Esquemático de medição proposto pela IEC 60270 (2000).	26
Figura 2.8 – Arranjo de detecção e localização de DP utilizado nos sensores conectados a uma central de monitoramento.....	29
Figura 2.9 - Desenho esquemático de um sensor instalado em uma janela dielétrica de um transformador de potência.....	29
Figura 2.10 - Fotografia de transformador de potência com sensor interno acoplado.	30
Figura 2.11 – Fotografia de sensor tipo sonda instalado em um transformador de potência.....	31
Figura 2.12 - Padrão PRPD correspondente a uma medição de descarga parcial.....	32
Figura 2.13 – Padrão PRPD de descargas internas, superficiais e corona, respectivamente.	33
Figura 2.14 – Circuito detector de envoltória.	34
Figura 2.15 – Sinal RF e sua respectiva envoltória.	36
Figura 2.16 – SVM com classificação linear.....	44
Figura 3.1 - Arranjo usado para comparar os sinais irradiados por descargas no ar e óleo.	55
Figura 3.2 - Sensor UHF no tanque do transformador.	56
Figura 3.3 - Posição dos sensores UHF C1 e C2 no tanque do transformador.	57
Figura 3.4 - Sinais de fundo com o transformador em carga, usando o pré-amplificador.	57
Figura 3.5 - Fotografia das vistas lateral e superior do sensor montado na janela dielétrica.....	58
Figura 3.6 - (a) Sinal UHF original de DP. (b) Sinal após a detecção de envoltória.	62
Figura 3.7 - Sistema de diagnóstico de descarga parcial para GIS utilizando o método radiométrico com base no circuito de detecção de envoltória.	63
Figura 3.8 - Sistema de diagnóstico de descarga parcial para GIS utilizando o método radiométrico com base no circuito de detecção de envoltória.	63
Figura 3.9 - Diagrama de circuito do detector de envoltória UHF.	65
Figura 3.10 - Fotografia de um detector de 3 canais de baixa potência com filtros de banda montados externamente.	65
Figura 3.11 - Diagrama de blocos simplificado do detector de descarga parcial. O detector de três canais converte sinais de RF brutos em magnitudes espectrais proporcionais.	66

Figura 3.12 - Diagrama de Detecção radiométrica de sinal de DP em transformador.....	67
Figura 3.13 - Circuito detector de envoltória simulado no Matlab.....	67
Figura 3.14 - Sinal resultante da simulação do circuito detector de envoltória.....	68
Figura 3.15 - Sinal radiométrico de DP de defeito produzido por partículas metálicas livre.....	69
Figura 3.16 - Sinal radiométrico de DP de defeito em eletrodos.....	69
Figura 3.17 - Sensor UHF sem fio projetado: (a) diagrama do sensor UHF sem fio; (b) imagem do sensor UHF sem fio.....	70
Figura 3.18 - Diagrama de blocos do sistema de detecção radiométrica.....	71
Figura 3.19 - Diagrama de blocos de detecção de pulso PD usando sensor UHF.....	72
Figura 3.20 – Função envoltória normalizada, área de pico e área de cauda demonstradas na envoltória de três sinais de DP: (a) Sinal de DP assimétrico com cauda em direção a direita. (b) Sinal de DP assimétrico com cauda em direção a esquerda. (c) Sinal de DP simétrico.....	78
Figura 3.21 –Diagramas 3D e 2D para os parâmetros ($f-A_p-A_t$). a) 3D ($f-A_p-A_t$), b) 2D ($A_p -A_t$), c) 2D ($f-A_p$), d) vista detalhada do diagrama $f-A_p$, e) 2D (A_t-f) e f) vista detalhada do diagrama $f-A_t$	79
Figura 3.22 - Representação dos parâmetros f , A_p e A_t em diagramas 2D e 3D para a classificação de pulsos de DP em <i>clusters</i>	80
Figura 3.23 - a) Padrão de DP do cluster 1 (defeito interno), b) Padrão de DP do cluster 2 (efeito corona) c) Padrão PD do cluster 3 (eletrodo com potencial flutuante).....	80
Figura 3.24 - Quatro tipos de representação de defeito após redução de dimensionalidade.....	81
Figura 4.1 – Fotografia da célula cilíndrica de acrílico com corpo de prova imerso em óleo.....	89
Figura 4.2 - Corpo de prova: (a) fotografia do corpo de prova utilizado e (b) diagrama de configuração dos defeitos.....	90
Figura 4.3 – Fotografia de uma barra de hidrogerador utilizada como fonte de DP.....	90
Figura 4.4 –Fotografia da vista da seção transversal da barra de hidrogerador.....	90
Figura 4.5 – Fotografia do transformador de potencial de 36 kV utilizado como fonte emissora de DP...91	91
Figura 4.6 – Diagrama esquemático para medição para detecção de DP.....	92
Figura 4.7 – Fotografia do arranjo de medição de descargas parciais.....	92
Figura 4.8 - Fotografia da impedância de medição LDM-5.....	92
Figura 4.9 – Fotografia da antena monopolo impressa circular.....	93
Figura 4.10 – Diagrama de blocos do algoritmo de geração de envoltória utilizando KDE.....	95
Figura 4.11 – Esquemático de detecção de DP com o sistema de condicionamento de sinais.....	96
Figura 4.12 - Analisador de rede utilizado para medir os coeficientes de transmissão e reflexão.....	97
Figura 4.13 – Fotografia do sistema de condicionamento de sinal.....	97
Figura 4.14 – Fotografia do sistema de aquisição de dados durante medição em subestação.....	98
Figura 4.15 - Fotografia da medição no (a) compensador síncrono, no (b) para-raios e no (c) transformador de corrente.....	99
Figura 4.16 - Fluxograma de seleção de atributos.....	102
Figura 5.1 – Resultado da aplicação do algoritmo de densidade por Kernel: (a) Sinal radiométrico de DP emitido pela barra de hidrogerador; (b) Sinal radiométrico de DP após a remoção do nível CC e elevação ao quadrado; (c) Envoltória do sinal DP.....	106

Figura 5.2 - Resultado da aplicação do algoritmo de densidade por Kernel: (a) Sinal radiométrico de DP emitido pelo corpo de prova; (b) Sinal radiométrico de DP após a remoção do nível CC e elevação ao quadrado; (c) Envoltória do sinal DP.	107
Figura 5.3 – Resultado da aplicação do algoritmo de densidade por Kernel: (a) Sinal radiométrico de DP emitido pelo TP; (b) Sinal radiométrico de DP após a remoção do nível CC e elevação ao quadrado; (c) Envoltória do sinal DP.....	108
Figura 5.4 – Gráfico 3D para os atributos amplitude, energia (área sob a curva), tempo de duração do sinal.	109
Figura 5.5 – Gráfico 2D para os atributos amplitude e energia (área sob a curva).....	109
Figura 5.6 – Gráfico 2D para os atributos amplitude e tempo de duração do sinal.	110
Figura 5.7 – Gráfico 2D para os atributos tempo e energia.	110
Figura 5.8 – Gráfico 3D para os atributos amplitude, tempo de subida e energia (área sob a curva).....	111
Figura 5.9 – Gráfico 3D para os atributos amplitude, tempo de descida e energia (área sob a curva).	111
Figura 5.10 – Gráfico 3D para os atributos tempo de descida, tempo de duração do sinal e tempo de subida.	112
Figura 5. 11 – Magnitude do coeficiente de transmissão S_{21} do filtro RF.	113
Figura 5. 12 – Magnitude do coeficiente de transmissão S_{21} do amplificador RF.....	113
Figura 5. 13 - Magnitude do coeficiente de reflexão S_{11} do circuito detector de envoltória.	114
Figura 5.14 -Sinal radiométrico de DP capturado do TP e sua respectiva envoltória detectados durante o ensaio.....	115
Figura 5.15 – FFT do sinal radiométrico de DP capturado do TP e de sua envoltória.	115
Figura 5. 16 – FFT do sinal radiométrico de DP capturado do corpo de prova de fenolite com cavidades e de sua envoltória.....	116
Figura 5. 17 - FFT do sinal radiométrico de DP capturado da barra de hidrogerador e de sua envoltória.	116
Figura 5. 18 - FFT do sinal radiométrico de DP capturado na subestação e sua respectiva envoltória. ...	117
Figura 5.19 - Gráfico de dispersão tridimensional do algoritmo K-means com os dados medidos em laboratório.	119
Figura 5.20 - Gráfico de dispersão tridimensional do algoritmo GMM com os dados medidos em laboratório.	120
Figura 5.21 - Gráfico de dispersão tridimensional do algoritmo Mean Shift com os dados medidos em laboratório.	120
Figura 5.22 - Gráfico de dispersão tridimensional do algoritmo K-means com os dados medidos em laboratório.	124
Figura 5.23 - Gráfico de dispersão tridimensional do algoritmo GMM com os medidos em campo.	125
Figura 5.24 - Gráfico de dispersão tridimensional do algoritmo Mean Shift com os dados medidos em campo.	125

LISTA DE TABELAS

Tabela 3.1 – Contribuições constatadas nos trabalhos que utilizam detecção de envoltória da revisão bibliográfica e as almeçadas nesta pesquisa.....	86
Tabela 4.1-Dados de calibração para a barra de hidrogerador.....	94
Tabela 4.2- Dados de calibração para a cuba de óleo com eletrodos do tipo ponta-plano.....	94
Tabela 4.3 – Dados de calibração para o transformador de potencial.	94
Tabela 5.1 – Matriz de coeficientes de correlação.....	118
Tabela 5.2 - Matriz de confusão, precisão, recall e acurácia média para o modelo SVM dos dados detectados em laboratório.....	122
Tabela 5.3 - Matriz de confusão, precisão, recall e acurácia média para o modelo Random Forest dos dados detectados em laboratório.....	123
Tabela 5.4 - Matriz de confusão, precisão, recall e acurácia média para o modelo de Regressão Logística dos dados detectados em laboratório.	123
Tabela 5.5 - Matriz de confusão, precisão, recall e acurácia média para o modelo SVM dos dados detectados em campo.....	126
Tabela 5.6 - Matriz de confusão, precisão, recall e acurácia média para o modelo Random Forest dos dados detectados em campo.	126
Tabela 5.7 - Matriz de confusão, precisão, recall e acurácia média para o modelo de Regressão Logística dos dados detectados em campo.	127

SUMÁRIO

Agradecimentos.....	4
Resumo.....	5
Abstract.....	6
Lista de Abreviaturas e Siglas.....	7
Lista de Símbolos.....	9
Lista de Ilustrações.....	11
1 Introdução.....	10
1.1 Relevância.....	14
1.2 Motivação.....	17
1.3 Objetivos.....	17
1.3.1 Objetivo Geral.....	18
1.3.2 Objetivos Específicos.....	18
1.4 Contribuições.....	19
1.5 Publicações.....	19
1.6 Organização do Texto.....	21
2 Fundamentação Teórica.....	22
2.1 Descargas Parciais.....	22
2.1.1 Método Elétrico Convencional Definido na Norma IEC 60270(2000).....	26
2.1.2 Método Radiométrico.....	27
2.1.2.1 Sensores Externos.....	28
2.1.2.2 Sensores Internos.....	30
2.1.2.3 Sensores Tipo Sonda.....	31
2.1.3 Interpretação de Descargas Parciais Por Meio da Análise PRPD.....	31
2.2 Detecção da Envoltória do Sinal.....	33
2.3 Atributos de Sinais de Descargas Parciais.....	37
2.3.1 Seleção de Atributos.....	38
2.4 Técnicas de Classificação e Agrupamento.....	42
2.4.1 Técnicas de Classificação.....	42
2.4.2 Técnicas de Agrupamento.....	47
3 Revisão Bibliográfica.....	52
3.1 Monitoramento de Descargas Parciais Utilizando o Método Radiométrico.....	52
3.2 Detector de Envoltória.....	61
3.3 Extração de Atributos para Separação de Descargas Parciais.....	74
3.4 Resumo das Contribuições dos Trabalhos Pesquisados.....	84
4 Metodologia.....	87
4.1 Procedimentos Experimentais.....	88
4.2 Método de Suavização do Sinal de DP – Procedimentos Computacionais.....	94
4.3 Sistema de Condicionamento de Sinais.....	96
4.4 Medição em Subestação de 230 kV.....	98

4.5	Extração e Seleção de Atributos.....	99
4.5.1	Seleção de Atributos	100
4.6	Separação e Classificação	102
5	Resultados e Análises	105
5.1	Algoritmo de Geração de Envoltórias.....	105
5.2	Sistema de Condicionamento de Sinais.....	112
5.3	Extração e Seleção de Atributos.....	117
5.4	Separação e Classificação das Envoltórias.....	119
5.4.1	Dados Detectados em Laboratório	119
5.4.2	Dados Detectados em Campo	124
6	Conclusões.....	129
6.1	Trabalhos a Serem Desenvolvidos no Futuro.....	131
7	Referências	132

1 INTRODUÇÃO

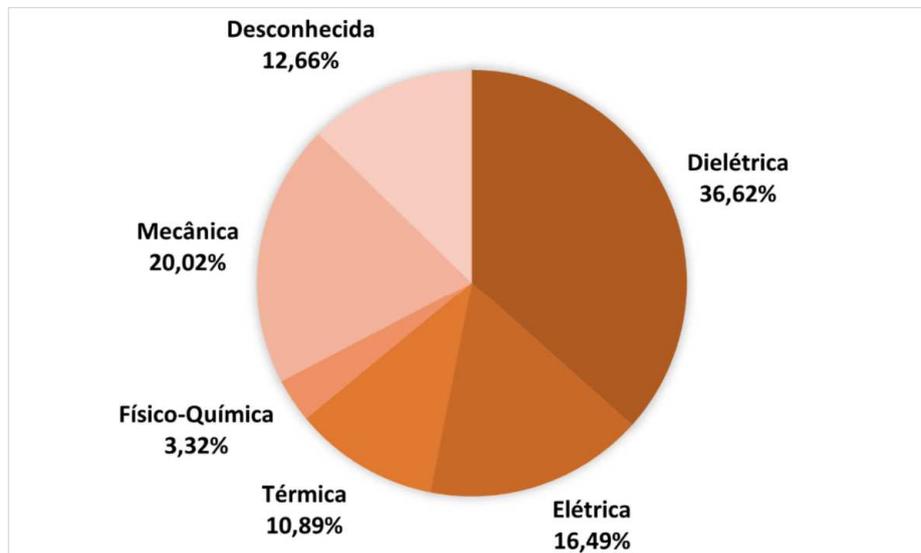
Os equipamentos elétricos e as linhas de transmissão em alta tensão são os ativos de produção de receita das geradoras e concessionárias de transmissão. Dessa forma, realizar o monitoramento das suas condições operacionais é de fundamental importância para garantir disponibilidade e segurança no suprimento de energia aos consumidores. Além disso, quando gerenciados de forma adequada, tais ativos se tornam um dos principais fatores de eficiência operacional e econômica (ÁLVAREZ et al., 2016; FRONTIN, 2013).

O isolamento elétrico nos equipamentos do Sistema Elétrico de Potência (SEP) é um dos principais fatores de falhas, visto que durante sua vida útil ele está submetido a estresses elétricos, mecânicos, térmicos e ambientais, que podem agir de forma individual ou combinada. Um exemplo pode ser visto na pesquisa realizada pelo CIGRE WORKING GROUP A2.37 (2015), em que uma análise da natureza das falhas em transformadores foi apresentada. O grupo de pesquisa coletou 964 grandes falhas que ocorreram no período de 1996 a 2010, dentro de uma população total fornecida por ano de 167.459 transformadores, constituídos por 56 concessionárias de 21 países. O resultado da análise do modo de falha dos transformadores pode ser observado na Figura 1.1, a partir da qual é possível constatar que as falhas dielétricas (isolamento) foram as mais proeminentes, seguidas pelas falhas do tipo mecânicas e elétricas.

Falhas dielétricas podem estar associadas à atividade de Descargas Parciais (DP), que são descargas elétricas de baixa intensidade que curto-circuitam parcialmente regiões do material isolante submetido a campos elétricos intensos (NATTRASS, 1988). A ação contínua de DP pode causar uma degradação progressiva do material isolante, culminando na ruptura completa do dielétrico, resultando em indisponibilidade, multas, custos de reparo ou substituição do ativo. Um exemplo de falha dielétrica pode ser observado na Figura 1.2, onde é apresentado um transformador de corrente (TC) com destruição completa do isolamento, no qual havia sido registrado um aumento significativo no nível de DP duas semanas antes da destruição. Dessa forma, a detecção e interpretação de DP são ferramentas robustas para o monitoramento da condição e

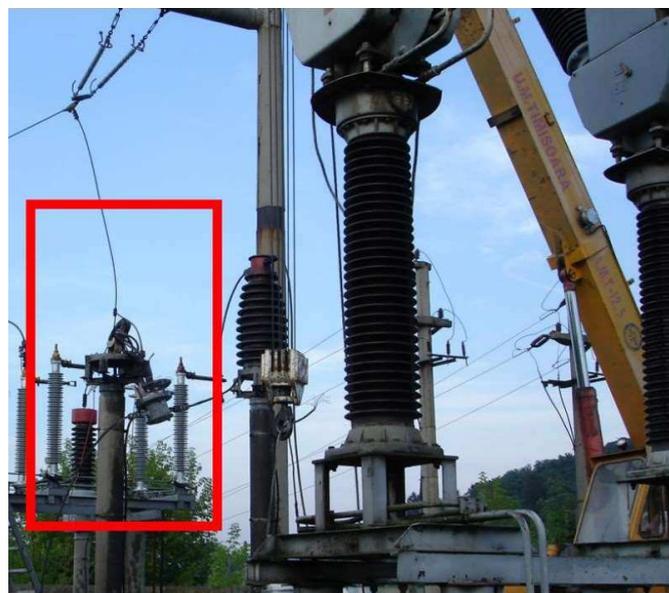
avaliação do risco de falhas de isolamento em equipamentos de alta tensão (BARTNIKAS, 2002; JUDD; YANG; HUNTER, 2005a; SCHICHLER et al., 2013).

Figura 1.1 - Gráfico de análise do modo de falhas de um grupo de 964 grandes falhas.



Fonte: Adaptado de CIGRE WORKING GROUP A2.37 (2015).

Figura 1.2 - Fotografia do Transformador de corrente tipo CESU 110 kV (925011/1979) destruído.



Fonte: Dan e Morar (2017).

Tradicionalmente, as DP são detectadas e avaliadas de acordo com os procedimentos descritos pelo método inserido na norma internacional IEC 60270 (2000), denominado, neste trabalho, método elétrico. A medição de DP pelo método elétrico requer o uso de um capacitor de acoplamento com isolamento adequado e livre de DP

conectado em paralelo com o equipamento monitorado. Devido à natureza invasiva do uso do capacitor de acoplamento, o nível de ruído presente em uma subestação e a complexidade em determinar a real fonte geradora das DP, a aplicação do método elétrico em campo é restrita a poucas aplicações, sendo utilizado majoritariamente em laboratório.

Como alternativa, outros métodos podem ser utilizados para o monitoramento de DP ou dos seus efeitos em subestações, dentre eles a análise de gases dissolvidos (AGD), o método de medição via Transformadores de Corrente de Alta Frequência (HFCT, do inglês: *High Frequency Current Transformer*), o método de detecção acústica e o método radiométrico.

A AGD é uma técnica amplamente utilizada para diagnosticar não conformidades em equipamentos, sendo majoritariamente aplicada no monitoramento de rotina em equipamentos isolados a óleo. Ela se baseia na medição e acompanhamento das concentrações acumuladas de gases dissolvidos em diferentes períodos de tempo, bem como nas proporções entre essas concentrações (KIRKBAS et al., 2020; TAHA; DESSOUKY; GHONEIM, 2021). Essa análise fornece informações sobre o estado do isolamento do equipamento e pode ajudar a identificar potenciais não conformidades como: superaquecimento, descargas parciais, baixa rigidez, risco de explosão, dentre outros. Além disso, nos últimos anos, têm surgido novas abordagens que exploram o uso de sensores químicos, oferecendo a perspectiva de monitoramento em tempo real (JIANG et al., 2019; JIN et al., 2020; SUN; OHODNICKI; STEWART, 2017). No entanto, é importante ressaltar que os resultados obtidos apenas por meio da AGD não são suficientes para determinar a localização da fonte geradora da não conformidade, sendo necessária a utilização de técnicas de diagnóstico mais detalhadas em conjunto com os dados fornecidos pela AGD.

No método de detecção de DP baseado na utilização de sensores HFCT, o sensor é acoplado ao cabo de aterramento do equipamento sob monitoramento (ÁLVAREZ et al., 2015; SUBRAMANIAM; RAMAN; PANDA, 2021). Dessa forma, é necessário o acesso ao cabo de conexão ao condutor terra do equipamento de alta tensão. Essa condição implica em limitações práticas quanto à sua aplicação em subestação, pois frequentemente os equipamentos de alta tensão são aterrados por múltiplos condutores de aterramento ou até mesmo por pedestal metálico.

No método de detecção acústica de DP, sensores piezoelétricos são aplicados para captar as variações de pressão causadas pela propagação das ondas sonoras provenientes das DP. No entanto, a detecção acústica é mais suscetível a ruídos mecânicos, elétricos e

externos (HUSSEIN; SHABAN; EL-HAG, 2018; MAHMOOD NAJAFI et al., 2013; MOHAMMAD et al., 2020). Além disso, devido às inúmeras atenuações ao longo do caminho de propagação da onda mecânica e à sua baixa magnitude, o método apresenta menor sensibilidade para defeitos internos, principalmente em um ambiente com baixa relação sinal ruído (FENG; SHAO, 2021; QIAN et al., 2018; RAJA; FLORIBERT, 2002). Por isso, os sensores acústicos devem ser posicionados próximo ao local em que está sendo emitida a DP. Assim, poder ser necessário reposicionar os sensores acústicos no equipamento até alcançar de uma sensibilidade ótima (COENEN; TENBOHLEN, 2012; MAHMOOD NAJAFI et al., 2013) ou utilizar um número maior de sensores para aumentar a sensibilidade do método (MARKALOUS; TENBOHLEN; FESER, 2008; RAJA; FLORIBERT, 2002).

A detecção radiométrica se baseia no princípio da emissão e captação de sinais eletromagnéticos por antenas (HAMPTON; MEATS, 1988). Dessa forma, o método radiométrico apresenta como vantagens a natureza não invasiva, sensibilidade na faixa de frequência desejada e robustez diante de sinais de descargas corona, cujas componentes significativas de energia estão compreendidas em faixas de frequências de até 300 MHz (JUDD, 2008; JUDD et al., 1999a; TANG et al., 2007). A pesquisa pioneira no monitoramento de descargas parciais utilizando o método radiométrico foi desenvolvida por Hampton e Meats (1988). Nesse estudo os pesquisadores realizaram diversos testes em laboratório utilizando corpos de prova pressurizados com SF₆, e em campo em uma subestação isolada a gás (GIS, do inglês: *Gas Insulated Substation*) de 420 kV pertencente ao grupo South of Scotland Electricity Board. Durante os testes, os sinais emitidos pelas fontes geradoras de DP eram registrados utilizando um analisador de espectro e identificados pelos momentos em que ocorriam as descargas no ciclo de tensão. Ademais, foram realizados testes para a localização de fontes de DP, utilizando dois sensores acopladores em cada lado da fonte de DP e medindo a diferença de tempo entre as frentes de onda que alcançaram os sensores.

A partir dos avanços obtidos por Hampton e Meats (1988), várias pesquisas foram conduzidas no campo do monitoramento de DP em GIS, utilizando sensores na faixa de frequência ultra alta (UHF, do inglês: *Ultra-High Frequency*). (HAMPTON et al., 1990; HAMPTON; IRWIN; LIGHTLE, 1990; LIGHTLE; HAMPTON; IRWIN, 1989; YUEN; CHAN, 1991; JUDD; FARISH; HAMPTON, 1996; MASAKI et al., 1994; PEARSON et al., 1995; MEIJER; GULSKI; SMIT, 1998). Com a consolidação do método radiométrico para a detecção, classificação e localização de DP em GIS, pesquisadores expandiram os

estudos para a aplicação do método radiométrico em outros equipamentos de alta tensão, como transformadores de potência (RUTGERS; FU, 1997; TENBOHLEN; BELTLE; SIEGEL, 2017; NOBREGA et al., 2018; PING et al., 2002; STRACHAN et al., 2005; TANG et al., 2009; XAVIER et al., 2021; JUDD; YANG; HUNTER, 2005b). Desse modo, o método radiométrico estabeleceu-se como uma abordagem aplicada na detecção, localização e classificação de DP em equipamentos elétricos (KAZIZ et al., 2023; LONG et al., 2021; ROSLIZAN et al., 2020; XAVIER et al., 2021).

1.1 RELEVÂNCIA

A detecção, a localização e a classificação de DP pelo método radiométrico requer a necessidade da obtenção de sinais de descargas parciais no espectro UHF, tornando-se necessário o uso de sistemas de aquisição com alta taxa de amostragem. A aquisição em alta taxa de amostragem requer instrumentação e acessórios adequados, como osciloscópios, analisadores de espectro, cabos e conexões para UHF. Na Figura 1.3, é apresentada uma fotografia que ilustra a medição de DP em uma subestação utilizando o método radiométrico. Em destaque, é possível verificar os instrumentos, compatíveis com UHF, que foram utilizados para adquirir os sinais de DP.

Figura 1.3 – Fotografia de medição de DP por meio do método radiométrico em subestação.



Fonte: (XAVIER, 2021).

No ambiente das subestações, tem-se campos elétricos e magnéticos intensos além de condições ambientais adversas, como umidade, poluição e variações de temperatura.

Nessas condições, os instrumentos utilizados podem ter seu desempenho e durabilidade comprometidos. Além disso, o risco de falha (queima) dos equipamentos eletrônicos é alto pela presença dos campos elétricos e magnéticos, assim como pela ocorrência de surtos. Cuidados devem ser observados durante as campanhas de aquisição periódicas, mas as adversidades do ambiente de subestação praticamente inviabilizam o monitoramento em tempo real. Portanto, é mais seguro e eficiente utilizar sistemas de monitoramento dedicados, especialmente projetados para a detecção e monitoramento *on-line* e em tempo real de DP em subestações.

Esta pesquisa foca no monitoramento de descargas parciais em equipamentos como TC, Transformador de Potencial Capacitivo (TPC), Transformador de Potencial (TP) ou mesmo para-raios. Para tanto, o sensor radiométrico é direcionado ao equipamento a ser inspecionado.

Diferentemente do método elétrico, o método radiométrico não pode ser calibrado e o monitoramento é feito pela evolução dos parâmetros classificatórios das descargas parciais no tempo. Tradicionalmente, a classificação das fontes de DP é realizada por meio da análise PRPD (do inglês: *Phase-Resolved Partial Discharge*). A partir da análise PRPD, é possível observar em um único gráfico as ocorrências de DP em uma fase específica da tensão aplicada, com certa magnitude de carga e, dessa forma, identificar o tipo de descarga com base no padrão obtido.

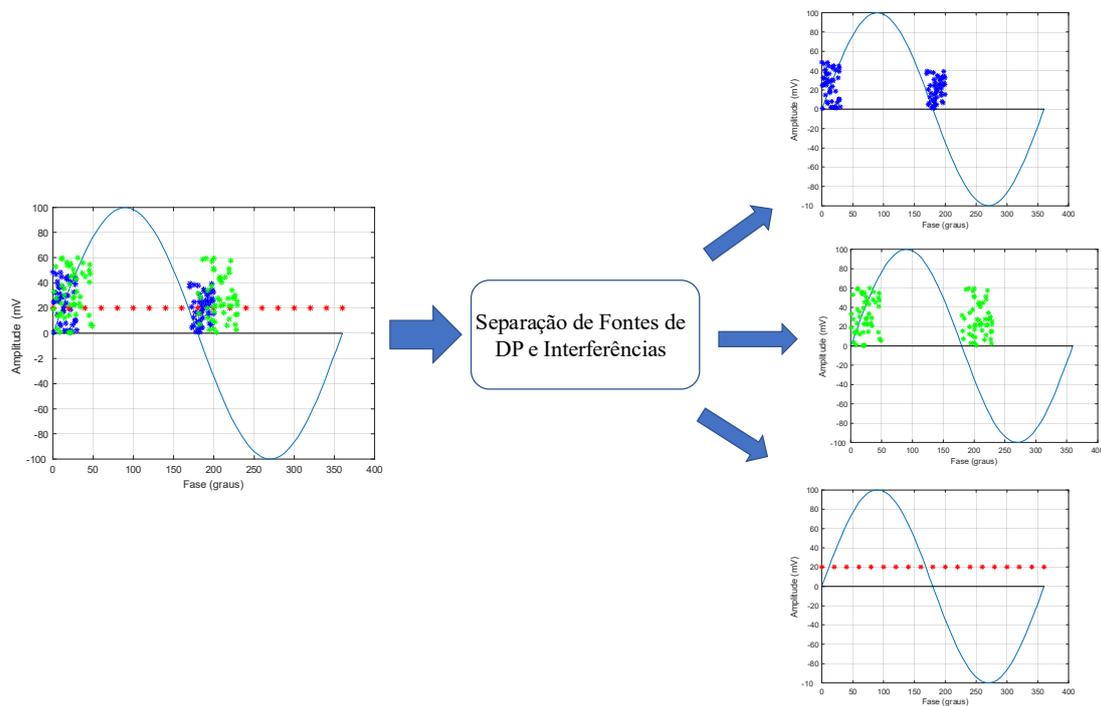
Um dos principais desafios da utilização do PRPD para um processo de classificação, e posteriormente o diagnóstico, é a presença simultânea de múltiplas fontes de DP ou ruído. Os padrões obtidos nessas condições são difíceis de interpretar, porque os sinais podem se sobrepor e fontes de maior amplitude ocultar a presença de outros tipos de fontes com menor amplitude (ARDILA-REY et al., 2020; CAVALLINI et al., 2003b; ROBLES et al., 2016). Ademais, muitas das fontes omitidas podem ser ou se tornar potencialmente mais danosas ao equipamento monitorado. Por esse motivo, recomenda-se a realização de um processo de separação para auxiliar na identificação de defeitos (ALVAREZ et al., 2016b; HAO et al., 2011; ROBLES et al., 2016).

Quando se necessita monitorar uma subestação completa ou os sensores radiométricos apresentam características omnidirecionais, a presença simultânea de múltiplas fontes pode ocultar a verdadeira fonte danosa de descargas. Essa problemática carece ainda mais de atenção no monitoramento por redes de sensores sem fio (WSN, do inglês: *Wireless Sensor Network*), uma vez que a técnica não é focada em um único

equipamento, mas no ambiente de subestação sujeito a diversos tipos de ruídos e fontes de DP.

Na Figura 1.4, é possível verificar um exemplo de sobreposição de fontes de descargas parciais (DP) e interferências em um gráfico de PRPD. Conforme evidenciado na Figura 1.4, a etapa de separação das fontes de DP deve ser realizada antes da interpretação, a fim de identificar corretamente cada fonte e evitar a omissão de possíveis defeitos associados.

Figura 1.4 - Esquemático do processo de separação e identificação de fontes DP e/ou ruído.



Fonte: Autoria própria.

Ao separar os sinais, torna-se possível distinguir e analisar individualmente cada um deles, evitando que informações relevantes sejam negligenciadas. Essa abordagem permite a identificação de equipamentos com descargas e contribui para a manutenção e monitoramento adequados.

Como exposto, existem dois desafios ainda na detecção de descargas parciais: a utilização de *hardware* aplicáveis ao ambiente de subestações e a ocorrência de múltiplas fontes de DP e interferências que podem ocorrer durante o monitoramento.

1.2 MOTIVAÇÃO

Diante das considerações mencionadas, como a importância da separação das fontes de descarga parcial (DP) e ruídos para a interpretação correta do sinal de DP, bem como a necessidade de um sistema de aquisição de dados escalável e economicamente viável para uso em subestações, esta tese propõe soluções complementares que visam atender a essas demandas.

A primeira solução proposta é o desenvolvimento de um sistema de condicionamento de sinais, baseado na técnica de detecção de envoltória, que reduza os requisitos de *hardware* do sistema de monitoramento, ao mesmo tempo em que mantém informações relevantes do sinal. Essa abordagem visa aumentar a aplicabilidade do método em subestações, tornando-o mais acessível e confiável em termos de implementação. Além disso, a utilização de um sistema de condicionamento de sinais dedicado para o monitoramento de DP possibilita a implementação do monitoramento *online* em larga escala, atendendo às necessidades de modernização e eficiência das infraestruturas elétricas.

A segunda solução proposta envolve a utilização das informações extraídas da envoltória do sinal para realizar a separação e classificação dos sinais, utilizando técnicas de aprendizado de máquina. Essa abordagem permite distinguir diferentes fontes de DP e ruídos, possibilitando uma análise confiável e eficiente, essencial para a manutenção preditiva e a gestão de ativos das subestações.

As soluções propostas trabalham em conjunto para proporcionar um sistema de monitoramento de DP eficaz e de maior utilidade prática. Ao reduzir os requisitos de *hardware* e utilizar técnicas avançadas de aprendizado de máquina, é possível obter resultados efetivos e relevantes na identificação e interpretação das descargas parciais. Isso contribui significativamente para a melhoria da segurança, disponibilidade e confiabilidade das subestações.

1.3 OBJETIVOS

Os objetivos desta tese se dividem em geral e específicos, conforme destacado nas subseções seguintes.

1.3.1 OBJETIVO GERAL

O objetivo geral desta pesquisa é desenvolver um sistema de condicionamento de sinais baseado na obtenção de envoltória capaz de ser utilizado na detecção e classificação de sinais de DP e propor algoritmos dedicados à identificação e à separação de fontes de DP a partir de atributos extraídos da envoltória do sinal de DP.

1.3.2 OBJETIVOS ESPECÍFICOS

Para atingir o objetivo geral da pesquisa, elencam-se os seguintes objetivos específicos:

- propor e configurar um sistema de condicionamento de sinais entre a antena e o instrumento de aquisição, dedicado à detecção da envoltória dos sinais de DP, que permita a geração de um amplo banco de dados para análise exhaustiva das envoltórias dos sinais de DP detectados, com diferentes fontes de DP;
- avaliar a capacidade e efetividade do sistema de condicionamento de sinal na redução dos requisitos de taxa de amostragem, por meio da análise dos níveis de frequência das envoltórias dos sinais de DP detectados;
- investigar exhaustivamente na literatura atributos capazes de fornecer uma separação efetiva entre diferentes fontes de DP a partir das envoltórias dos sinais;
- investigar minuciosamente e selecionar, dentre os atributos extraídos das envoltórias, aqueles que possuem maior relevância e poder discriminatório na separação dos sinais de DP, por meio da aplicação de algoritmos de seleção de atributos;
- investigar e comparar técnicas de aprendizado de máquina, aplicadas na separação e classificação de sinais radiométricos de DP, a fim de avaliar o desempenho e a robustez de cada abordagem na separação e classificação de sinais de DP a partir das envoltórias de sinais radiométricos.

1.4 CONTRIBUIÇÕES

Pelo exposto no decorrer das subseções anteriores, destaca-se que as principais contribuições desta pesquisa são:

- Desenvolvimento de um sistema que permita que a aquisição de sinais de DP seja realizada com uma taxa de amostragem reduzida, ocasionando redução dos requisitos de *hardware* do sistema de monitoramento e maior aplicabilidade em campo para detecção, classificação e localização de defeitos.
- Identificação de técnicas de aprendizado de máquina e de atributos eficazes extraídos das envoltórias dos sinais de DP para separação e classificação de sinais de DP.

1.5 PUBLICAÇÕES

Os resultados obtidos até o momento na pesquisa, bem como os resultados relacionados a ela, foram divulgados a partir de publicações de artigos em periódicos e congressos científicos conforme apresentado a seguir.

Publicação em periódicos:

Carvalho, I. F.; da Costa, E. G.; Nobrega, L. A. M. M.; Silva, A. D. C. Identification of Partial Discharge Sources by Feature Extraction from a Signal Conditioning System. *Sensors* 2024, 24, 2226. <https://doi.org/10.3390/s24072226>.

Silva, A. D. C.; **Carvalho, I. F.**; Nóbrega, L. A. M. M.; Xavier, G. R.; da Costa, E. G. Avaliação de técnicas de inteligência artificial na classificação de descargas parciais. *Tecnologia em Marcha*, v. 34, p. 232-244, 2021.

Santos Júnior, A. C. d.; Serres, A. J. R.; Xavier, G. V. R.; da Costa, E. G.; Serres, G. K. F.; Leite Neto, A. F.; **Carvalho, I. F.**; Nobrega, L. A. M. M.; Lazaridis, P. Classification of Partial Discharge Sources in Ultra-High Frequency Using Signal Conditioning Circuit Phase-Resolved Partial Discharges and Machine Learning. *Electronics* 2024, 13, 2399. <https://doi.org/10.3390/electronics13122399>.

Publicação em congressos:

Carvalho, I. F.; da Costa, E. G.; Nóbrega, L. A. M. M.; Silva, A. D. C.; Lira, G. S.; Costa, A. I.; Marotti, A. F. Classification of Radiometric Partial Discharge Signals Using Signal Conditioning System. In: IEEE International Conference on High Voltage Engineering and Application, 2024 Berlin, Germany. ICHVE 2024.

Silva, A. D. C.; Freire, R. C. S.; Nobrega, L. A. M. M.; **Carvalho, I. F.;** Alves, L. F. B. Assessment of an Instrumentation System for Radiometric Monitoring of High-Voltage Equipment. In: 8th International Symposium on Instrumentation Systems, Circuits and Transducers (INSCIT), 2024, João Pessoa. International Symposium on Instrumentation Systems, Circuits and Transducers, 2024.

Carvalho, I. F.; Santos, A. J.; Nóbrega, L. A. M. M.; da Costa, E. G.; Silva, A. D. C.; Lira, G. S.; Marotti, A. F.; Costa, A. I.; Souza, J. A. PRPD Analysis in Current Transformers Using UHF Sensors and Signal Conditioning System. In: 23rd International Symposium on High Voltage Engineering, 2023 Glasgow, UK. ISH 2023.

Silva, A. D. C.; **Carvalho, I. F.;** Nóbrega, L. A. M. M.; Xavier, G. R.; da Costa, E. G. Avaliação de técnicas de inteligência artificial na classificação de descargas parciais. In: XV Congreso Iberoamericano de Alta tensión y Aislamiento Eléctrico, 2021, San José. ALTAE 2021.

Santos, A. J.; **Carvalho, I. F.;** Xavier, G. R.; da Costa, E. G.; Nobrega, L. A. M. M. Artificial Intelligence Applied to PRPD Patterns Classification Using UHF Printed Monopole Antenna and Envelope Detector. In: 23rd International Symposium on High Voltage Engineering, 2023 Glasgow, UK. ISH 2023.

Silva, A. D. C.; Freire, R. C. S.; Nobrega, L. A. M. M.; **Carvalho, I. F.;** Xavier, G. R.; da Costa, E. G.; Melo, J. V. J. Location of Partial Discharges Sources Using Radiometric Signal Envelopes. In: 23rd International Symposium on High Voltage Engineering, 2023 Glasgow, UK. ISH 2023.

Silva, A. D. C.; Freire, R. C. S.; Nobrega, L. A. M. M.; **Carvalho, I. F.;** Xavier, G. R.; Silva, H. D.; Souza, A. S. Evaluation of Envelope Detection for Radiometric Measurements of Partial Discharges in Instrument Transformers. In: 7th International Symposium on Instrumentation Systems, Circuits and Transducers, 2023 Rio de Janeiro, BR. INSCIT 2023.

1.6 ORGANIZAÇÃO DO TEXTO

O texto desta tese está dividido em seis capítulos. No Capítulo 2 é apresentada a fundamentação teórica que serve como base para o desenvolvimento do trabalho, contemplando conceitos sobre descargas parciais, técnicas de monitoramento, técnicas de detecção de envoltória e técnicas de separação e classificação de DP.

Em seguida, no Capítulo 3 é apresentada a revisão bibliográfica, na qual são destacados trabalhos correlatos ao tema desta tese, focando no monitoramento da atividade de DP utilizando a técnica radiométrica e na separação e classificação de sinais de DP. Adicionalmente, são abordados estudos que empregam sistemas de condicionamento de sinal baseados na técnica de detecção de envoltória para a detecção de DP, analisando suas contribuições e resultados obtidos.

No Capítulo 4 é apresentada a metodologia aplicada para a realização dos experimentos e utilização dos algoritmos necessários para atingir os objetivos específicos e geral estabelecidos.

O Capítulo 5 é dedicado a apresentação, discussão e análise dos resultados alcançados ao longo da pesquisa.

Por fim, o Capítulo 6 apresenta uma síntese das principais conclusões do trabalho, assim como a proposição de trabalhos à continuidade da pesquisa, sugerindo direções que podem ser exploradas para expandir o conhecimento e aprofundar os resultados obtidos.

2 FUNDAMENTAÇÃO TEÓRICA

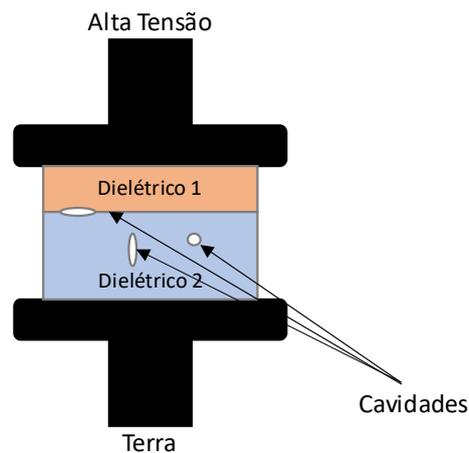
Neste capítulo é apresentada a fundamentação teórica com os conceitos necessários à compreensão do trabalho desenvolvido. Dessa forma, são abordados conceitos relacionados a descargas parciais, técnicas de monitoramento da atividade de DP, detecção da envoltória de sinais, extração e seleção de atributos de sinais de DP, bem como técnicas de agrupamento e classificação.

2.1 DESCARGAS PARCIAIS

As DP são descargas elétricas localizadas que curto-circuitam parcialmente a isolação de equipamentos (NATTRASS, 1988). A ocorrência de DP é atribuída à existência de campos elétricos intensos em áreas específicas do material isolante, combinada com uma quantidade mínima de elétrons disponíveis para iniciar o processo de avalanche eletrônica. Portanto, a ocorrência de DP é influenciada pela aplicação de tensão no equipamento ou material e é caracterizada por sua natureza estocástica, uma vez que a ocorrência da avalanche eletrônica depende da configuração dos elétrons disponíveis no momento do fenômeno.

As descargas parciais podem ser classificadas em três categorias de acordo com a natureza de sua localização: descargas internas, descargas superficiais e descargas corona. As descargas internas ocorrem em cavidades preenchidas com gás, presentes nos materiais sólidos e líquidos usados em sistemas de isolamento. Uma das principais razões para o surgimento de descargas internas em cavidade é a menor rigidez dielétrica dos gases, quando comparadas às dos líquidos ou sólidos. Essa diferença provoca a intensificação do campo elétrico dentro da cavidade, resultando em disrupções localizadas (KREUGER, 1989; MACÊDO, 2014). Na Figura 2.1 pode-se observar uma ilustração de um sistema de isolamento com cavidades.

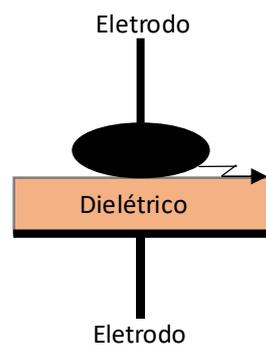
Figura 2.1 - Exemplo de isolamento com falhas que podem causar descargas parciais.



Fonte: Adaptado de Macêdo (2014).

Diferente das descargas internas, as descargas superficiais ocorrem na superfície de um material dielétrico, geralmente partindo do eletrodo para a superfície. O processo de descarga superficial é iniciado quando a componente de campo elétrico tangente à superfície excede um determinado valor crítico. Esse tipo de descarga geralmente ocorre em terminações de cabos, buchas, saias de isoladores ou em enrolamentos de geradores (KREUGER, 1989). Na Figura 2.2, é possível observar uma representação de descarga superficial.

Figura 2.2 - Representação de descarga parcial superficial.

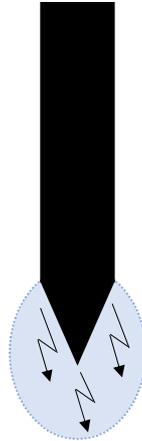


Fonte: Autoria própria.

Descargas corona ocorrem em meios gasosos quando há uma intensificação do campo elétrico nas proximidades de um eletrodo. As pontas e extremidades de eletrodos apresentam pequenos raios de curvatura com campo elétrico elevado, o qual proporciona a ocorrência da ionização do gás que envolve o eletrodo, dando origem à descarga corona

(KREUGER, 1989). Um esquemático representativo da descarga corona pode ser observado na Figura 2.3.

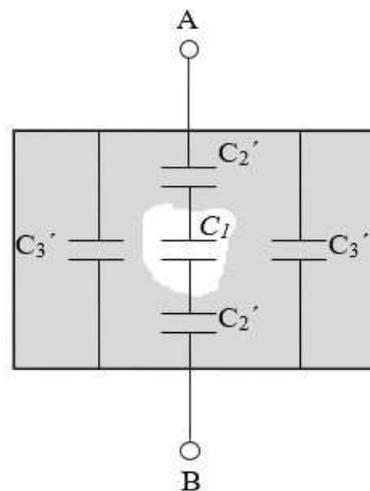
Figura 2.3 - Esquemático representativo de descarga corona.



Fonte: Autoria própria.

O fenômeno de ocorrência de descargas parciais pode ser modelado por meio de um circuito capacitivo que representa um material dielétrico no qual existe uma cavidade preenchida por um gás, geralmente o ar, conforme apresentado na Figura 2.4.

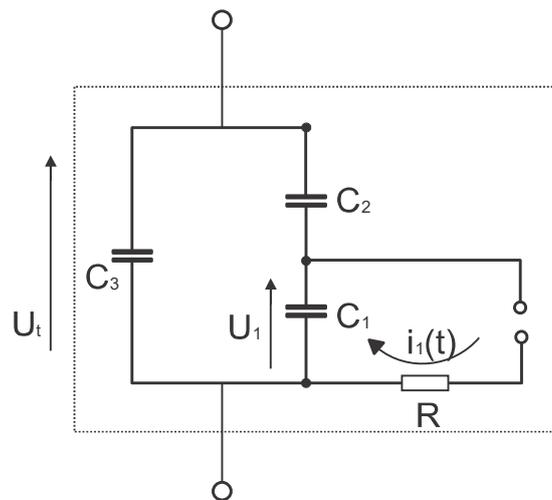
Figura 2.4 – Modelo representativo do fenômeno de descargas parciais.



Fonte: Costa e Neves (1996).

O modelo de descargas parciais apresentado na Figura 2.4 pode ser representado por meio de um circuito equivalente que pode ser visualizado na Figura 2.5. No circuito equivalente, C_1 representa a capacitância da cavidade do dielétrico, C_2 a capacitância do material que está em série com a cavidade, C_3 a capacitância restante da amostra e R_1 representa a resistência do arco elétrico da descarga.

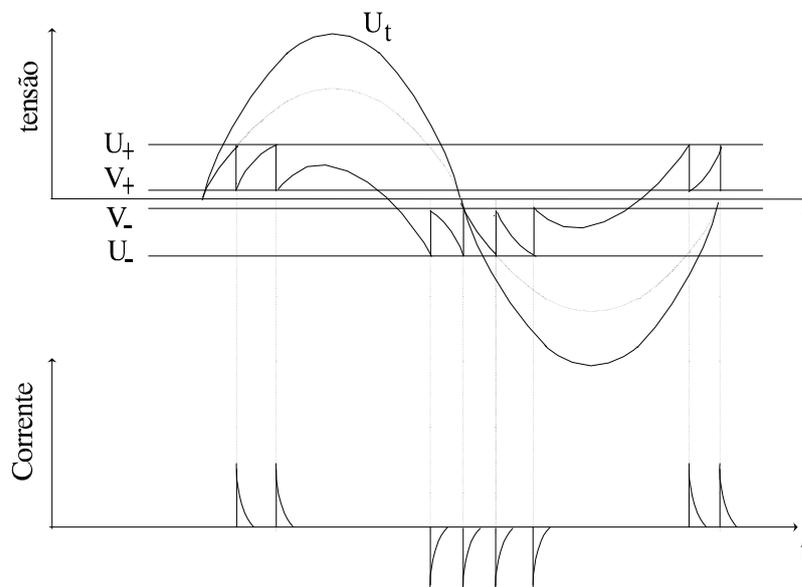
Figura 2.5 - Circuito elétrico equivalente para o modelo de descargas parciais.



Fonte: Adaptado de Costa e Neves (1996).

No circuito elétrico da Figura 2.5, é possível observar que o dielétrico é submetido a uma tensão alternada $U_t(t)$ nos seus terminais. Para compreender o processo de formação de DP em um dielétrico, um gráfico representativo do fenômeno pode ser visualizado na Figura 2.6.

Figura 2.6 - Gráfico representativo do processo de descargas parciais em um dielétrico.



Fonte: Costa e Neves (1996).

Quando a tensão U na cavidade atinge o valor de U_+ , a cavidade gasosa com baixa rigidez dielétrica perde sua capacidade de isolamento e é dado início o processo de descarga. Após a descarga é possível verificar a formação de um pulso de corrente e a

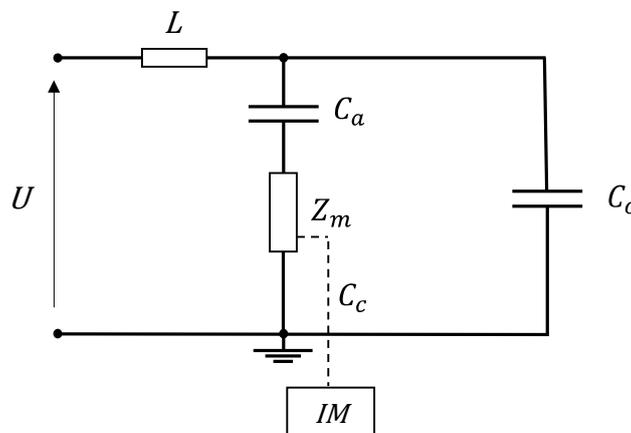
redução da tensão até V_+ , processo semelhante à aplicação de degrau de tensão U_+ sobre o capacitor C_l . Enquanto a cavidade é submetida a um crescimento de tensão, o valor de V_+ aumenta até que a ruptura ocorra novamente, reiniciando o processo. O procedimento descrito ocorre de modo análogo para o semiciclo negativo. O intervalo entre o início e a extinção da descarga é da ordem de nanosegundos, gerando pulsos de corrente de alta frequência nos terminais de isolamento.

A atividade de descargas parciais pode ser medida e quantificada por meio de diferentes técnicas, tais como o método padrão estabelecido na norma IEC 60270 (2000), a análise de gases dissolvidos (AGD), o monitoramento acústico, o monitoramento utilizando HFCT e o monitoramento radiométrico. Neste trabalho, são abordados dois métodos, o método padrão estabelecido pela norma IEC 60270 (2000) e o método radiométrico que é a técnica na qual esta pesquisa é baseada.

2.1.1 MÉTODO ELÉTRICO CONVENCIONAL DEFINIDO NA NORMA IEC 60270(2000)

O método elétrico convencional definido pela norma IEC 60270 (2000) para medição de DP utiliza um capacitor de acoplamento, uma impedância externa para a medição, uma indutância para interferências oriundas da fonte de tensão e um sistema de aquisição de dados. Seguindo as diretrizes da norma IEC 60270 (2000), existem diversas configurações para a medição por meio do método convencional. Nesta tese, adotou-se o arranjo apresentado na Figura 2.7 como configuração de referência.

Figura 2.7 - Esquemático de medição proposto pela IEC 60270 (2000).



Fonte: Adaptado de IEC 60270 (2000).

O circuito apresentado na Figura 2.7 é composto por:

- um objeto de teste, que pode ser considerado como um capacitor C_O ;
- um capacitor de acoplamento C_a ;
- uma fonte de alimentação de alta tensão U ;
- um indutor L para filtrar sinais de descargas oriundos da fonte de alimentação;
- uma impedância Z_m para medição do sinal de DP;
- um cabo coaxial C_c ;
- um instrumento de medição IM , geralmente um detector comercial de DP ou um osciloscópio com alta taxa de aquisição.

O instrumento de medição utilizado deve medir a carga aparente "q" expressa em picocoulomb (pC). Para tanto, a calibração do sistema de medição deve ser feita por meio da injeção de pulsos de corrente utilizando um calibrador, conectado aos terminais do objeto de teste. O objetivo da calibração é avaliar a resposta do sistema de medição, isto é, se o sistema de medição é capaz de quantificar corretamente a magnitude de DP especificada.

Considerando que a capacitância C_O do objeto de teste afeta as características do circuito, a calibração deve ser feita com cada novo objeto de teste, a menos que os testes sejam feitos em uma série de objetos semelhantes com valores de capacitância dentro de $\pm 10\%$ dos valores médios (IEC60270, 2000).

O método elétrico, definido pela norma, apresenta as vantagens de ser padronizado, calibrável, reproduzível e, portanto, confiável e amplamente utilizado. Em virtude disso, ele é estabelecido como método de referência e tem sido utilizado na rotina de testes de aceitação de equipamentos. No entanto, apesar das vantagens destacadas, o método citado possui limitações para sua aplicação em campo, devido à necessidade de utilização de um capacitor de acoplamento conectado em paralelo, razão pela qual o método é majoritariamente utilizado em laboratório.

2.1.2 MÉTODO RADIOMÉTRICO

O método de detecção radiométrica consiste na detecção da irradiação produzida pelo pulso de DP. Tipicamente, um sinal de DP é caracterizado como um sinal de curta duração, da ordem de nanossegundos, que produz uma irradiação eletromagnética que se propaga em todas as direções, com uma faixa de frequência que varia de

aproximadamente 50 MHz a 3 GHz, a depender do tipo de defeito e meio de propagação (TENBOHLEN et al., 2023; CHEN et al., 2003). Por exemplo, em transformadores de potência, as atividades de DP se concentram principalmente na faixa de frequência de 300 MHz até 1,5 GHz (JUDD et al., 1999a). Para GIS a faixa de frequência predominante compreende a faixa de 300 MHz a 3 GHz (HAMPTON; MEATS, 1988).

Uma das principais vantagens oferecidas pelo método radiométrico é a sua natureza não invasiva, visto que o método dispensa conexão elétrica com o objeto de teste. Além disso, a faixa de frequência típica das antenas usadas (NOBREGA et al., 2019a; XAVIER et al., 2019), entre 300 MHz e 1500 MHz, confere ao método a possibilidade de eliminar descargas corona, uma vez que as principais componentes de energia dessas descargas se concentram em frequências de até 300 MHz (TANG et al., 2007; TENBOHLEN et al., 2008).

O monitoramento da atividade de DP utilizando o método radiométrico é realizado por meio de sensores, comumente projetados em faixa de frequência UHF. De acordo com o seu local de instalação, um sensor UHF pode ser de três tipos: sensores externos, sensores internos e sensores tipo sonda. As três categorias de sensores são descritas brevemente a seguir.

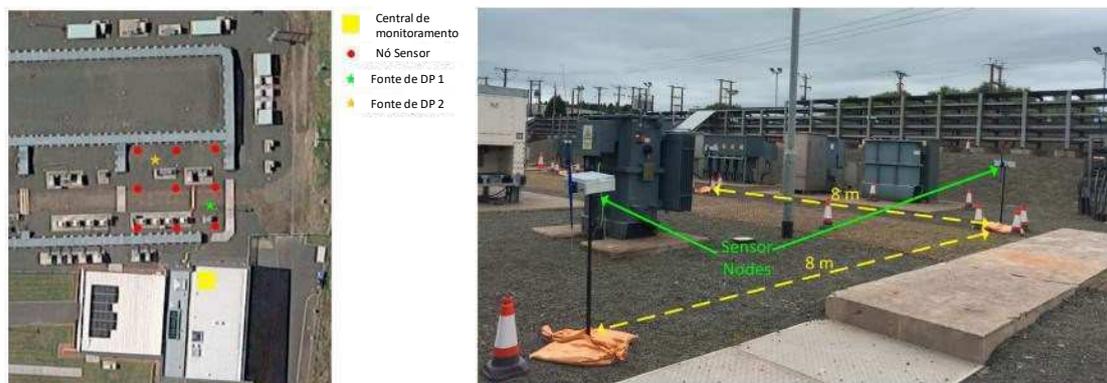
2.1.2.1 SENSORES EXTERNOS

Sensores externos são dispostos na parte externa dos equipamentos de alta tensão. Com a utilização desses sensores, é possível não apenas monitorar a atividade de DP em um equipamento elétrico específico, mas também realizar a detecção e localização de mais de uma fonte de defeitos em uma subestação, a depender do arranjo utilizado.

Na Figura 2.8, é possível observar um arranjo contendo uma rede de sensores para monitoramento e localização da atividade de DP em um ambiente de subestação. Os sensores estão conectados a uma central de monitoramento capaz de detectar qual equipamento está sob o efeito de DP.

Para o uso de sensores externos no monitoramento da atividade de DP, deve-se considerar que ocorrem perdas de propagação dos sinais eletromagnéticos irradiados da fonte até o sensor. Além disso, para o monitoramento de uma subestação torna-se necessário a utilização de muitos sensores, cuja quantidade dependerá do tamanho da área que necessita ser monitorada.

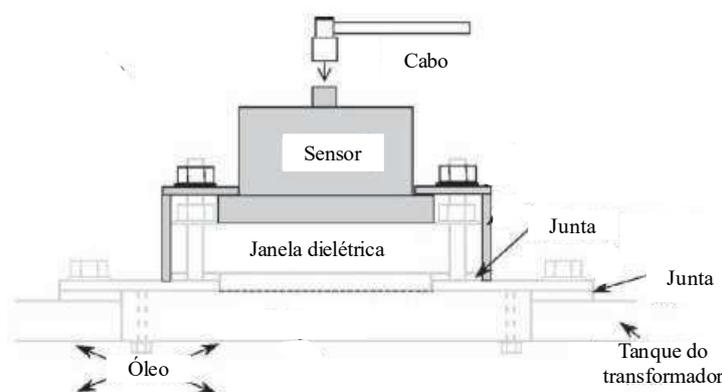
Figura 2.8 – Arranjo de detecção e localização de DP utilizado nos sensores conectados a uma central de monitoramento.



Fonte: Upton et al. (2017).

Sensores externos também podem ser instalados em aberturas no tanque de transformadores de potência, utilizando janelas dielétricas projetadas para esse fim, ou por meio de adaptações nas escotilhas de inspeção. Na Figura 2.9, pode ser observado um esquema ilustrativo de instalação de um sensor externo do tipo janela em um equipamento.

Figura 2.9 - Desenho esquemático de um sensor instalado em uma janela dielétrica de um transformador de potência.



Fonte: Adaptado de Judd e Hunter (2005).

Como pode ser verificado na Figura 2.9, é necessária a inserção de um dielétrico entre o sensor e a parte interna do equipamento, criando assim a chamada janela dielétrica. O meio com o material dielétrico possibilita que a irradiação eletromagnética seja transmitida até o sensor. Para escolher o material dielétrico adequado, devem ser consideradas suas propriedades mecânicas, químicas e vida útil. Isso se deve ao fato de que a janela dielétrica deve ser capaz de resistir a condições operacionais adversas, tais como variações de pressão do óleo e possíveis exposições a substâncias químicas ou

umidade presentes no ambiente. Além disso, o projeto mecânico deve ser cuidadosamente executado para assegurar que a janela não seja exposta ao ambiente externo, permanecendo sempre coberta pelo sensor ou por uma placa metálica de proteção, a fim de manter a pressão do óleo dentro do equipamento em níveis normais. Alguns exemplos de materiais dielétricos que podem ser considerados incluem o politetrafluoretileno (PTFE ou teflon) e a resina epóxi (JUDD; YANG; HUNTER, 2005b).

Uma dificuldade inerente ao uso de sensores acoplados ao tanque é a necessidade de realizar adaptações nos equipamentos já em operação, o que requer uma interrupção na operação para diminuir o nível de óleo e instalar as escotilhas necessárias. Portanto, a fase mais apropriada para a instalação de janelas dielétricas é durante a fabricação do equipamento. A partir disso, desde 2008, o CIGRÉ recomenda que transformadores de potência sejam fabricados com janelas dielétricas para viabilizar o monitoramento radiométrico de DP (CIGRE WORKING GROUP A2.27, 2008).

2.1.2.2 SENSORES INTERNOS

Os sensores do tipo interno são aqueles instalados no interior do tanque permanentemente e projetados para o monitoramento contínuo do equipamento. Eles permanecem em contato com o gás ou óleo isolante, por esse motivo, apresentam um revestimento com material isolante, anticorrosivo, antioxidante e tolerante a altas temperaturas, como a resina epóxi (LIU; LI, 2010). Na Figura 2.10, pode ser observado um transformador de potência com um sensor interno acoplado.

Figura 2.10 - Fotografia de transformador de potência com sensor interno acoplado.

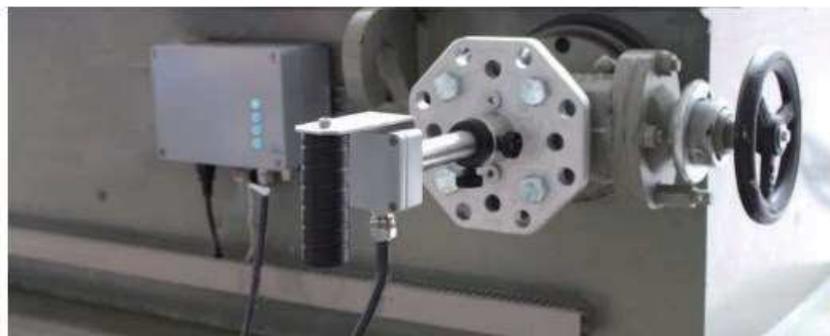


Fonte: Liu e Li (2010).

2.1.2.3 SENSORES TIPO SONDA

Sensores tipo sonda são aplicados em transformadores de potência a partir de suas válvulas de óleo. A aplicação desse tipo de sensor é possível mesmo em transformadores em serviço. Além disso, também é permitida sua instalação permanente como parte de um sistema de monitoramento de DP *on-line*. A antena deve ser inserida no transformador até fornecer sensibilidade suficiente, pois se o sensor permanecer dentro válvula, o sensor terá baixa sensibilidade devido à blindagem eletromagnética. Comumente, uma profundidade de inserção de aproximadamente 50 mm é um valor razoável (SIEGEL et al., 2017). Além das considerações de sensibilidade, uma distância mínima entre o sensor UHF e as partes em alta tensão deve ser preservada para garantir que falhas ou curto-circuito não ocorram. Na Figura 2.11, é mostrada uma fotografia de um sistema de monitoramento com um sensor tipo sonda instalado em um transformador (SIEGEL; BELTLE; TENBOHLEN, 2016).

Figura 2.11 – Fotografia de sensor tipo sonda instalado em um transformador de potência.



Fonte: Siegel, Beltle e Tenbohlen (2016).

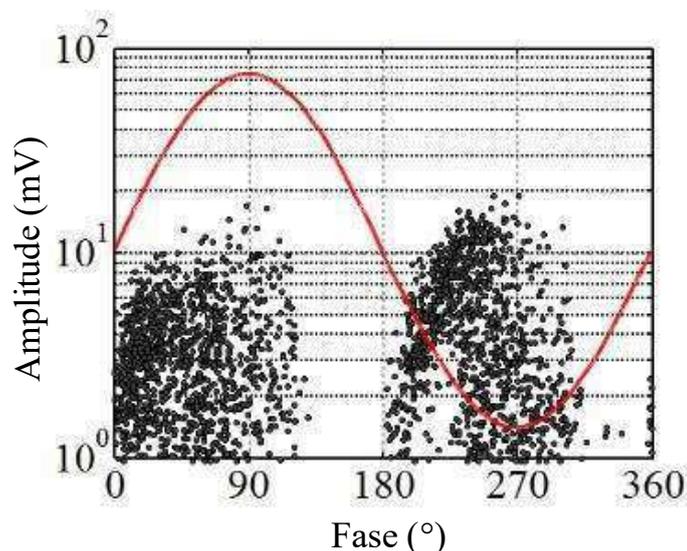
2.1.3 INTERPRETAÇÃO DE DESCARGAS PARCIAIS POR MEIO DA ANÁLISE

PRPD

A análise PRPD é uma das técnicas mais utilizadas para classificar tipos de DP, com base nos padrões obtidos. Para realizar a análise PRPD, é construído um gráfico no qual o eixo das abscissas representa a informação de fase, utilizando para tal um ciclo da tensão aplicada, e no eixo das ordenadas são exibidas a magnitude da carga (pC) ou nível de tensão (mV) das DP. Assim, com base no posicionamento dos sinais de DP no ciclo de tensão, um tipo de descarga é associado a um padrão específico. Na Figura 2.12, é

possível verificar um gráfico PRPD no qual cada ponto representa informações sobre a fase e a intensidade de cada sinal de DP medido e o aglomerado dos pontos indica o padrão ou padrões de defeitos.

Figura 2.12 -Padrão PRPD correspondente a uma medição de descarga parcial.

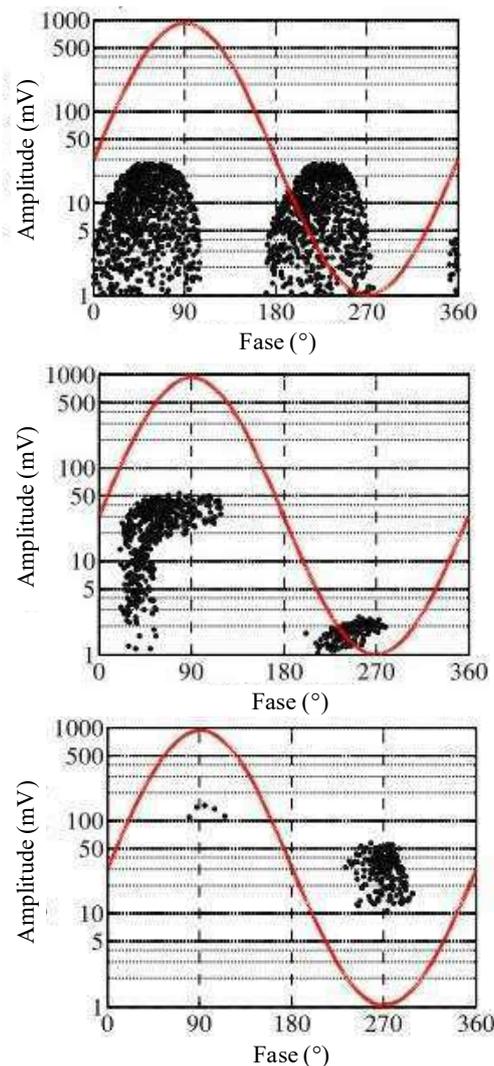


Fonte: Alvarez et al. (2016).

A técnica de análise PRPD relaciona um tipo de DP a um padrão PRPD específico, contudo, em uma amostra ou equipamento se pode ter várias fontes de descargas parciais. Se uma descarga corona ocorre e o eletrodo está conectado à alta tensão, a manifestação das descargas no gráfico PRPD aparece na crista do semiciclo negativo, perto do ângulo de fase 270°. Por outro lado, se uma descarga corona ocorre e o eletrodo está conectado ao aterramento do circuito, a concentração de descargas aparece na crista do semiciclo positivo da senoide, próximo a 90° (NATTRASS, 1988).

Na ocorrência de descargas internas, tem-se uma maior concentração dos pulsos nas fases de transição da senoide, isto é, próximos aos valores de 0° e 180°, a depender da localização da descarga no interior do material isolante. Por fim, na ocorrência de descargas superficiais, constata-se uma distribuição com maior uniformidade dos pulsos de descarga para todas as fases referentes a um dos semiciclos de onda da senoide e há uma assimetria ao comparar os padrões de ambos os semiciclos. Na Figura 2.13, é possível verificar o padrão PRPD correspondente a descargas internas, superficiais e corona, respectivamente.

Figura 2.13 – Padrão PRPD de descargas internas, superficiais e corona, respectivamente.



Fonte: Alvarez et al. (2016).

2.2 DETECÇÃO DA ENVOLTÓRIA DO SINAL

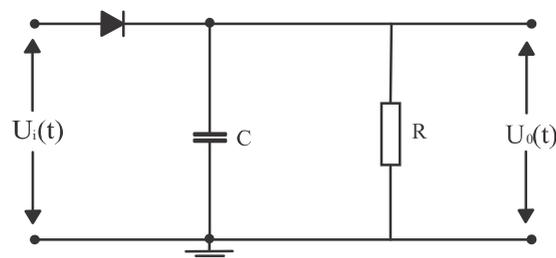
O sinal digital, ao se propagar, está sujeito a variações em suas características, podendo sofrer mudanças de intensidade e fase. Essas mudanças são resultado de diversos fenômenos que ocorrem durante a transmissão, podendo comprometer a integridade da informação transmitida. Dessa forma, para detectar o sinal transmitido, o receptor deve estar em sincronismo com a fase da portadora local, refletindo as mudanças de fase no canal. Isso caracteriza a detecção coerente, que, devido à necessidade de um circuito de recuperação de portadora, tem um aumento da complexidade do sistema, que pode resultar em custos adicionais e maior consumo de energia. No entanto, vale ressaltar que

nenhum sistema prático de comunicação digital coerente operará sob perfeita coerência de fase, uma vez que não existe um circuito de recuperação de portadora ideal (GUIMARÃES; SOUZA, 2015). Por outro lado, a detecção não coerente, que não exige sincronização de portadora, é mais simples, mas apresenta degradação de desempenho em comparação com a detecção coerente.

Um exemplo de circuito que apresenta detecção não coerente é o circuito de detecção de envoltória. O circuito detector de envoltória é simples, de baixo custo, e amplamente utilizado em diferentes aplicações, tais como análise de sinal de ultrassom (ASSEF et al., 2018; SCHLAIKJER et al., 2003; LYONS, 2017) e aplicações de radiofrequência (RF) (GE et al., 2020; TEIKARI; HALONEN, 2006; YITONG; ZHAO; KAI, 2016).

A técnica de detecção de envoltória consiste em passar o sinal modulado por um dispositivo não-linear e em seguida por um filtro para refinar o sinal e, dessa forma, filtrar componentes remanescentes de alta frequência. Os dispositivos não-lineares comumente utilizados são diodos e para a suavização do sinal são utilizados filtros passa-baixa. Na Figura 2.14 um exemplo de circuito detector de envoltória simples pode ser observado.

Figura 2.14 – Circuito detector de envoltória.



Fonte: Autoria própria.

A primeira etapa do projeto do circuito detector de envoltória consiste no dimensionamento geral do circuito. A capacitância e a resistência do filtro devem ser definidas de modo que seja obtida uma constante RC maior que o período da portadora $\left(\frac{1}{f_c}\right)$ e menor que a máxima variação do sinal mensagem $\left(\frac{1}{f_{max}}\right)$. Em resumo, a constante de tempo RC deve satisfazer à Equação (2.1):

$$\frac{1}{f_c} \ll RC \ll \frac{1}{f_{max}}. \quad (2.1)$$

O capacitor determina o desempenho do detector de envoltória. Portanto, a seleção dos parâmetros R e C é um passo crucial para o correto dimensionamento do

circuito (LIU; LI, 2010). O diodo utilizado no circuito de retificação deve ser selecionado de acordo com as características do sinal de entrada. Para sinais radiométricos de DP, por exemplo, devido as suas componentes de ultra alta frequência, é necessário que o diodo utilizado possua resposta rápida, ou seja, tempo de comutação extremamente rápido, da ordem de nanosegundos ou menos. Diodos Schottky são exemplos de diodos que possuem rápida resposta e baixa tensão de polarização direta (usualmente menor que 0,3 V), o que resulta em baixas perdas de potência durante a condução.

Para avaliar o desempenho do circuito de detecção de envoltória, a análise por software é frequentemente empregada, utilizando-se estratégias que vão desde a simulação do circuito projetado, até métodos de suavização que promovem a extração da envoltória de sinais, como o método de suavização de densidade por Kernel (KDE, do inglês: *Kernel Density Estimation*) (WEGLARCZYK, 2018).

O algoritmo de geração de envoltória baseado no KDE pode ser sintetizado em três passos (PINPART, 2010; PINPART; JUDD, 2010). O primeiro passo consiste na remoção do nível CC do sinal de entrada. A remoção de possíveis deslocamentos CC presentes nos sinais amostrados é realizada para que, em aplicações destinadas à comparação de envoltórias, todos os sinais comparados compartilhem uma base comum. O segundo passo consiste em elevar ao quadrado os pontos de dados amostrados de tensão com o objetivo de produzir uma forma de onda unipolar proporcional à potência instantânea do sinal. Além disso, a elevação ao quadrado visa evitar a possibilidade de valores nulos na forma de onda suavizada, preservando a forma de onda do sinal original. Por fim, a última etapa consiste em implementar o estimador por Kernel Gaussiano. O KDE é efetivamente um filtro passa-baixa e, portanto, possibilita a redução da taxa de amostragem para gravar envoltórias de sinais radiométricos de DP. O KDE aplicado à criação de envoltórias de sinais UHF de DP pode ser definido como (PINPART, 2010; PINPART; JUDD, 2010):

$$En_i = \sum_{j=1}^n K\left(\frac{t_i - t_j}{W}\right) \cdot VS_j / \sum_{j=1}^n K\left(\frac{t_i - t_j}{W}\right), \quad (2.2)$$

em que:

- En_i é o componente suavizado da envoltória na i -ésima amostra;
- VS_j é a tensão instantânea ao quadrado na j -ésima amostra;
- t_i e t_j são amostras de tempo no i -ésimo e j -ésimo ponto;

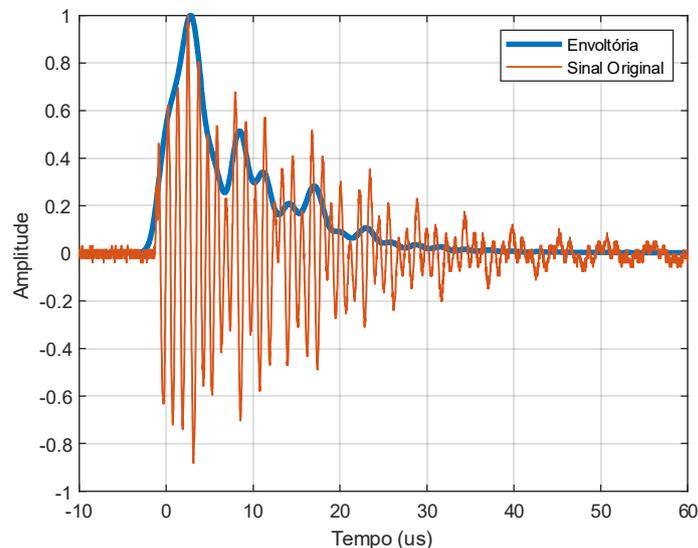
- W representa o parâmetro de suavização para a estimativa de densidade de Kernel $\hat{f}(x)$;
- K é a função de suavização Kernel Gaussiana dada por:

$$K(t) = \frac{1}{\sqrt{2\pi} \cdot (0,37^2)} e^{\left(-\left(\frac{t_i-t_j}{W}\right)^2 / 2 \cdot 0,37^2\right)}, \quad (2.3)$$

em que, 0,37 é o fator de ponderação.

Um exemplo do processo de extração de envoltória pode ser observado na Figura 2.15, em que a curva em vermelho é o sinal de radiofrequência (RF), denominado sinal original, e a curva em azul representa a envoltória do sinal de RF.

Figura 2.15 – Sinal RF e sua respectiva envoltória.



Fonte: Autoria própria.

A análise da Figura 2.15 revela que, embora haja uma clara suavização do sinal original, a envoltória tende a manter a forma característica do sinal. Esse aspecto ressalta a eficácia da técnica de detecção de envoltória como uma alternativa viável para reduzir os requisitos de *hardware* do sistema de aquisição, ao mesmo tempo em que preserva as informações essenciais do sinal. Dessa forma, é possível alcançar uma diminuição do custo computacional e um aumento da eficácia do sistema.

2.3 ATRIBUTOS DE SINAIS DE DESCARGAS PARCIAIS

Quando as interferências externas do ambiente de medição são minimizadas, é possível vincular sinais de DP ao tipo de falha e equipamento que está emitindo o defeito, ou seja, o local de falha (MACÊDO, 2014). Esta associação pode ser realizada por meio da extração de atributos dos sinais de descarga parcial.

A extração de atributos dos sinais de DP possibilita a obtenção de informações acerca das características intrínsecas das DP. Essa abordagem permite uma análise mais detalhada e robusta dos sinais emitidos durante o processo. A relevância do procedimento reside na capacidade de associar padrões específicos de sinais a fontes e/ou tipos de descargas, proporcionando entendimentos sobre a condição operacional e a integridade dos equipamentos sob monitoramento.

Assim, para descrever características de uma DP, grandezas básicas relacionadas à forma de onda do sinal e operadores estatísticos podem ser utilizadas. Essas grandezas podem ser definidas como os parâmetros intrínsecos ao pulso de DP, tais como intensidade do sinal, tempo de subida, tempo de descida, duração do pulso e energia do sinal. Por outro lado, os operadores estatísticos, de acordo com Gulski e Kreuger (1992), são operadores para análise estatística de parâmetros deduzidos dos sinais de DP. Dentre os principais parâmetros derivados e estatísticos destacam-se (HAN et al., 2019; LIU; LIU; HU, 2009):

- Valor de pico (V_p):

$$V_p(x) = \max(x_i), i = 1, 2, \dots, N. \quad (2.4)$$

- Valor RMS (V_{RMS}):

$$V_{RMS}(x) = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}. \quad (2.5)$$

- Amplitude Média (A_{med}):

$$A_{med}(x) = \frac{1}{N} \sum_{i=1}^N |x_i|. \quad (2.6)$$

- Amplitude da Raíz Quadrada (A_{r2}):

$$A_{r2}(x) = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right)^2. \quad (2.7)$$

- Fator de Crista (F_c):

$$F_c(x) = \frac{V_p(x)}{V_{RMS}(x)} \quad (2.8)$$

- Fator de Liberação (F_L):

$$F_L(x) = \frac{V_p(x)}{A_{r2}(x)} \quad (2.9)$$

- Fator de Impulso (F_I):

$$F_I(x) = \frac{V_p(x)}{V_{med}(x)} \quad (2.10)$$

- Fator de Forma (F_F):

$$F_F(x) = \frac{V_{RMS}(x)}{V_{med}(x)} \quad (2.11)$$

- Assimetria (*Skewness* - S_k):

$$S_k(x) = \frac{E(x - \mu)^3}{\sigma^3} \quad (2.12)$$

- Curtose (*Kurtosis* - K_u):

$$K_u(x) = \frac{E(x - \mu)^4}{\sigma^4} \quad (2.13)$$

Em que, x_i é o valor da amostra i , N é o número total de pontos, μ é a média de x , σ é o desvio padrão de x e E representa o valor esperado.

Ao incorporar técnicas de processamento de sinais, a extração de atributos viabiliza a implementação de algoritmos inteligentes para agrupamento e classificação de DP. Isso não apenas facilita a identificação precoce de potenciais defeitos, mas também contribui para a otimização dos programas de manutenção, resultando em maior disponibilidade, confiabilidade operacional e redução de custos associados a paradas não programadas.

2.3.1 SELEÇÃO DE ATRIBUTOS

A seleção de atributos é a etapa que proporciona o maior conhecimento de uma base de dados. Pelo uso de seleção criteriosa são selecionados atributos com maior qualidade e informação para a separação ou classificação a ser realizada e eliminados atributos redundantes ou não-informativos. Além disso, ao selecionar atributos, a quantidade de dados é reduzida, proporcionando assim uma maior eficiência do algoritmo de classificação. As principais abordagens utilizadas para a seleção de atributos são:

Wrappers, Filtros e Embedded (BLUM; LANGLEY, 1997; RODRIGUEZ-GALIANO et al., 2018).

Na abordagem *Wrapper*, o algoritmo de aprendizado é utilizado para guiar o processo de seleção de atributos. O algoritmo de aprendizado avalia cada subconjunto de atributos e usa a acurácia do classificador para avaliar e definir o melhor subconjunto (JOHN; KOHAVI; PFLEGER, 1994). Para tanto, o algoritmo analisa exaustivamente as combinações possíveis de variáveis, de modo a tornar o custo computacional alto, mesmo para conjunto de dados que não possuem uma quantidade grande de atributos, visto que o número de avaliações de subconjuntos cresce exponencialmente com o número de atributos (HALL, 2000).

O *Recursive Feature Elimination* (RFE) é um bom exemplo de método de seleção de features baseado na abordagem *Wrapper*. O RFE é uma técnica de seleção de atributos utilizada para otimizar modelos de aprendizado de máquina. A abordagem começa com a construção de um modelo utilizando todos os atributos disponíveis, seguida pela avaliação da importância de cada um dos atributos para o desempenho do modelo (GUYON; WESTON; BARNHILL, 2002). No decorrer do processo, o RFE elimina de forma iterativa os atributos considerados menos significativos e reconstrói o modelo após cada remoção. O ciclo se repete até que se alcance um conjunto definido de atributos, que idealmente representam o equilíbrio ideal entre simplicidade do modelo e capacidade de previsão. A principal vantagem deste método é a sua eficácia em reduzir a complexidade do modelo, melhorando tanto a eficiência computacional quanto a generalização do modelo em dados não vistos anteriormente.

Na abordagem *Embedded* (Embutida), o subconjunto de atributos é selecionado durante a fase de treinamento do modelo de classificação. Os métodos embutidos se apresentam vantajosos sobre os *Wrapper* porque a seleção de atributos é parte do processo de aprendizagem, ou seja, o método de extração está embutido no algoritmo de classificação, o que diminui os custos e permite que sejam praticáveis em dados com maior dimensionalidade (GARCIA; PARAISO; NIEVOLA, 2017). Um exemplo da abordagem *Embedded* são os algoritmos de indução de árvores de decisão, nos quais a seleção de atributos é realizada no processo de definição dos nós que irão formar as árvores de decisão.

Diferente da abordagem *Wrapper* e *Embedded*, as abordagens de seleção de atributo do tipo Filtro são independentes do método de aprendizado utilizado para classificação. Ou seja, métodos de filtros são aplicados em uma etapa de pré-

processamento para filtrar atributos que serão posteriormente utilizados em um algoritmo de aprendizado.

Quatro parâmetros de avaliação de atributos são comumente utilizadas em métodos de Filtro (DASH; LIU, 1997):

- Distância: medida de separabilidade, divergência ou discriminação entre atributos. Um exemplo é a medida de distância euclidiana.
- Informação: critério que determina o ganho de informação com o uso de um determinado atributo. Dessa forma, os atributos escolhidos são aqueles que possuem maior ganho de informação.
- Dependência: qualifica a capacidade de prever o valor de um atributo a partir de outro. A medida de dependência pode ser utilizada para classificar o quanto dois atributos estão correlacionados e avaliar o valor de redundância do atributo.
- Consistência: encontra subconjunto mínimo de atributos que satisfaz a taxa de inconsistência aceita, que é geralmente definida pelo usuário. Dessa forma, a medida de consistência é fortemente dependente do conjunto de treinamento e de hipóteses bem definidas.

Os parâmetros citados podem ser utilizados associadas a métodos de busca ou utilizadas no ranqueamento de atributos, onde serão selecionados os atributos que ultrapassem um determinado valor de relevância.

Quando existem muitos atributos que separam perfeitamente os dados, técnicas baseadas na abordagem filtro, que selecionam atributos classificando-os com coeficientes de correlação, são amplamente utilizadas. Ao efetuar uma análise de correlação, é possível reduzir a dimensionalidade do conjunto de atributos, já que atributos perfeitamente correlacionados são redundantes, não agregando informações adicionais ao modelo (GUYON; ELISSEEFF, 2003).

O coeficiente de correlação de Pearson é uma medida estatística que avalia a relação linear entre duas variáveis quantitativas, definido como:

$$R(i) = \frac{cov(X_i, Y)}{\sqrt{var(X_i)var(Y)}} \quad (2.14)$$

Em que *cov* corresponde a covariância e *var* a variância. Considerando o conjunto de *m* exemplos $\{x_k, y_k\}$ consistindo em *n* variáveis de entrada $x_{k,i}$ ($i = 1, \dots, n$) e uma variável de saída, $R(i)$ é dado por:

$$R(i) = \frac{\sum_{k=1}^m (x_{k,i} - \bar{x}_i) (y_k - \bar{y})}{\sqrt{\sum_{k=1}^m (x_{k,i} - \bar{x}_i)^2 \sum_{k=1}^m (y_k - \bar{y})^2}}, \quad (2.15)$$

sendo a notação de barra representa uma média sobre o índice k .

Assim, após avaliar o coeficiente de correlação, é possível filtrar os melhores atributos. O coeficiente de correlação varia de -1 a +1, de forma que quanto maior o seu valor absoluto, mais fortemente as variáveis estão correlacionadas. Coeficientes de correlação positivos indicam que um atributo x aumenta conforme o valor do atributo y cresce. Em contrapartida, se o coeficiente é negativo, as variáveis estão correlacionadas negativamente.

A correlação, por ser uma estatística de segunda ordem, avalia apenas a dependência linear entre os atributos e o sinal de interesse. Portanto, caso o modelo em questão seja não linear, outras técnicas como a Informação Mútua podem ser mais apropriadas. A Informação Mútua mede a dependência estatística entre duas variáveis, ou seja, o quanto a informação de uma variável ajuda a prever a outra. Diferentemente da correlação, a Informação Mútua não se restringe a relações lineares e pode capturar dependências mais complexas e não lineares entre as variáveis (GUYON; ELISSEEFF, 2003; KRASKOV; STÖGBAUER; GRASSBERGER, 2004).

A Informação Mútua é avaliada a partir do cálculo da quantidade de informação compartilhada entre a variável de interesse e cada atributo. Dessa forma, é possível identificar quais atributos são mais relevantes para a classificação ou previsão. Matematicamente, a Informação Mútua está associada à entropia e pode ser calculada a partir da Equação (2.16):

$$IM(X, Y) = H(X) + H(Y) - H(X, Y), \quad (2.26)$$

Em que $IM(X, Y)$ é a informação mútua para X e Y , $H(X)$ é a entropia para X e $H(X, Y)$ é a entropia condicional para X dado Y . O resultado varia de zero a um, e quanto maior o resultado, maior a quantidade de informação compartilhada entre as variáveis.

A seleção de atributos desempenha um papel fundamental na análise de dados e na construção de modelos de aprendizado de máquina. Esta seção explorou diferentes abordagens, como *Wrapper*, Filtro e *Embedded*, cada uma oferecendo métodos distintos para identificar e selecionar os atributos mais relevantes para um modelo. Desde a análise exaustiva de subconjuntos de atributos até a integração da seleção durante o treinamento do modelo, essas técnicas permitem reduzir a dimensionalidade dos dados, melhorar a eficiência dos algoritmos de classificação e aumentar a capacidade de generalização dos

modelos para novos dados. Compreender e aplicar adequadamente as técnicas de seleção de atributos não apenas aprimora a qualidade dos modelos, mas também impulsiona a tomada de decisões mais informadas e eficazes com base nos dados disponíveis.

2.4 TÉCNICAS DE CLASSIFICAÇÃO E AGRUPAMENTO

Técnicas de classificação e agrupamento são amplamente utilizadas na análise de dados, oferecendo diversas vantagens, como a otimização de processos, redução de custos operacionais e ampliação da compreensão dos dados. A classificação organiza os dados em categorias predefinidas, enquanto o agrupamento identifica padrões e estruturas inerentes aos dados sem a necessidade de conhecimento prévio, facilitando a segmentação e a descoberta de informações relevantes. Ambas as técnicas auxiliam na tomada de decisões e aumentam a capacidade de previsão e análise dos dados. Nesta seção, serão discutidas técnicas de classificação e agrupamento amplamente utilizadas.

2.4.1 TÉCNICAS DE CLASSIFICAÇÃO

A classificação é uma área do aprendizado de máquina que atribui uma classe, rótulos predefinidos, para um novo dado de acordo com suas características. A classificação pode se dividir em binária ou multiclasse, abrangendo diversas técnicas, tais como Regressão Logística (DREISEITL; OHNO-MACHADO, 2002; KLEINBAUM; KLEIN, 2002), Máquinas de Vetor de Suporte (SVM, do inglês: *Support Vector Machines*) (BHAVSAR; PANCHAL, 2012; CHANDRA; BEDI, 2021), Árvores de decisão e florestas aleatórias (ALI et al., 2012; BERNARD; HEUTTE; ADAM, 2009).

A regressão logística é um modelo comumente utilizado para classificação, devido à sua capacidade de estimar a probabilidade de uma instância pertencer a uma classe específica (GÉRON, 2022; LAVALLEY, 2008). O modelo de regressão logística considera o logaritmo natural das probabilidades como uma função de regressão dos preditores. Assim, considerando que a relação das probabilidades pode ser escrita como:

$$\frac{z}{(1 - z)}, \quad (2.37)$$

sendo z representa a propabilidade do evento positivo, ou seja, a probabilidade do evento que se deseja prever. A função logística (*logit function*) pode ser definida como:

$$\text{logit}(z) = \log \frac{z}{(1-z)}. \quad (2.48)$$

A função logística é conhecida por sua capacidade de transformar valores de entrada do intervalo de 0 a 1, em valores no intervalo completo de números reais. Isso possibilita a expressão de uma relação linear entre os valores dos recursos e as probabilidades logarítmicas (RASCHKA; MIRJALILI, 2019):

$$\text{logit}(z(y=1|x)) = w_0 \cdot x_0 + w_1 \cdot x_1 + \dots + w_m \cdot x_m = \sum_{i=0}^m w_i \cdot x_i = w^T \cdot x, \quad (2.59)$$

em que $z(y=1|x)$ é a probabilidade condicional que um exemplo específico pertença à classe 1, dados os seus atributos, x .

Assim, a probabilidade de um determinado exemplo pertencer a uma classe específica é dada pela função sigmoide logística:

$$\emptyset(s) = \frac{1}{1 + e^{-s}}, \quad (2.20)$$

em que s é a combinação linear de pesos e entradas, $w^T x$. A partir da Equação 2.20 é possível inferir que $\emptyset(s)$ tende a 1 se s tende ao infinito, visto que e^{-s} torna-se muito pequeno para valores grandes de s . Do mesmo modo, $\emptyset(s)$ tende a 0 quando s tende ao negativo infinito, já que e^{-s} torna-se muito grande para valores negativos grandes de s . Assim, é possível inferir que a função sigmoide transforma valores reais de entrada em valores no intervalo $[0,1]$.

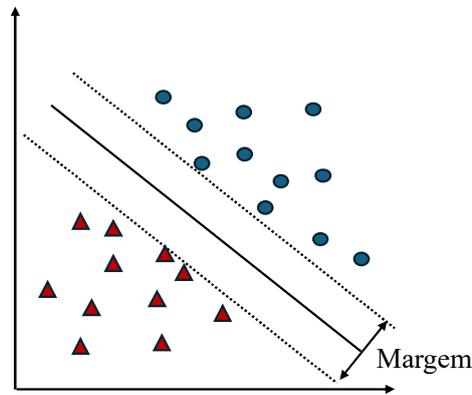
Além da classificação binária, a Regressão Logística pode ser facilmente generalizada para configurações multiclasse, conhecida Regressão Logística Multinomial, caracterizada por sua simplicidade de implementação e eficiência no treinamento. Essa capacidade de generalização amplia significativamente a aplicabilidade desse modelo em uma variedade de cenários de aprendizado supervisionado.

Outro modelo de aprendizado de máquina poderoso e amplamente utilizado é a máquina de vetores de suporte (SVM). O SVM é capaz de realizar classificação linear ou não linear, regressão e até mesmo detecção de valores discrepantes (GÉRON, 2022; RASCHKA; MIRJALILI, 2019).

Na classificação linear as classes podem ser facilmente separadas por uma linha reta, conforme ilustrado na Figura 2.16. A linha sólida no gráfico representa o limite de decisão de um classificador SVM. Este limite não apenas separa as duas classes, mas também é escolhido para maximizar a margem entre as instâncias de treinamento mais próximas. Isso é chamado de classificação de margem máxima, ou seja, o classificador

não apenas busca separar as classes, mas também procura encontrar um hiperplano que maximiza a margem entre as instâncias mais próximas de diferentes classes (CORTES; VAPNIK, 1995; VAPNIK, 1999).

Figura 2.16 – SVM com classificação linear.



Fonte: Autoria própria.

A fim de compreender como o SVM encontra um hiperplano ótimo, considere o conjunto de treinamento rotulado (CORTES; VAPNIK, 1995):

$$(y_1, x_1), \dots, (y_i, x_i), \quad y_i \in \{-1, 1\}. \quad (2.21)$$

Cada ponto x_i pertence a uma das classes, positiva (+1) ou negativa (-1). Dessa forma, supõem-se que existe um hiperplano que separa os pontos positivos dos negativos. Para que os dados sejam linearmente separáveis deve existir um vetor w e um escalar b tal que as desigualdades

$$w \cdot x_i + b \geq 1 \quad \text{se } y_i = 1, \quad (2.22)$$

$$w \cdot x_i + b \leq -1 \quad \text{se } y_i = -1, \quad (2.23)$$

sejam válidas para todos os elementos dos conjuntos de treinamento. Assim combinando as Equações 2.22 e 2.23:

$$y_i(w \cdot x_i + b) \geq 1, \quad i = 1, 2, \dots, N \quad (2.24)$$

O hiperplano ótimo $w_0 x + b_0 = 0$ é o único que separa conjunto de treinamento com uma margem máxima. Isso determina a direção $w/\|w\|$ onde a distância entre as projeções dos vetores de treinamento de duas classes diferentes é máxima (CORTES; VAPNIK, 1995).

A distância $\rho(w_0, b_0)$ é definida por:

$$\rho(w_0, b_0) = \min_{\{x:y=1\}} \frac{x \cdot w}{|w|} - \max_{\{x:y=-1\}} \frac{x \cdot w}{|w|}. \quad (2.25)$$

O hiperplano ótimo (w_0, b_0) é o argumento que maximiza a distância $\rho(w_0, b_0)$. Assim, combinando as equações 2.24 e 2.25:

$$\rho(w_0, b_0) = \frac{2}{|w_0|} = \frac{2}{\sqrt{w_0 \cdot w_0}}. \quad (2.26)$$

Portanto, o hiperplano ótimo que gera a margem máxima é o único que minimiza $\|w\|^2$ sujeito à restrição da Equação 2.24 (CORTES; VAPNIK, 1995).

Embora os classificadores SVM lineares sejam eficientes em muitos casos, na maioria dos ambientes práticos, os dados de treinamento não são linearmente separáveis (GÉRON, 2022; MOHRI; ROSTAMIZADEH; TALWALKAR, 2018). Assim, para manipular dados não linearmente separáveis as restrições lineares do SVM precisam ser relaxadas para permitir a convergência da otimização na presença de ruídos e erros de classificação, com a devida penalização de custos (MOHRI; ROSTAMIZADEH; TALWALKAR, 2018; RASCHKA; MIRJALILI, 2019).

Conforme destacado, o SVM pode ser utilizado tanto na classificação de dados linearmente separáveis como em dados não lineares. O SVM possui várias vantagens em relação a outros algoritmos devido à sua capacidade de lidar com espaços de alta dimensionalidade, poder de generalização e robustez a outliers.

Assim como as SVMs, as Árvores de Decisão, ou *Decision Trees*, são algoritmos versáteis de aprendizado de máquina que podem executar tarefas de classificação e regressão. Esses algoritmos constroem uma estrutura semelhante a um fluxograma, composta por "nós" nos quais condições são verificadas. Se a condição for atendida, o fluxo segue por um ramo específico; caso contrário, segue por outro. O processo continua até a finalização da árvore. Durante a construção da árvore, o algoritmo utiliza os dados de treinamento para identificar as melhores condições a serem avaliadas em cada nó e decide como incorporá-las no fluxo. Para dividir os nós nas características mais informativas, é necessário definir uma função objetivo para otimizar por meio do algoritmo de aprendizado de árvore (RASCHKA; MIRJALILI, 2019). Assim, a função objetivo é maximizar o ganho de informação (IG, do inglês: *Information gain*) em cada divisão, que é definido por:

$$IG(D_p, r) = I(D_p) - \sum_{f=1}^m \frac{N_f}{N_p} I(D_f), \quad (2.27)$$

em que r é o atributo para realizar a divisão; D_p e D_f são o conjunto de dados do nó pai e do f -ésimo nó filho; I é a medida de impureza; N_p é o número total de exemplos de

treinamento no nó pai; e N_f é o número de exemplos no f -ésimo nó filho. Nota-se que o ganho de informação é simplesmente a diferença entre a impureza do nó pai e a soma das impurezas do nó filho. Assim, quanto menores forem as impurezas dos nós filhos, maior será o ganho de informação (RASCHKA; MIRJALILI, 2019).

As três medidas comumente usadas de impureza do nó são entropia (I_E), índice Gini (I_G) e erro de classificação (I_C). A entropia mede o grau de desordem ou de impureza. Assim, considerando que todas as classes de uma base de dados são não vazias ($p(j|n) \neq 0$), a entropia é definida como:

$$I_E(n) = - \sum_{j=1}^c p(j|n) \log_2 p(j|n). \quad (2.28)$$

A proporção de dados que pertencem a classe j para um nó n é representado por $p(j|n)$. A entropia é, portanto, zero se todos os exemplos em um nó pertencem à mesma classe, e a entropia é máxima se houver uma distribuição de classes uniforme. Para o caso em que existem apenas duas classes, a entropia é 0 se $p(1|n) = 1$ ou $p(0|n) = 0$. Se as classes forem distribuídas uniformemente com $p(1|n) = 0,5$ e $p(0|n) = 0,5$, a entropia é 1.

O índice Gini também mede o grau de desordem ou de impureza. No entanto, o cálculo é feito de forma diferente:

$$I_G(n) = \sum_{j=1}^c p(j|n) (1 - p(j|n)) = 1 - \sum_{j=1}^c p(j|n)^2. \quad (2.29)$$

A partir da Equação 2.29, nota-se que o índice Gini é 0 (nó puro) se todas as instâncias de treinamento pertencem a uma mesma classe. Por outro lado, quando o índice Gini é máximo (nó impuro) aumenta o número de classes uniformemente distribuídas neste nó.

Em aplicações práticas, tanto a impureza de Gini como a entropia geralmente produzem resultados muito semelhantes. A impureza de Gini é um pouco mais rápida de calcular. Contudo, quando diferem, a impureza de Gini tende a isolar a classe mais frequente no seu próprio ramo da árvore, enquanto a entropia tende a produzir árvores ligeiramente mais equilibradas (GÉRON, 2022).

Uma outra medida de impureza é o erro de classificação:

$$I_C(n) = 1 - \max \{p(j|n)\}. \quad (2.30)$$

O erro de classificação é um critério útil para poda, mas não recomendado para o crescimento de uma árvore de decisão, pois é menos sensível a mudanças nas

probabilidades de classe dos nós (MOHRI; ROSTAMIZADEH; TALWALKAR, 2018). Assim, o índice de Gini e os critérios de entropia são normalmente preferidos na prática.

As Árvores de Decisão parecem relativamente fáceis de interpretar e isto é frequentemente sublinhado como uma das suas características mais úteis. No entanto, tais interpretações devem ser realizadas com cuidado, uma vez que as árvores de decisão são instáveis: pequenas alterações nos dados de treino podem resultar em divisões muito diferentes e, portanto, a árvores completamente diferentes, como resultado da sua natureza hierárquica (MOHRI; ROSTAMIZADEH; TALWALKAR, 2018). Além disso, as árvores de decisão possuem uma característica que pode limitar sua eficácia na aprendizagem preditiva: a imprecisão. Elas raramente fornecem precisão preditiva comparável à melhor que pode ser alcançada com os dados disponíveis. Assim, aumentar as Árvores de Decisão melhora sua precisão, ao mesmo tempo, mantém a maioria das suas propriedades desejáveis para mineração de dados (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

As Árvores de Decisão são os componentes fundamentais de um algoritmo de aprendizado de máquina que está entre os mais robustos disponíveis atualmente, as Florestas Aleatórias (GÉRON, 2022). A Floresta Aleatória é um classificador que consiste em uma coleção de classificadores estruturados em árvore (BREIMAN, 2001):

$$\{h(x, \theta_k)\}, \quad (2.31)$$

sendo $\{\theta_k\}$ são vetores aleatórios independentes distribuídos de forma idêntica e cada árvore dá um voto unitário para a classe mais popular na entrada x .

Nas Florestas Aleatórias, o algoritmo inicia selecionando aleatoriamente algumas amostras do conjunto. A escolha aleatória cria uma diversidade entre as árvores individuais da floresta, tornando o método robusto, capaz de lidar com diferentes perspectivas dos dados e menos suscetível a *overfitting* (RASCHKA; MIRJALILI, 2019). Em resumo, enquanto as Árvores de Decisão constroem uma única estrutura de decisão, as Florestas Aleatórias combinam múltiplas árvores criadas a partir de subconjuntos aleatórios dos dados de treinamento, aumentando a eficácia e a generalização do modelo.

2.4.2 TÉCNICAS DE AGRUPAMENTO

Assim como na classificação, no agrupamento, ou clusterização, cada instância é atribuída a um grupo. No entanto, o agrupamento é uma tarefa não supervisionada que consiste na implementação de técnicas computacionais para separar um conjunto de

dados em diferentes grupos com base em suas semelhanças. A noção de similaridade depende da tarefa em questão. Em alguns casos, duas instâncias próximas serão consideradas semelhantes, enquanto em outros casos semelhantes podem estar distantes, desde que pertençam ao mesmo grupo densamente compactado (GÉRON, 2022). Diferentemente de algoritmos de classificação e regressão, algoritmos de agrupamento são não supervisionados, ou seja, os algoritmos devem entender as relações entre dados sem estarem rotulados a nenhuma categoria prévia.

Os algoritmos de agrupamento podem ser divididos nos seguintes tipos: agrupamento baseado em centroides, agrupamento baseado em densidades, agrupamento baseado em distribuições e agrupamento hierárquico.

As técnicas de agrupamento baseadas em centroides têm como objetivo encontrar, a partir de uma quantidade determinada de grupos (ou *clusters*), os centroides que representam o centro de cada cluster. A partir dos centroides, identifica-se a que cluster cada ponto pertence com base na distância até cada um dos centroides. Um exemplo amplamente utilizado de algoritmo de agrupamento é o algoritmo K-means.

O algoritmo K-means se inicia com a escolha de k grupos, cada um dos quais consiste em um único ponto aleatório, denominado centroide. Em seguida, cada novo ponto é adicionado ao centroide mais próximo segundo uma distância d (LLOYD, 1982; MACQUEEN, 1967). Uma distância comumente usada para agrupar pontos com características contínuas é a distância Euclidiana quadrada:

$$d(x, y)^2 = \sum_{i=1}^n (x_i - y_i)^2. \quad (2.32)$$

A Equação 2.32 define a distância euclidiana quadrada entre dois pontos, x e y , no espaço n -dimensional, onde o índice i refere-se à i -ésima dimensão.

Com base na métrica de distância Euclidiana, o algoritmo K-means pode ser descrito como um problema de otimização simples, uma abordagem iterativa para minimizar a soma dos erros quadrados dentro do *cluster*. No entanto, uma desvantagem do K-means é a necessidade de especificar o número k de clusters previamente. Outras técnicas de agrupamento, como agrupamento hierárquico e agrupamento baseado em densidade, não exigem essa especificação antecipada do número de clusters e não assumem estruturas esféricas nos dados.

Algoritmos de agrupamento baseados em densidade têm como objetivo identificar regiões de alta concentração de pontos e os conectar em grupos, identificando, dessa

forma, os *clusters*. O representante mais conhecido desse tipo de agrupamento é o *Density-Based Spatial Clustering of Applications with Noise* (DBScan).

O algoritmo DBScan é baseado na densidade dos pontos, permitindo a identificação de clusters com base na densidade em vez da distância (ESTER et al., 1996). Ao contrário do K-means, o DBScan por sua vez não exige que seja inserido, a priori, o número de *clusters*, uma vez que elabora os grupos com base no número de vizinhos a um ponto e no raio da vizinhança. Assim, a noção de densidade é definida como o número de pontos dentro de um raio da vizinhança especificado, ρ .

De acordo com o algoritmo DBScan, um rótulo especial é atribuído a cada ponto de dados usando os seguintes critérios (RASCHKA; MIRJALILI, 2019):

- Um ponto é considerado um ponto central se pelo menos um número especificado de pontos vizinho (MinPt) estiver dentro do raio especificado, ρ .
- Um ponto de fronteira é um ponto que tem menos vizinhos que MinPt dentro de ρ , mas está dentro do raio ρ de um ponto central.
- Todos os outros pontos que não são nem centrais nem fronteirios são considerados pontos de ruído.

O DBScan é capaz de lidar com *clusters* de diferentes formas e tamanhos, além de identificar pontos de dados como *outliers*. No entanto, para funcionar de maneira eficaz dois hiperparâmetros no DBSCAN (MinPt e ρ) precisam ser otimizados. Encontrar uma boa combinação de MinPt e ρ pode ser problemático se as diferenças de densidade no conjunto de dados forem relativamente grandes.

Assim como o DBSCAN, o algoritmo Mean Shift não requer que o número de clusters a serem encontrados seja especificado previamente. Proposto por Fukunaga e Hostetler (1975), o Mean Shift é um procedimento iterativo que desloca cada ponto de dados para a média dos pontos de dados em sua vizinhança (CHENG, 1995; COMANICIU; MEER, 2002; FUKUNAGA; HOSTETLER, 1975).

Seja $A \subset \mathbb{R}$ um conjunto de dados finito, K um kernel e $w : A \rightarrow (0, \infty)$ uma função de peso. A média amostral com kernel K em $x \in \mathbb{R}$ é definida como:

$$m(x) = \frac{\sum_{y \in A} K(y - x)w(y)y}{\sum_{y \in A} K(y - x)w(y)}. \quad (2.33)$$

Seja $T \subset Rd$ um conjunto finito de centros de *cluster*. A evolução de T na forma de iterações $T \leftarrow m(T)$ com $m(T) = \{m(y) : y \in T\}$ é chamado de algoritmo Mean Shift (FUKUNAGA; HOSTETLER, 1975; GAN; MA; WU, 2007).

Em termos gerais, o Mean Shift trata cada ponto de dados como uma distribuição de probabilidade e utiliza um kernel para estimar a densidade local ao redor de cada ponto. Para cada ponto de dados, o algoritmo calcula a média dos pontos dentro de uma janela definida pelo parâmetro largura de banda. O ponto é então deslocado para essa média, movendo-se na direção do gradiente da densidade, em direção às regiões de maior densidade. O processo de deslocamento é repetido iterativamente até que os pontos converjam para as posições onde a densidade seja máxima, identificando assim os modos da densidade. Esses modos representam os centros dos clusters.

Quanto aos algoritmos de agrupamento baseados em distribuições, eles têm a característica de modelar diferentes distribuições a partir dos dados e consideram cada distribuição encontrada como um agrupamento distinto. Em outras palavras, os algoritmos procuram ajustar várias distribuições aos dados, associando cada distribuição a um cluster específico. Com base nesse enfoque, a atribuição de cada ponto aos grupos pode ser realizada de forma probabilística. Isso significa que, com base nas distribuições identificadas em cada grupo, é possível estimar a probabilidade de um ponto pertencer a uma determinada distribuição. Um exemplo ilustrativo desse conceito são os modelos de Mistura Gaussiana (GMM, do inglês: *Gaussian Mixture Model*) que fornecem uma abordagem clássica e poderosa para análise de agrupamento (BANFIELD; RAFTERY, 1993) e também são úteis para compreender e sugerir critérios de agrupamento poderosos (GAN; MA; WU, 2007).

O GMM tenta adaptar diferentes modelos gaussianos aos dados. Nesse contexto, cada modelo gaussiano representa uma distribuição de probabilidade associada a um cluster. Por meio do GMM, é possível calcular a probabilidade de um ponto pertencer a cada distribuição gaussiana, auxiliando na tarefa de atribuição de pontos aos clusters de forma mais flexível e probabilística.

Uma maneira de encontrar o número certo de clusters ao usar um GMM é traçar o critério de informação bayesiano (BIC) ou o critério de informação de Akaike (AIC) como uma função do número de clusters e, em seguida, escolher o número de clusters que minimiza o BIC ou AIC. Outra técnica é usar um modelo de mistura Bayesiana Gaussiana, que seleciona automaticamente o número de clusters (GÉRON, 2022).

Por fim, algoritmos de agrupamento hierárquico têm como objetivo agrupar dados semelhantes entre si com base em métricas de distância. A principal característica que os distingue dos outros tipos de algoritmos de agrupamento é a capacidade de criar vários níveis de *clusters*, resultando em uma estrutura hierárquica de agrupamentos. Essa hierarquia é representada por uma árvore de *clusters* na qual um dado pode pertencer a grupos menores e a grupos maiores, estabelecendo assim uma relação hierárquica entre eles.

A partir da hierarquia de *clusters*, é possível controlar o grau de semelhança desejado entre os dados para que eles pertençam a um mesmo grupo. Isso permite ajustar a granularidade dos agrupamentos, escolhendo clusters mais específicos ou agregados, conforme seja necessário. Dois exemplos de algoritmos de agrupamento hierárquico são o *Agglomerative Clustering* (JOHNSON, 1967) e o *Balanced Iterative Reducing and Clustering using Hierarchies* (BIRCH) (ZHANG; RAMAKRISHNAN; LIVNY, 1996).

Em síntese, os algoritmos de agrupamento desempenham um papel fundamental na análise de dados, fornecendo uma abordagem não supervisionada para identificar padrões e estruturas nos conjuntos de dados. A capacidade desses algoritmos em agrupar instâncias similares de forma automática e identificar relações intrínsecas nos dados é de grande valor em diversas áreas, incluindo ciência de dados, aprendizado de máquina e análise de informações.

Paralelamente, os métodos de classificação desempenham um papel crucial ao categorizar dados e prever resultados com base em padrões previamente identificados, possibilitando a tomada de decisões informadas e a realização de análises preditivas. No contexto desta pesquisa, tanto o agrupamento quanto a classificação emergem como técnicas que permitem a identificação de padrões e características relevantes nos sinais de DP, contribuindo significativamente para o avanço da análise dos fenômenos.

No presente capítulo, foram explorados conceitos fundamentais que servem como alicerce para o desenvolvimento desta tese. Os conceitos abordados abrangem a técnica de detecção de Descargas Parciais (DP) através do método internacional IEC 60270 (2000) e o método radiométrico, bem como a detecção da envoltória de sinais, a extração e seleção de atributos de sinais de DP, além das técnicas de classificação e agrupamento.

No capítulo subsequente, será apresentada a revisão bibliográfica detalhada das principais pesquisas correlatas, fornecendo um contexto para a compreensão das contribuições da pesquisa.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo, apresenta-se a revisão bibliográfica das pesquisas mais relevantes relacionadas aos seguintes temas: monitoramento de DP utilizando o método radiométrico, detecção por envoltória de sinais e extração de atributos para separação de sinais de DP. Para tanto, o capítulo será dividido em quatro seções.

Na primeira seção são discutidos trabalhos que promoveram a evolução do método radiométrico como ferramenta de monitoramento de DP. Na segunda seção são reportados os principais trabalhos que utilizaram técnicas de detecção de envoltória de sinais de DP e suas respectivas contribuições. Na terceira seção são apresentadas as contribuições das principais publicações na qual a temática de extração de atributos de sinais de DP para promover a separação entre defeitos e classificação de fontes se faz tema. Por fim, a última seção compreende um resumo onde as contribuições dos principais trabalhos que aplicaram a técnica de detecção de envoltória de sinais de radiométricos de DP são apresentadas, com destaque para as contribuições que esta pesquisa alcançou.

3.1 MONITORAMENTO DE DESCARGAS PARCIAIS UTILIZANDO O MÉTODO RADIOMÉTRICO

Os primeiros estudos de monitoramento da atividade de DP utilizando o método radiométrico foram implementados em GIS. Com a evolução da técnica de detecção de DP em GIS, pesquisadores expandiram os estudos para a aplicação do método radiométrico para detecção, localização e classificação de DP em outros equipamentos de alta tensão, tais como transformadores de potência. Nesta seção, é apresentada uma revisão bibliográfica que aborda os avanços no monitoramento da atividade de DP, desde a sua utilização em GIS até as aplicações em equipamentos de alta tensão, como transformadores de potência.

As primeiras pesquisas sobre detecção e localização de DP utilizando o método radiométrico são datadas da década de 80, quando em 1988 Hampton e Meats (1988) publicaram o artigo *“Diagnostic measurements at UHF in gas insulated substations”*,

pioneiro sobre medições UHF de DP. No estudo os pesquisadores realizaram diversos testes em laboratório, utilizando fontes de DP pressurizadas com SF_6 instaladas separadamente em uma plataforma de câmaras GIS de 420 kV, e em campo em uma GIS de 420 kV pertencente ao grupo *South of Scotland Electricity Board*. Os resultados de detecção apresentaram maior sensibilidade na faixa de frequência de 600 MHz - 900 MHz. No geral, as técnicas apresentadas por Hampton e Meats, embora tivessem algumas limitações, ofereceram um meio prático de diagnosticar condições de falha em potencial que podem surgir em uma GIS.

A partir dos avanços obtidos por Hampton e Meats (1988), outras pesquisas foram realizadas seguindo a linha de monitoramento de DP em GIS por meio de sensores na faixa UHF (HAMPTON et al., 1990; HAMPTON; IRWIN; LIGHTLE, 1990; LIGHTLE; HAMPTON; T., 1989). Em 1991, Yuen e Chan (1991) realizaram o monitoramento de DP utilizando a técnica de detecção radiométrica em uma GIS de 400 kV na subestação de Castle Peak, empregando o uso de sensores externos acoplados em janelas de inspeção. A pesquisa foi conduzida em dois momentos, com um intervalo de seis meses entre elas, e o resultado de ambas mostrou uma correlação alta e indicou que não houve mudança significativa na atividade de PD no período de seis meses. Apesar dos estudos realizados indicarem que as DP eram de um tipo semelhante, a causa exata de todas as descargas não foi determinada.

Pearson, Hampton e Sellars (1991), por meio do artigo “*A Continuous UHF Monitor for Gas Insulated Substations*”, publicaram os resultados de uma pesquisa inovadora sobre um sistema de monitoramento de DP em uma GIS utilizando a técnica radiométrica. Ao contrário da prática comum, que envolvia medições de DP em GIS com intervalos de várias semanas, esse sistema permitiu o monitoramento contínuo. Os sinais capturados por sensores UHF eram processados por uma unidade de condicionamento de sinal que incluía amplificadores e um detector de envoltória. Os dados coletados eram exibidos para identificar a fonte de descarga e podiam ser armazenados de maneira condensada para análise ao longo do tempo. Além disso, os resultados podiam ser interpretados por um sistema especialista e uma análise da situação era enviada por meio de um link para um computador no escritório do engenheiro, para que ele pudesse supervisionar continuamente uma série de subestações. Portanto, já no início da década de noventa o monitoramento da atividade de DP em GIS utilizando o método radiométrico mostrava-se promissor.

Em 1994, Masaki et al. (1994) realizaram uma série de medições de DP utilizando o método de detecção radiométrica em duas GIS de 300 kV. Nas medições realizadas foram verificadas a distribuição de ruído, a propagação e atenuação do pulso de DP na GIS e a localização de DP utilizando sensores externos. A atenuação dos pulsos de DP foi verificada pelos autores a partir da injeção de pulsos de DP artificiais em locais pré-definidos e a sua respectiva medição em outras localizações. A partir dos resultados obtidos os autores constataram que em frequências acima de 100 MHz o nível de ruído era geralmente mais baixo. Contudo, em frequências mais baixas era possível detectar ruídos mais expressivos em algumas localidades. Em relação ao estudo de atenuação dos pulsos, foi diagnosticado que os sinais eram rapidamente atenuados durante a propagação do pulso, e a distância de atenuação era em torno de 5 m para componentes de frequências acima de 500 MHz. Assim, a partir dos resultados dos estudos de detecção de ruído e da propagação de pulsos de DP os autores concluíram que a faixa de frequência de 200 a 400 MHz era mais adequada para detecção de sinais de DP.

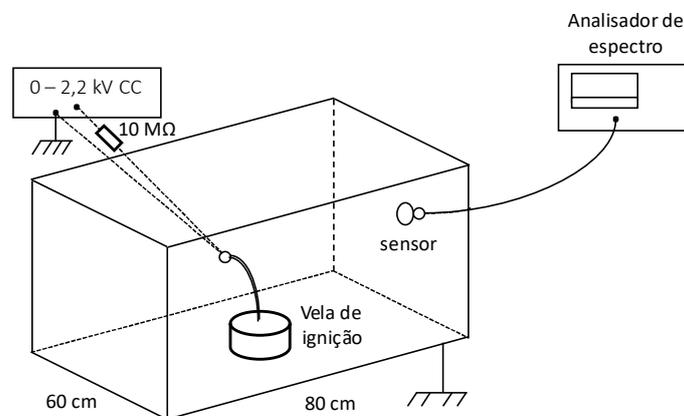
No ano seguinte, em 1995, em um estudo realizado por Pearson et al. (1995), foi documentado o avanço da utilização do método radiométrico na detecção de DP em GIS no Reino Unido. No estudo foi destacado que todas as novas GIS estavam sendo equipadas com sensores UHF e, em alguns casos, a instalação de sensores estava sendo realizada retroativamente às subestações existentes.

Em um estudo desenvolvido por Kurrer et al. (1996), a sensibilidade do método radiométrico de banda estreita na detecção de DP em GIS foi avaliada por meio de uma comparação com o método elétrico que utiliza um capacitor de acoplamento. As amplitudes dos sinais no domínio do tempo em várias frequências centrais na faixa UHF foram comparadas com os níveis de DP medidos com o método elétrico. Por fim, foi demonstrado pelos autores uma sensibilidade semelhante de detecção entre os métodos para a pequena configuração experimental avaliada nos ensaios. No entanto, os autores destacaram que em instalações maiores, graus mais altos de atenuação de sinal são possíveis, o que poderia resultar em uma redução de sensibilidade de detecção. Dessa forma, os autores relataram a necessidade de mais investigações para determinar a diminuição da sensibilidade devido à atenuação em uma GIS de grande porte. Apesar da necessidade de maiores investigações, os autores ressaltaram que a diminuição de sensibilidade não é apenas um reflexo do método radiométrico de banda estreita, mas da física da descarga parcial e se aplica igualmente a outros métodos de detecção.

Com os avanços e a consolidação do método radiométrico para a detecção, classificação e localização de DP em GIS, pesquisadores expandiram os estudos para a aplicação do método radiométrico em outros equipamentos de alta tensão, como transformadores de potência. Os primeiros testes de medições radiométricas de DP para transformadores de potência foram realizados em 1997 por Rutgers e Fu (1997). Os autores realizaram medições UHF e acústicas de DP em um tanque de transformador de 110 kV preenchido com óleo. Os resultados dos testes realizados em laboratório demonstraram que tanto sensores UHF quanto sensores acústicos são sensíveis à detecção de DP em óleo. Por fim, os resultados das medições indicaram que os sinais obtidos pelo método radiométrico apresentaram uma menor atenuação que aqueles obtidos pelo método acústico.

Dois anos depois, em 1999, Judd et al. (1999) avaliaram a viabilidade da aplicação do método radiométrico de detecção de DP em um transformador de potência. Inicialmente foi utilizado um arranjo experimental formado por uma câmara de alumínio blindada contendo uma fonte de DP e um sensor UHF cônico conectado a um analisador de espectro para avaliar DP no ar e no óleo, conforme pode ser observado na Figura 3.1.

Figura 3.1 - Arranjo usado para comparar os sinais irradiados por descargas no ar e óleo.

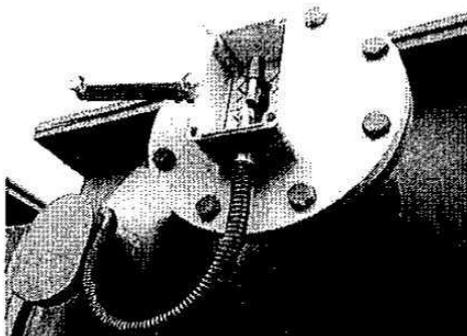


Fonte: Adaptado de Judd et al. (1999).

Após as análises realizadas, observou-se que as descargas no óleo geraram sinais em frequências de até 1,5 GHz. Com esses resultados, os autores projetaram um sensor UHF adaptado para ser instalado na parte interna do tanque do equipamento, conforme pode ser verificado na Figura 3.2. Nos testes realizados com o sensor imerso no óleo, verificou-se um aumento na amplitude do sinal radiométrico. No mesmo estudo, foram realizados testes em GIS para efeito comparativo com os realizados no transformador. Os

testes comparativos demonstraram que os pulsos injetados no transformador apresentavam uma menor energia do que as DP em SF₆, mas ainda assim eram detectáveis, indicando a eficácia do monitoramento UHF em transformadores de potência.

Figura 3.2 - Sensor UHF no tanque do transformador.

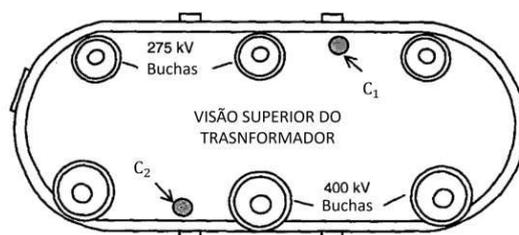


Fonte: Judd et al. (1999c).

Em 2000, Judd et al. (2000) utilizaram do conhecimento adquirido no desenvolvimento de tecnologias de monitoramento de DP utilizando o método radiométrico em GIS para realizar testes de monitoramento de DP em transformadores de potência. Os autores utilizaram dois sensores UHF acoplados ao transformador por meio de janelas dielétricas, conforme apresentado na Figura 3.3. A medição de DP foi realizada em três tempos: com o transformador antes de ser energizado; com o transformador durante a energização e com o transformador em carga. A etapa inicial, antes da energização, foi realizada com o objetivo de identificar o nível de ruído de fundo, visto que existia uma torre de comunicação nas imediações. Nessa fase, as medições foram feitas com e sem um pré-amplificador. Os autores constataram que ao utilizar o pré-amplificador os sinais de comunicação se tornaram mais aparentes. Durante a energização, um monitor portátil de descargas parciais foi utilizado, de modo que o monitor portátil ficou gravando dados continuamente. No primeiro minuto após o transformador ser energizado, ambos os canais registraram seis eventos e os autores observaram que os padrões de descarga em ambos os sensores eram bastante semelhantes. O transformador foi colocado em carga 22 minutos após a energização, nesse momento não foi observada nenhuma mudança significativa no espectro UHF. Os espectros UHF sob carga registrados com o pré-amplificador são exibidos na Figura 3.4. Os autores concluíram que não houve uma mudança nos níveis de ruído de fundo quando comparados os resultados obtidos com o transformador em carga e antes de ser

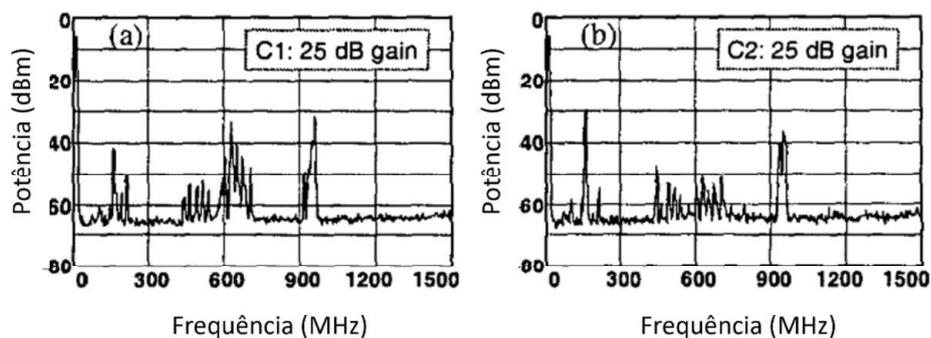
energizado. A principal contribuição dos autores foi a demonstração, por meio dos testes realizados, do potencial da técnica UHF para uso em aplicações de monitoramento de transformadores.

Figura 3.3 - Posição dos sensores UHF C1 e C2 no tanque do transformador.



Fonte: Adaptado de Judd et al. (2000).

Figura 3.4 - Sinais de fundo com o transformador em carga, usando o pré-amplificador.



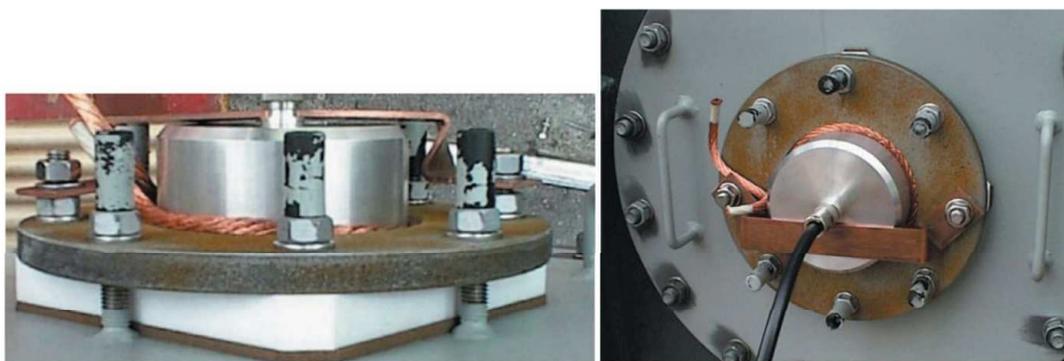
Fonte: Adaptado de Judd et al. (2000).

Diversas outras pesquisas foram promovidas para desenvolver e comprovar a aplicabilidade da técnica radiométrica no monitoramento da atividade de DP em transformadores. Em 2004, Wang et al. (2004) projetaram um sistema de monitoramento *on-line* de DP utilizando o método radiométrico e instalaram em um transformador de potência de 120 MVA/220 kV em serviço na província de Henan na China. O sistema de monitoramento era composto por sensor UHF, amplificador, osciloscópio digital, placa de aquisição de dados (DAQ) com taxa de amostragem de 20 MHz e computador industrial. Os sensores utilizados foram do tipo espirais de Arquimedes com largura de banda de 500 MHz - 1500 MHz e ganho de 40 dB. Como o transformador estava em serviço, a antena foi projetada em uma válvula de óleo, semelhante ao trabalho realizado por Pemen et al. (1999). O amplificador apresentava dois canais de saída: um para a saída dos sinais transitórios UHF e outro para a demodulação dos sinais transitórios UHF. O canal UHF é utilizado para fazer um monitoramento portátil ou localizar a DP no

transformador no auxílio do osciloscópio digital. O canal de demodulação UHF foi usado para obter a distribuição estatística dos sinais de DP na dependência do ângulo de fase da tensão de teste aplicada. Como os sinais de demodulação UHF têm um tempo de subida muito mais lento em comparação com os sinais UHF, os sinais demodulados eram digitalizados usando uma taxa de amostragem mais baixa. O sistema desenvolvido tinha a capacidade de filtrar interferências, como sinais de telefone celular, sendo essa uma das principais contribuições do trabalho realizado.

Em 2005, dois artigos foram publicados por Judd, Yang e Hunter (JUDD; YANG; HUNTER, 2005a, 2005b) sobre monitoramento de DP em transformadores utilizando sensores UHF. No primeiro artigo (JUDD; YANG; HUNTER, 2005a), os autores descreveram uma visão geral sobre a técnica que permitia a detecção, localização e monitoramento de DP em transformadores. O ponto chave da abordagem seguida pelos autores é a utilização de janelas dielétricas para formar uma abertura elétrica robusta por meio da qual os campos eletromagnéticos de alta frequência, no tanque, poderiam ser identificados. Na Figura 3.5 são ilustradas duas vistas de um dos sensores utilizados (JUDD; YANG; HUNTER, 2005b). Essa abordagem se origina das aplicações em GIS e uma das vantagens é que os sensores externos podem ser instalados ou removidos com a planta está em serviço ou com uma breve interrupção.

Figura 3.5 - Fotografia das vistas lateral e superior do sensor montado na janela dielétrica.



Fonte: Judd, Yang, e Hunter(2005b).

No segundo artigo (JUDD; YANG; HUNTER, 2005b), os resultados dos testes realizados em transformadores de potência foram divulgados. A partir dos resultados obtidos os autores listaram diversas vantagens da utilização da técnica radiométrica no monitoramento de DP em transformadores, tais como: boa imunidade à interferência de descargas corona, a localização de fontes pode ser automatizada, múltiplas fontes de DP podem ser tratadas simultaneamente, dentre outras.

Denissoff et al. (2008) apresentaram os resultados de medições banda estreita versus banda larga, realizadas utilizando um analisador de espectro em uma instalação de laboratório com um defeito de DP artificial incorporado de intensidade variável. Uma sensibilidade abaixo de 5 pC revelou-se detectável pelo método radiométrico apresentado. Os resultados das experiências de laboratório demonstraram alta eficácia da detecção da atividade de DP pelo método *on-line* UHF em terminações de cabos plugáveis. Um estudo comparativo entre sensores capacitivos e indutivos foi conduzido. O sensor capacitivo representa um disco de cobre com diâmetro de 2,5 cm, colocado cerca de 2 cm acima da superfície do cabo e o sensor indutivo é uma bobina de duas voltas feita de um fio de cobre isolado e enrolada ao redor do cabo. Como resultado, os sensores usados foram eficazes na faixa de frequência de 650 MHz - 950 MHz para os capacitivos e 200 MHz - 350 MHz para os indutivos, respectivamente. A sensibilidade máxima do método radiométrico de DP de banda estreita compreendia 5 pC para o sensor indutivo e 10 pC o para sensor capacitivo.

Pesquisas continuaram sendo desenvolvidas com o objetivo de aprimorar a aplicação do método radiométrico no monitoramento de DP, e muitas técnicas foram desenvolvidas utilizando tecnologias de contato e sem fio. Em 2017, Upton et al. (2017) projetaram um sistema WSN radiométrico em tempo real para monitorar e localizar fontes de DP. Usando um algoritmo baseado na intensidade do sinal recebido (RSS, do inglês: *Received Signal Strength*), conseguiram localizar fontes emuladas de DP com precisão de até 2 metros. No ano seguinte, Khan et al. (2018) propuseram um algoritmo de localização de DP baseado em RSS e utilizaram uma antena receptora dipolo para receber os sinais de DP. O estudo experimental mostrou que esse método ofereceu a menor margem de erro em comparação com outros algoritmos (mínimos quadrados e *ratio and search*), especialmente quando o número de nós receptores aumentou. A localização baseada em RSS mostrou-se uma técnica viável para o monitoramento de DP.

Pesquisas recentes têm evidenciado a evolução do método radiométrico no monitoramento de DP (CHAI; PHUNG; MITCHELL, 2019; KAZIZ et al., 2023; NOBREGA et al., 2019a; NOBREGA et al., 2019b; XAVIER et al., 2021). Em 2019, Chai, Phung, Mitchell (2019) elaboraram uma revisão detalhada dos sensores UHF utilizados para detecção de DP em equipamentos de alta tensão. As principais vantagens do método radiométrico na detecção de DP, tais como eliminação de ruído com frequência inferior a 200 MHz e alta sensibilidade de detecção, são mostradas em comparação com as abordagens de detecção existentes em termos de sua aplicação.

Em 2019, Nobrega et al. (2019b) apresentaram um algoritmo de localização de DP em transformadores de potência, utilizando ondas eletromagnéticas geradas por pulsos de DP. O método proposto considerava os efeitos de reflexão, refração e difração das ondas UHF dentro do tanque do equipamento, com uma melhor identificação da localização das DP. O método foi validado em seis simulações diferentes, demonstrando um alto nível de precisão e eficácia na localização de defeitos em várias posições dentro do transformador.

Em 2021, Xavier et al. (2021) forneceram um levantamento abrangente sobre as pesquisas mais relevantes na área de detecção, classificação e localização de fontes de descarga parcial (DP) usando o método radiométrico. Os autores forneceram análises, comparações e destacaram as principais contribuições sobre o desenvolvimento e otimização de sensores UHF para aplicações na detecção, classificação e localização de fontes de DP. A partir dos trabalhos avaliados, os autores destacaram que o uso de classificadores é aplicado não apenas para a identificação de defeitos, mas também para sua separação no caso de fontes múltiplas. Visto que a existência de múltiplos defeitos em um equipamento pode dificultar a aplicação de algoritmos de localização, pois há uma grande probabilidade de superposição de sinais. Por fim, os autores apontaram tendências e desafios relacionados aos estudos na área de pesquisa de monitoramento de DP com sensores UHF tais como miniaturização de sensores, aplicação de técnicas de ganho (para melhoria de sensibilidade) e calibração do sensor.

As interferências de telecomunicações podem ser fontes de ruído para um sensor UHF externo ao equipamento de alta tensão, especialmente em subestações abertas. Recentemente, Kayzer Azam et al. (2023) desenvolveram um sensor planar que elimina as interferências de telecomunicações, especificamente a banda GSM-900, durante a detecção de DP, sem a necessidade de filtros de pós-processamento. Esse novo sensor incorpora um ressonador de acoplamento projetado para eliminar a interferência da banda GSM-900 dentro da largura de banda do sensor. Sendo um sensor para atenuar esses ruídos a nível físico, a expectativa é que sua integração com técnicas convencionais de pós-processamento contribua significativamente para a melhoria da precisão no diagnóstico completo de DP, abrangendo detecção, classificação e localização, mesmo em ambientes ruidosos.

Um estudo conduzido por Tenbohlen et al. (2023) investigou as faixas de frequências eficazes para medições radiométricas de DP em transformadores em aplicações práticas. Nesse artigo, uma revisão da literatura sobre várias medições

laboratoriais e os fatores que influenciam no espectro de frequência dos pulsos de DP foi apresentada. A partir dessas observações práticas, algumas conclusões puderam ser tiradas para dispositivos e configurações de medição de DP no espectro UHF. Segundo os autores, um sistema de medição radiométrica de DP deve cobrir a faixa de frequência de aproximadamente 400 MHz a 900 MHz para fornecer sensibilidade básica. Além disso, os autores apontaram que é preferível uma faixa mais ampla, pois o pico do sinal de DP real de um caso individual pode estar fora dessa faixa.

As pesquisas apresentadas nesta seção destacaram a evolução do método radiométrico, desde suas aplicações iniciais em GIS até sua implementação no monitoramento de DP em transformadores de potência. Ao longo dos anos, esforços significativos em pesquisa têm sido dedicados ao aprimoramento de sensores e à busca pela faixa de frequência mais adequada para a detecção de DP. Além disso, foram realizados avanços significativos no desenvolvimento de técnicas para localizar e classificar os sinais de DP, o que ampliou consideravelmente o potencial do método radiométrico no monitoramento de DP.

Nas próximas seções as principais pesquisas relacionadas a circuitos detectores de envoltória aplicados em sistemas para detecção de DP e a extração de atributos dos sinais de DP para promover a separação e/ou classificação de sinais serão apresentadas e discutidas.

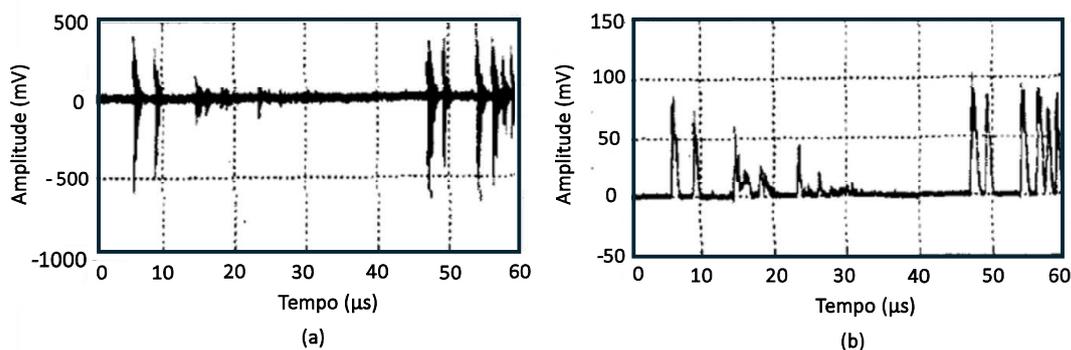
3.2 DETECTOR DE ENVOLTÓRIA

O detector de envoltória é um tipo de circuito de modulador AM largamente utilizado devido ao seu baixo custo, simples implementação e eficácia comprovada. Abordagens baseadas no processo de detecção de envoltória foram testadas por pesquisadores no monitoramento e análise da atividade de DP, porém, ainda carecem de análises mais aprofundadas, conforme demonstrado a seguir.

Em 2003, Chen et al. (2003) utilizaram a técnica de detecção de envoltória com o objetivo de suprimir interferências na detecção *on-line* de DP em um transformador. Para as medições os autores projetaram antenas com largura de banda de 100 MHz a 3 GHz e frequência central de 800 MHz e realizaram testes em uma célula de óleo. Os sinais UHF captados eram enviados a um amplificador UHF com largura de banda de 300 MHz a 3 GHz por meio de cabo coaxial. A constante de tempo utilizada no detector de envoltória

foi de 1 μ s. Os resultados dos sinais radiométricos originais e dos sinais após a detecção da envoltória podem ser visualizados na Figura 3.6. A partir dos resultados alcançados, destaca-se como principais contribuições do artigo a capacidade do detector de envoltória de ser utilizado para minimizar interferências e reduzir a taxa de amostragem do sistema de medição de DP.

Figura 3.6 - (a) Sinal UHF original de DP. (b) Sinal após a detecção de envoltória.

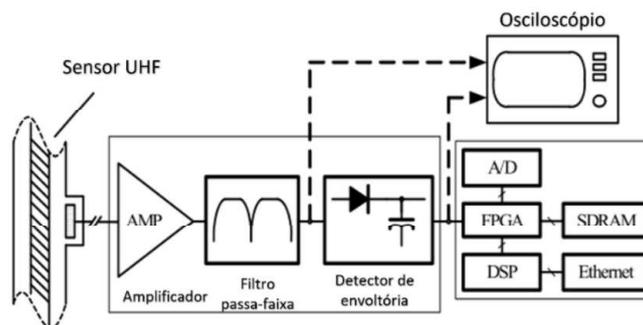


Fonte: Adaptado de Chen et al. (2003).A qual

Yunpeng et al. (2007) investigaram um sistema radiométrico de monitoramento *on-line* de DP para transformadores. O sistema de detecção de DP aplicado era composto por um sensor na faixa UHF, uma unidade de condicionamento de sinal, composta por um amplificador e por um circuito detector de envoltória, cabo coaxial de alta frequência, placa de aquisição de dados e um computador com *software* de instrumentação virtual. Os testes experimentais foram realizados utilizando arranjos projetados para simular modelos típicos de DP, tais como descarga ponta-plano, descarga superficial, descarga interna, descarga em cuba de óleo e descarga flutuante. Os resultados da pesquisa demonstraram que assim como em Chen et al. (2003) o sistema projetado por Yunpeng et al. (2007) conseguiu realizar a diminuição dos níveis de ruído e apresentou estabilidade esperada.

Em 2008, um circuito de detecção de envoltória de sinais radiométricos e um sistema de aquisição de dados foram projetados por Li-Xue et al. (2008) com o objetivo de detectar e identificar defeitos em uma GIS. O *hardware* do sistema de detecção de DP consistia nos seguintes componentes: sensor UHF, amplificador de banda larga, filtro passa-banda, circuito de captura de onda GSM, circuito de extração de envoltória e circuito de coleta de dados de alta velocidade, conforme pode ser visualizado na Figura 3.7.

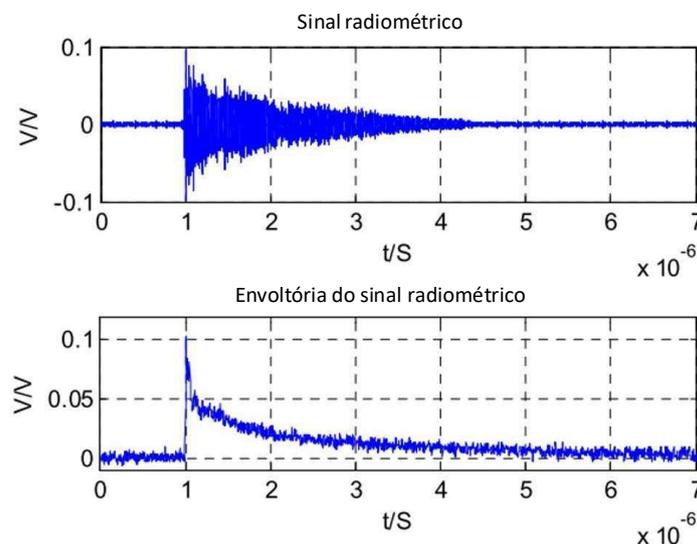
Figura 3.7 - Sistema de diagnóstico de descarga parcial para GIS utilizando o método radiométrico com base no circuito de detecção de envoltória.



Fonte: Adaptado de Li-Xue et al. (2008).

A taxa de amostragem adotada no estudo de Li-Xue et al. (2008) foi de 250 MS/s. As características no domínio do tempo dos sinais de DP gerados pelo mesmo modelo de defeito apresentavam características semelhantes, assim como suas envoltórias. Na Figura 3.8 são exibidos um sinal radiométrico e sua respectiva envoltória. Para aumentar a sensibilidade e a confiabilidade da detecção de DP os autores aplicaram a técnica de *Wavelet* nas envoltórias dos sinais com o objetivo de reduzir o ruído branco e aumentar a relação Sinal Ruído (SNR, do inglês: *Signal to Noise Ratio*).

Figura 3.8 - Sistema de diagnóstico de descarga parcial para GIS utilizando o método radiométrico com base no circuito de detecção de envoltória.



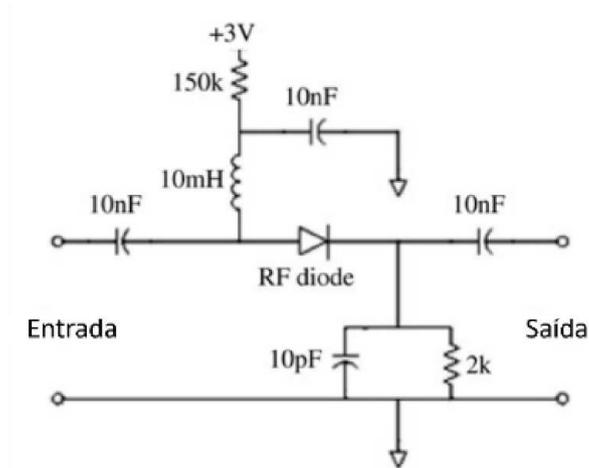
Fonte: Li-Xue et al. (2008).

Em 2008, Pinpart, Fletcher e Judd (2008) divulgaram uma pesquisa cujo objetivo era a investigação de um novo método para promover a separação de sinais de DP detectados por sensores UHF. Uma das abordagens utilizadas pelos autores se baseava na

análise das envoltórias dos sinais de DP por meio de um cálculo de similaridade. As envoltórias foram geradas por meio do método de suavização de densidade por Kernel (KDE, do inglês: *Kernel Density Estimation*) e o algoritmo de geração de envoltória implementado consistia nas seguintes etapas: remoção do nível CC do sinal; elevação ao quadrado os pontos de dados de tensão amostrados e utilização do KDE para criação de envoltórias de sinais UHF de DP. Por fim, as envoltórias eram normalizadas e comparadas a partir do cálculo de similaridade, realizado a partir da diferença ponto a ponto entre duas envoltórias. Apesar do trabalho ter se mostrado uma boa alternativa de distinção entre fontes de DP, visto que uma vantagem da comparação baseada em envoltória é que tanto a taxa de amostragem de dados quanto a carga computacional são reduzidas quando comparadas com métodos que usam o sinal UHF amostrado original, os autores destacaram a necessidade de mais estudos para a confirmação do desempenho do método. Assim, Pinpart e Judd deram continuidade a pesquisa e, em 2010, publicaram o artigo “*Differentiating between partial discharge sources using envelope comparison of ultra-high-frequency signals*” (PINPART; JUDD, 2010), no qual o método de separação de DP a partir da avaliação de similaridade entre envoltórias apresentado em (PINPART; FLETCHER; JUDD, 2008a) foi avaliado por meio de modelagens e testes experimentais.

Em Pinpart e Judd (2010), para avaliar o método de comparação de envoltórias em uma implementação prática, dois detectores de envoltória na faixa UHF idênticos foram construídos, cujo diagrama de circuito pode ser verificado na Figura 3.9. As entradas do circuito são sinais radiométricos detectados pelos sensores, enquanto as saídas são as envoltórias dos sinais a serem capturadas usando um osciloscópio. Os ensaios em laboratório utilizaram um transformador com dois sensores instalados. Os pulsos de DP foram gerados no tanque usando uma fonte de centelhamento alimentada por bateria. A partir dos resultados das pesquisas, os autores concluíram que a técnica de comparação de envoltórias ofereceu um potencial significativo para redução da taxa de amostragem. A largura de banda da envoltória do sinal (em torno de 10 MHz) foi muito menor que a largura de banda do sinal radiométrico original (cerca de 1000 MHz), permitindo que o sinal seja amostrado, digitalizado e armazenado usando *hardware* mais econômico e uma menor quantidade de memória.

Figura 3.9 - Diagrama de circuito do detector de envoltória UHF.



Fonte: Pinpart e Judd (2010).

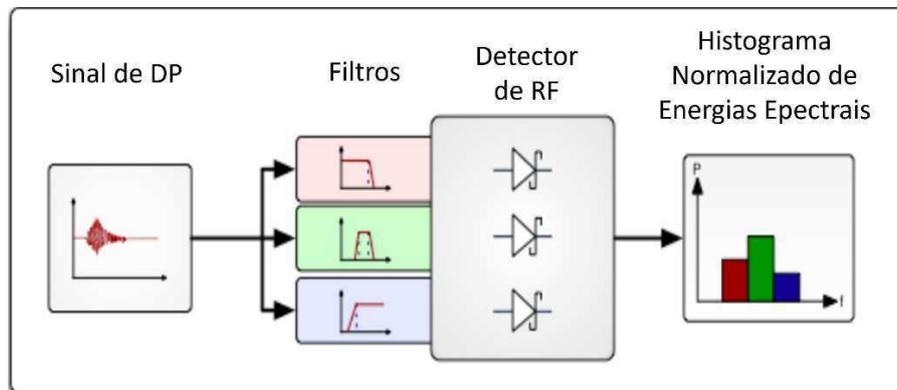
O estudo de Baker, Judd e McArthur (BAKER; JUDD; MCARTHUR, 2010) descreve o uso de um detector de envoltória de RF para reduzir a taxa de amostragem necessária em um sistema de medição de DP em uma rede sem fio. O detector utiliza uma técnica baseada em frequência para distinguir entre eventos de DP e ruídos impulsivos em uma subestação, monitorando a gravidade dos defeitos ao longo do tempo e fornecendo informações sobre a saúde da planta. O protótipo do detector utilizado foi colocado em uma caixa de metal com conectores externos que permitiam a conexão de filtros, que poderiam ser reconfigurados, se necessário, conforme pode ser verificado na Figura 3.10. Uma visão geral do sistema projetado pode ser vista na Figura 3.11.

Figura 3.10 - Fotografia de um detector de 3 canais de baixa potência com filtros de banda montados externamente.



Fonte: Baker, Judd e McArthur (2010).

Figura 3.11 - Diagrama de blocos simplificado do detector de descarga parcial. O detector de três canais converte sinais de RF brutos em magnitudes espectrais proporcionais.



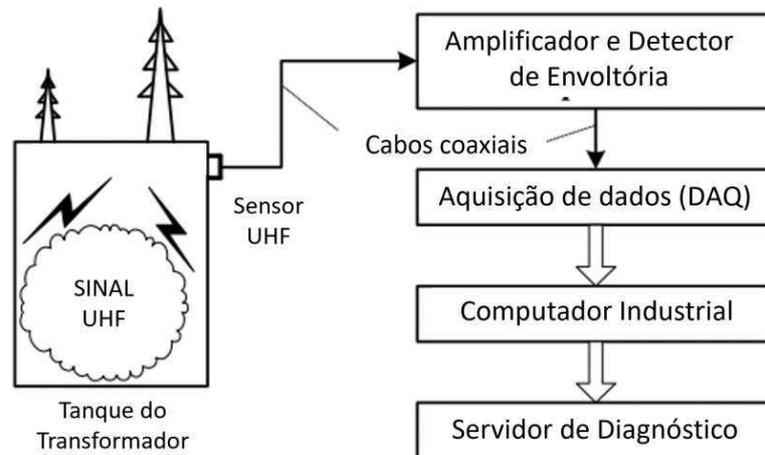
Fonte: Adaptado de Baker, Judd e McArthur (2010).

As bandas de frequência do detector, selecionadas de acordo com estudos anteriores, foram de 0 MHz a 450 MHz, 400 MHz a 750 MHz e 700 MHz a 3200 MHz. O detector consistia em três canais idênticos, cada um capaz de converter sinais de RF de banda larga em um pulso de saída que se aproxima do sinal de RF conectado para restringir a faixa de frequência de entrada. No centro do circuito está um circuito detector com diodo Schottky, seguido por um filtro passa-baixa de 5 MHz usado para condicionar o pulso de saída removendo qualquer traço de componentes de frequência UHF. Este sinal é então amplificado da faixa de milivolts até a faixa de Volt, permitindo que ele seja amostrado por um conversor analógico para digital. A saída resultante são três envoltórias de pulsos que representam a energia relativa dentro das três bandas de frequência, que são então amostrados e armazenados para análise. O teste do dispositivo foi realizado em laboratório usando um tanque com células de teste simulando diferentes defeitos de DP. Os resultados mostraram que o detector pode detectar múltiplos defeitos, mas sugeriram a necessidade de mais testes em plantas reais para melhorar o desempenho e expandir o conhecimento sobre os espectros de frequência de emissão de DP.

Em 2010, Liu e Li (2010) empregaram a técnica de detecção de envoltória para extrair envoltórias dos sinais radiométricos de DP em transformadores de potência. Para isso, um sensor UHF interno foi projetado e montado no tanque do transformador, estabelecendo um sistema de monitoramento radiométrico de DP online, conforme mostrado na Figura 3.12. Os sinais radiométricos originais foram pré-amplificados, transmitidos por cabos coaxiais para o detector de envoltória para redução de frequência e, em seguida, amostrados por placa de aquisição de dados (DAQ) em um computador

industrial para extração e identificação de pulso. Por fim, os resultados foram enviados ao servidor de diagnóstico por barramento CAN.

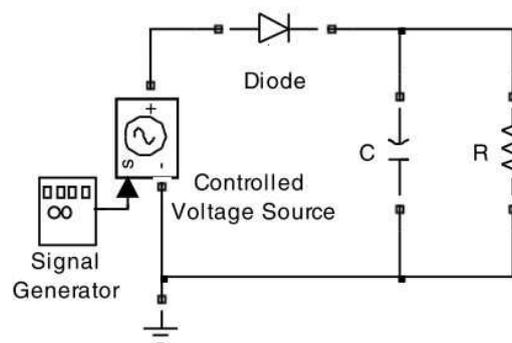
Figura 3.12 - Diagrama de Detecção radiométrica de sinal de DP em transformador.



Fonte: Adaptado de Liu e Li (2010).

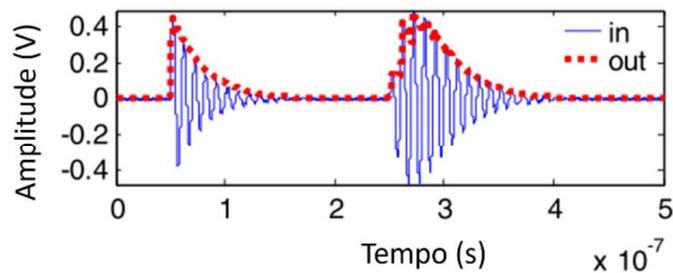
O circuito projetado pode ser observado na Figura 3.13, enquanto na Figura 3.14 um sinal UHF de DP simulado e sua respectiva envoltória pode ser verificada. Após o êxito nos testes computacionais, foram realizados testes em um transformador de 35/220/500 kV e 360 MV com níveis baixos de DP. Os resultados indicaram que a amplitude máxima registrada dos sinais de DP foi de aproximadamente 100 mV e que até atividades de DP de baixos níveis podiam ser detectadas no transformador. De acordo com os resultados dos testes laboratoriais, foi desenvolvido um sistema de monitoramento *online* distribuído baseado na detecção de sinais radiométricos de DP. O sistema foi aplicado a quatro transformadores de potência em uma usina hidrelétrica. Os resultados experimentais demonstraram que o sensor interno UHF e o detector de envoltória podiam efetivamente extrair sinais radiométricos de DP emitidos de fontes de descarga.

Figura 3.13 - Circuito detector de envoltória simulado no Matlab.



Fonte: Liu e Li (2010).

Figura 3.14 - Sinal resultante da simulação do circuito detector de envoltória.

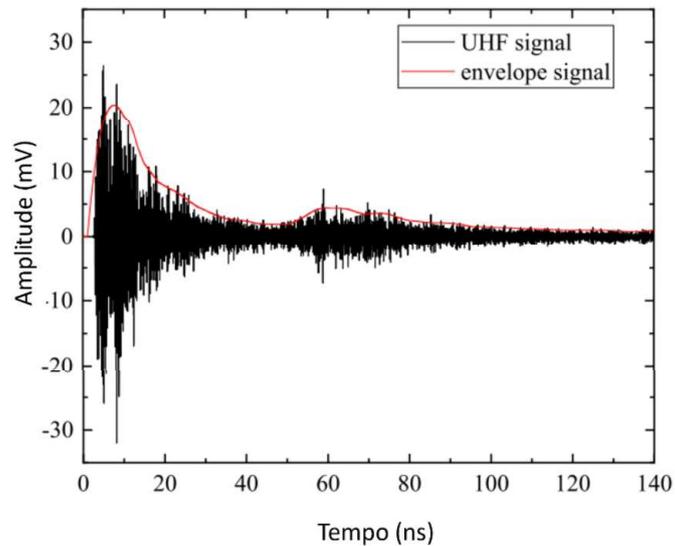


Fonte: Liu e Li (2010).

No trabalho de Souza Neto et al. (2014), foi desenvolvida uma WSN com o propósito de realizar monitoramento em tempo real de DP. No sistema de monitoramento, foi implementado um circuito detector de envoltória com o objetivo de reduzir os requisitos de frequência de amostragem. O sistema proposto foi testado utilizando células geradoras de DP, e os resultados obtidos demonstravam a viabilidade do sistema de detecção de DP. Essa viabilidade estava estreitamente ligada ao uso do detector de envoltória, uma vez que sua utilização permitiu a amostragem do pulso de descarga parcial a uma taxa de amostragem significativamente mais baixa, na faixa de dezenas de MHz, enquanto preservava a energia do sinal.

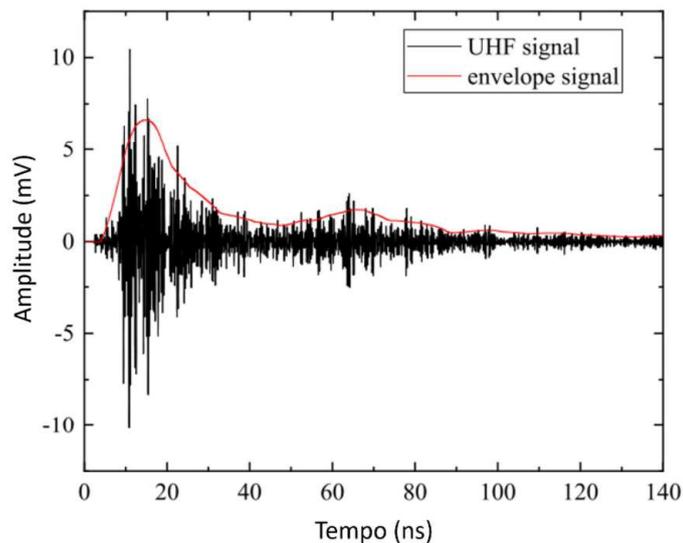
No trabalho de Han et al. (2019) um detector de envoltória foi utilizado como base para um método de extração de características no domínio do tempo de sinais UHF de DP. O detector de envoltória foi utilizado pelos autores devido a sua vantagem na redução no volume de dados o que pode propiciar uma melhoria na velocidade de processamento. No artigo, a filtragem Savitzky-Golay foi usada para obter uma envoltória suave. Os sinais de DP produzidos em partículas metálicas livres e no eletrodo, assim como suas respectivas envoltórias, podem ser visualizados nas Figura 3.15 e Figura 3.16. A partir das envoltórias capturadas de diferentes defeitos, os parâmetros estatísticos foram extraídos para análise. Foi possível constatar que utilizando as formas de onda suavizadas o objetivo de reduzir a dimensão dos dados foi obtido.

Figura 3.15 - Sinal radiométrico de DP de defeito produzido por partículas metálicas livre.



Fonte: Han et al. (2019).

Figura 3.16 - Sinal radiométrico de DP de defeito em eletrodos.

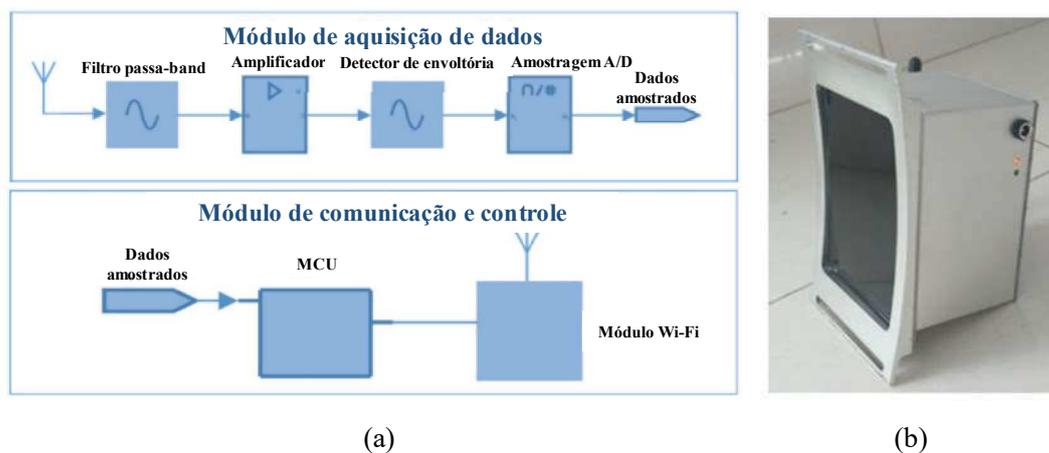


Fonte: Han et al. (2019).

Nas pesquisas (KHAN et al., 2020; MOHAMED et al., 2021; WU et al., 2019), o circuito de detecção de envoltória foi aplicado como parte integrante do sistema de detecção e localização do sinal radiométrico de DP, com base na intensidade do sinal recebido (RSS, do inglês: *Received signal strength*). Em (WU et al., 2019), é proposto um método de direção de chegada de DP baseado em energia usando um indicador de intensidade de sinal recebido de um conjunto de sensores sem fio UHF. Para os sensores UHF sem fio projetados, a largura de banda do sinal é de 300 MHz a 1500 MHz e a taxa de amostragem de conversão A/D (Analogico-Digital) é de 2,7 MHz. Em primeiro lugar,

a onda eletromagnética UHF era recebida pela antena UHF. Em seguida, a forma de onda de detecção de envelope é obtida após o condicionamento do sinal por um filtro passa-faixa, amplificador e detector. Por fim, os dados digitais foram gerados após a amostragem A/D e transmitidos ao computador por meio de um módulo Wi-Fi controlado por uma Unidade de Microcontrolador (MCU, do inglês: *Microcontroller Unit*). O valor de pico da forma de onda de detecção de envelope foi utilizado no algoritmo de localização. O diagrama e a imagem do sensor UHF sem fio são mostrados na Figura 3.17, respectivamente. Os resultados obtidos evidenciaram que o erro médio é menor que 5° usando um algoritmo de interpolação de spline cúbico. Em relação à precisão, observou-se que foi aproximadamente a mesma de métodos de estimativa de atraso de tempo. Dessa forma, a principal contribuição dos autores foi a aplicação de um sistema de baixo custo na localização de sinais de DP.

Figura 3.17 - Sensor UHF sem fio projetado: (a) diagrama do sensor UHF sem fio; (b) imagem do sensor UHF sem fio.



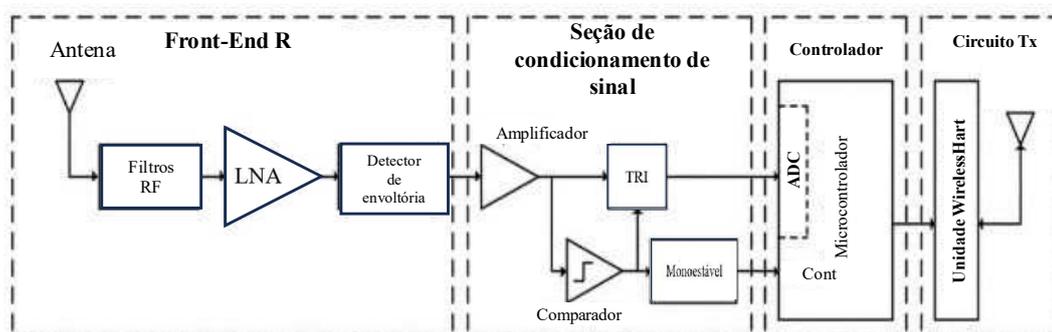
Fonte: Adaptado de Wu et al. (2019).

Em um estudo publicado por Khan et al. (2020) algoritmos de centroide e centroide ponderado foram utilizados para localizar uma fonte de DP. Um sinal de DP artificial foi gerado utilizando um calibrador conectado a uma antena bicônica com faixa de frequência de 10 MHz a 1 GHz e 8 sensores RF foram utilizados para a estimação de localização da fonte. O sistema de detecção era composto por *front-end* de RF, microcontrolador e condicionamento de sinal e unidade de comunicação. O *front-end* de RF incluía os filtros de RF, o amplificador de baixo ruído e o detector de envelope. A unidade de condicionamento de sinal consistia no amplificador, comparador e nos circuitos monoestáveis. A saída da unidade de condição de sinal foi alimentada na

unidade de microcontrolador onde a conversão analógica para digital do sinal também é realizada. O HART (do inglês: *Highway Addressable Remote Transducer*) sem fio foi utilizado para enviar e receber dados de um nó para outro devido à sua adequação na implantação sob condições industriais adversas. Os resultados mostraram que a estimativa da fonte foi possível. Para todas as quatro posições, a estimativa de localização da fonte mostrou um erro de cerca de 1 metro ou menos. Considerando a simplicidade dos algoritmos, os resultados obtidos foram satisfatórios.

Mohamed et al. (2021) apresentaram um estudo com um sistema de detecção de DP baseado em sensores radiométricos que pode funcionar como uma rede de sensores sem fio escalável. O sistema compreende quatro subsistemas que vão desde os sensores de detecção até a unidade de processamento de sinal, microcontrolador e circuitos de transmissão (Circuitos Tx). São usados transceptores HART sem fio que continuamente recebem e registram os dados que são processados. O sistema supervisor implantado é, então, utilizado para processar os dados recebidos pelos sensores. O diagrama de blocos do sistema de detecção radiométrica é ilustrado na Figura 3.18. O *front-end* RF consiste em componentes-chave de RF, incluindo antena, filtros, um amplificador de baixo ruído e um detector de envoltória. A unidade de condicionamento de sinal consiste em um amplificador, comparador e monoestável. A próxima parte é a unidade do microcontrolador que consiste em uma unidade interna de conversão analógica para digital (ADC). A parte final é a unidade de comunicação que consiste em nós HART sem fio.

Figura 3.18 - Diagrama de blocos do sistema de detecção radiométrica.



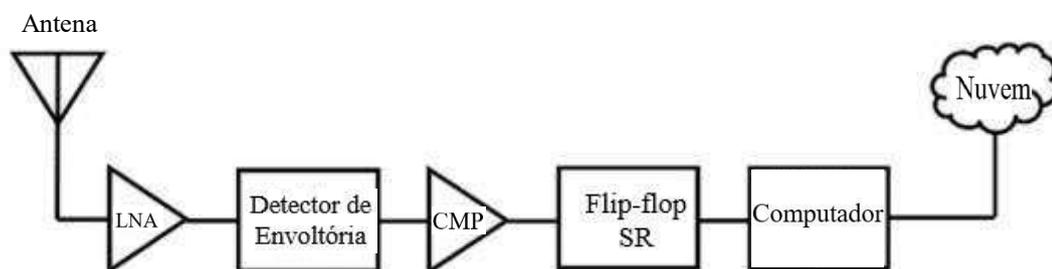
Fonte: Adaptado de Mohamed et al. (2021).

O sistema foi testado para detecção e localização de DP utilizando um algoritmo independente baseado em RSS e comparado com um sistema usando tecnologia de rádio definido por *software* (SDR, do inglês: *Software Defined Radio*). A partir dos resultados

obtidos, pode-se destacar que o algoritmo de localização desenvolvido teve um erro considerado baixo (0,8 m) para o sensor radiométrico. Além disso, os sistemas avaliados demonstraram confiabilidade e viabilidade de implementação para detecção e localização de DP, com menor custo que os métodos tradicionais.

Em Ghanakota et al. (2022) foram avaliadas as capacidades de medição de quatro técnicas diferentes de aquisição de sinal UHF: detecção de pulso de sinais de DP, amostragem de envoltória de sinais, amostragem heteródino de sinal de DP e amostragem passa banda de sinal. Dentre as quatro técnicas comparadas, as duas primeiras aplicam a técnica de detecção de envoltória durante a medição de sinais. O diagrama de blocos para detecção de pulsos de sinais de DP é mostrado na Figura 3.19. Ele consiste em uma cascata linear de amplificador de baixo ruído (LNA) de banda larga, um detector de envelope, um comparador e um flip-flop SR. Um computador de placa única (SBC, do inglês: *Single Board Computer*) é proposto para contar e enviar a ocorrência de eventos de DP, junto com o tempo e o valor quadrático médio (RMS) dos pulsos DP, para a nuvem para monitoramento *on-line* remoto.

Figura 3.19 - Diagrama de blocos de detecção de pulso PD usando sensor UHF.



Fonte: Adaptado de Ghanakota et al. (2022).

Nesta técnica a envoltória do sinal de DP era comparada com uma tensão de limiar (VTH, do inglês: *Threshold Voltage*) para detectar o evento de DP. Quando o comparador detectava que o sinal ultrapassou o limiar, ele gerava um sinal que era registrado (ou "travado") no pino Q de um flip-flop SR. O evento de DP registrado era enviado para um computador de placa única, que foi programado para contar o número de pulsos de DP, registrar a tensão RMS, resetar o flip-flop SR para preparar o sistema para a próxima medição, e enviar os dados coletados para a nuvem, permitindo o monitoramento remoto online.

Na técnica de amostragem de envoltória, o sinal de DP é filtrado por um filtro passa-baixa e, em seguida, a envoltória do sinal é calculada usando a transformada de

Hilbert. Posteriormente, um filtro de média móvel é aplicado para obter a Raiz Média Quadrática (RMS) da envoltória do sinal. A análise dos resultados inclui a visualização da envoltória RMS do sinal de DP, as respostas de magnitude e fase do filtro passa-baixa e a comparação entre a envoltória RMS amostrada na saída do conversor A/D e na saída do filtro de média móvel.

As quatro técnicas de medição abordadas no estudo de Ghanakota et al. (2022) foram comparadas em vários fatores, como largura de banda, taxa de amostragem, complexidade de hardware, reconfigurabilidade, custo e recursos de IoT (do inglês: *Internet of Things*) para monitoramento de DP *online*. Pode-se observar que as técnicas de detecção de pulso e amostragem de envoltória são de medição simples e de baixo custo. Essas duas técnicas podem ser facilmente adotadas para monitoramento de DP *online* devido à largura de banda relativamente baixa do sinal processado (0-250 MHz). Além disso, de acordo com os resultados apontados pelo artigo essas técnicas têm potencial para serem implantadas no campo junto com sensores UHF distribuídos conectados a arquiteturas de reconstrução de sinal de DP que possuem identificação de fonte de DP e recursos de localização.

As pesquisas destacadas nesta seção demonstraram que a aplicabilidade da técnica de detecção de envoltória na medição e monitoramento da atividade de DP de sinais radiométricos é promissora, uma vez que o detector de envoltória permite a diminuição da taxa de amostragem necessária para a obtenção do pulso de DP. Além disso, em alguns trabalhos foi destacada a possibilidade da minimização de interferências aplicando o detector de envoltória. Essas descobertas evidenciam não apenas a eficácia do detector de envoltória, mas também sua relevância para aprimorar os métodos de detecção e análise de DP, contribuindo assim para avanços significativos na área de monitoramento e diagnóstico de sistemas elétricos.

No entanto, conforme destacado, a utilização da detecção de envoltória permite diversos níveis de suavização de sinais. Os estudos anteriores carecem de uma avaliação da capacidade do sistema desenvolvido de manter informações suficientes para a classificação de múltiplas fontes. Essa avaliação é essencial, pois a suavização de sinais pode resultar na perda de informações, comprometendo a eficácia da classificação de fontes. Mais adiante, neste trabalho, será realizada a análise da capacidade do sistema desenvolvido em suavizar sinais, mantendo informações suficientes para a classificação.

Na seção seguinte as principais pesquisas relacionadas ao processo de extração de atributos de sinais de DP serão apresentadas e discutidas.

3.3 EXTRAÇÃO DE ATRIBUTOS PARA SEPARAÇÃO DE DESCARGAS PARCIAIS

No final da década de 1960, o Working Group 21.03 (1969) publicou um resumo clássico sobre o reconhecimento de descargas. Os autores elaboraram um sistema para diagnosticar as possíveis origens das descargas a partir de suas características observadas. Padrões de descargas típicos e de interferência foram descritos em termos de distribuição de descargas em cada parte do ciclo da tensão aplicada e na variação de magnitude com a tensão de teste e o tempo de aplicação. Seguindo a mesma metodologia, Natrass (1988) apresentou um trabalho que buscava auxiliar o processo de interpretação de sinais de DP a partir da identificação do padrão visual da DP plotada em gráficos elípticos.

A introdução de técnicas de processamento digital permitiu que o reconhecimento de DP, realizado anteriormente de maneira visual a partir do estudo dos padrões de descarga na elipse, fosse automatizado. Em 1992, Gulski e Kreuger (1992) fizeram uso de um analisador de descarga auxiliado por computador no estudo de uma combinação de parâmetros estatísticos e de descarga para promover a separação entre diferentes fontes de DP. As distribuições de descargas foram analisadas por meio de operadores estatísticos e uma melhoria importante na caracterização das descargas foi mostrada com o uso de operadores (*skewness*, curtose e fator de correlação cruzada modificado) que representam uma análise estatística das distribuições fase-posição. Já em 1993, no trabalho de Gulski e Krivda (1993), o reconhecimento de fontes de DP foi realizado a partir da aplicação de Redes Neurais Artificiais (RNA), cujas entradas eram os dados referentes aos parâmetros estatísticos extraídos de gráficos PRPD.

Posteriormente, Krivda (1995) publicou um artigo de revisão geral sobre procedimentos de reconhecimento automatizado de DP. Em seu trabalho, Krivda (1995) discutiu sobre a seleção de padrões de DP, extração de informações relevantes para o reconhecimento de DP e a estrutura de um banco de dados para o reconhecimento de DP. Nos anos seguintes, pesquisas dedicadas a métodos de separação e classificação de sinais de DP continuaram em desenvolvimento e atributos representativos foram extraídos de formas de onda de pulso de DP e aplicados à separação de sinais (ARDILA-REY, J. A.; MARTÍNEZ-TARIFA, J. M.; ROBLES, G.; ROJAS-MORENO, 2013; CAVALLINI et

al., 2003a; CONTIN et al., 2002; HAO; LEWIN, 2010; HUNTER; HAO; LEWIN, 2010; PENG et al., 2013).

Em (Cavallini et al. (2003a) e Contin et al. (2002) os autores utilizaram atributos baseados nas características estocásticas dos pulsos de DP para a separação e classificação dos sinais. Isso incluiu a análise da altura e distribuições de fase dos pulsos de DP, bem como a avaliação de características temporais e de frequência dos pulsos adquiridos. Esses atributos foram essenciais para a identificação das fontes de DP, que foi obtida por meio do método de agrupamento baseado em algoritmos *fuzzy*.

Outras abordagens de separação e classificação de fontes de DP foram propostas usando ferramentas de classificação como *Support Vector Machine* (HAO; LEWIN, 2010; HUNTER; HAO; LEWIN, 2010), técnicas como a Transformada *Wavelet* (HAO et al., 2011), e análise espectral (ARDILA-REY, J. A.; MARTÍNEZ-TARIFA, J. M.; ROBLES, G.; ROJAS-MORENO, 2013).

Hao et al. (2011) apresentaram um procedimento para a identificação de sinais de DP gerados por múltiplas fontes utilizando Transformada *Wavelet*. Os autores partiram do pressuposto que diferentes fontes de DP exibiriam perfis de sinais distintos, que se manifestariam na distribuição de energias em relação a frequência e ao tempo. Dessa forma, a técnica foi baseada na comparação de energias do sinal associadas a determinados níveis de decomposição *Wavelet*. Os atributos foram extraídos de pulsos de DP individuais e projetados em um espaço tridimensional para permitir o agrupamento de dados de fontes de DP específicas. O algoritmo DBSCAN foi escolhido devido a sua capacidade de identificar *clusters* de forma arbitrária no espaço de n dimensões. Os autores comprovaram a robustez do algoritmo proposto aplicando conjuntos de dados que foram coletados usando uma variedade de técnicas (sensores de largura de banda diferentes, diferentes taxas de amostragem de aquisição etc.) em diversas configurações de objeto de teste, dentre os quais foram utilizados arranjos com barras como fontes de DP. A partir dos resultados obtidos, os pesquisadores concluíram que em todos os casos discutidos o sistema proposto conseguiu separar efetivamente os sinais produzidos por fontes conhecidas.

No trabalho de Ardila-Rey et al. (2013), análises de potência espectral de pulsos de DP e as relações de potência espectrais em diferentes frequências foram calculadas para classificar fontes de DP e ruído por meio de uma representação gráfica em um plano. Um sistema de aquisição de padrões PRPD e visualização de forma de onda de pulso foi programado para desenvolver este algoritmo de classificação. A partir dos resultados

obtidos nos testes, os autores concluíram que as relações de potência do sinal resultaram em *clusters* diferentes para ruído e descargas para todos os objetos de teste estudados. Além disso, cada tipo de fonte de DP (interna, de superfície e corona) resultou em um *cluster* localizado em uma posição diferente ou com uma forma diferente no mapa de razão de potência.

Peng et al. (2013) propuseram uma metodologia para aplicação do método *K-Means* à tarefa de reconhecer padrões de DP sem informação de referência de fase. Uma taxa de reconhecimento de 80% foi alcançada quando o algoritmo foi testado em 85 conjuntos de dados de monitoramento *on-line*, quando a sobreposição de sinal não é empregada. No entanto, a acurácia aumentou para 100% ao sobrepor 5 ciclos de registros de dados, demonstrando que o método é eficaz. Os resultados apresentados demonstraram que a metodologia proposta é capaz de reconhecer padrões de atividade DP em aplicações de monitoramento *on-line* para cabos monofásicos e trifásicos e é uma técnica eficaz para rejeitar sinais de interferência.

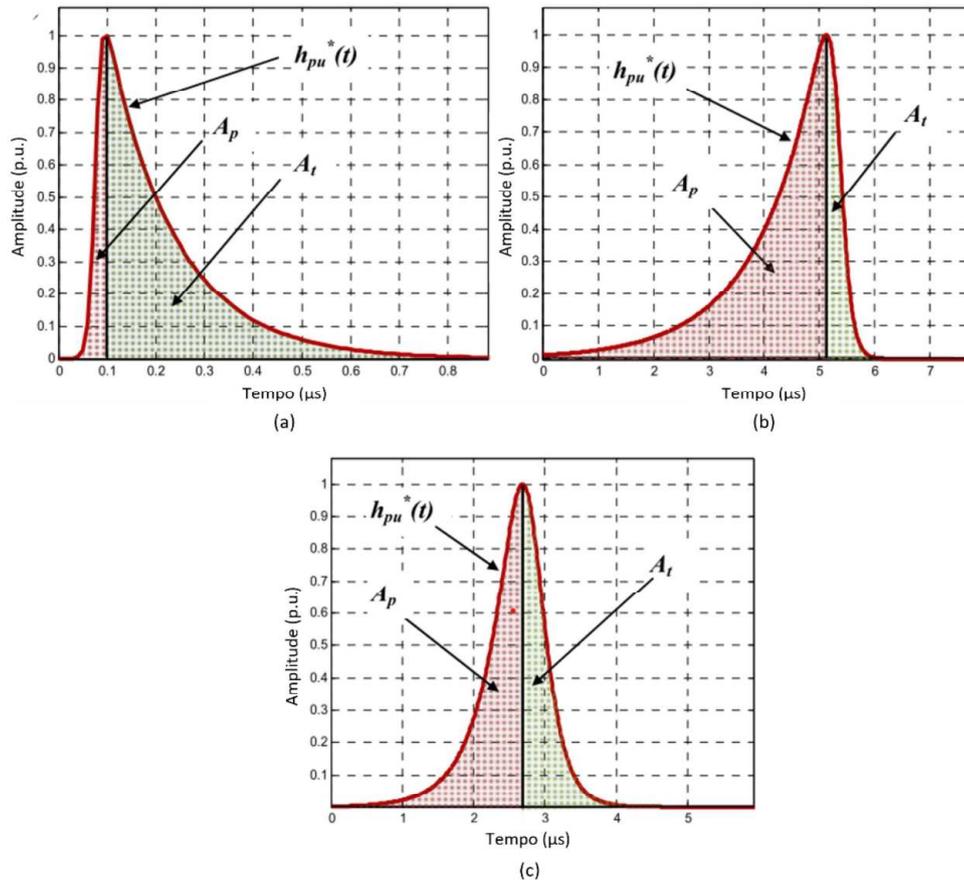
A técnica de processamento de sinal com base na distribuição de potência dos sinais de entrada em bandas de frequência, *power ratios*, pode ser usada para caracterizar diferentes fontes de DP e ruído eletromagnético (ALBARRACIN et al., 2015; ROBLES; FRESNO; MARTÍNEZ-TARIFA, 2015). Em 2015, Robles, Fresno e Martínez -Tarifa (2015) propuseram um método de separação de eventos capturados por antenas e identificação de quais desses eventos seriam DP. A separação dos eventos foi realizada com mapas de razão de potência baseados nas características espectrais do sinal e a identificação do tipo de evento foi realizada localizando a fonte com um arranjo de quatro antenas. Os autores analisaram os sinais dos clusters calculando as diferenças de tempo de chegada (TDOA, do inglês: *Time differences of Arrival*) para todos os pares de antena. Por fim, os resultados dos testes apresentados no artigo demonstraram que DP e interferências puderam ser separadas com mapas de razão de potência e, além disso, as fontes de DP puderam ser localizadas.

No trabalho de Li-Xue et al. (2008), um sistema de diagnóstico de DP para GIS utilizando o método radiométrico baseado em um circuito de detecção de envoltória foi projetado. Os autores propuseram um método de reconhecimento de padrões que analisa os parâmetros característicos da envoltória do sinal no domínio do tempo utilizando uma rede neural BP. Para realização dos testes foram utilizados cinco modelos de defeitos em uma GIS: modelo com partículas metálicas livres, modelo com agulha no condutor, modelo com cavidade de ar no espaçador isolantes, modelo com partículas metálicas no

espaçador isolante e um modelo de eletrodo flutuante. A partir de uma expressiva quantidade de experimentos foi observado que as características no domínio do tempo dos sinais de descarga parcial e as envoltórias geradas pelo mesmo modelo de defeito eram aproximadamente as mesmas. Enquanto as características no domínio do tempo dos sinais de DP e as formas das envoltórias geradas pelos diferentes modelos de defeito eram diferentes. Portanto, os autores concluíram que os parâmetros característicos das envoltórias dos sinais podiam ser amostrados e usados em algoritmos de rede neural para reconhecimento de padrão. Sete parâmetros característicos foram usados para descrever a forma da envoltória de sinal radiométrico de DP: tempo de pico de onda, tempo de borda de subida do pulso, tempo de borda de descida do pulso, largura de pulso de descarga, tempo de resistência de descarga aparente, assimetria e curtose. Ao amostrar os parâmetros característicos dos sinais de envoltória e usar o reconhecimento de modelo com base em uma rede neural BP, os defeitos testados foram distinguidos com uma taxa de reconhecimento alta, sendo a menor delas de 96% para o modelo com partículas metálicas no espaçador isolante e 100% para os modelos de eletrodo flutuante e agulha no condutor.

Alvarez et al. (2016) apresentaram uma ferramenta de classificação de sinais de DP baseada em uma modelagem matemática da forma de onda dos sinais registrados. Os autores aplicaram a ferramenta proposta para a classificação de sinais de DP e interferências de ruídos medidos com sensores HFCT em sistemas de cabos em laboratório. O dispositivo de medição utilizado nos testes de DP inclui uma ferramenta de filtragem de ruído baseada na transformada *Wavelet*. O filtro foi utilizado para que os sinais em forma de pulso fossem diferenciados do ruído de fundo contínuo. No artigo, três parâmetros característicos (f , A_p e A_t) eram obtidos automaticamente para cada sinal em forma de pulso medido. O parâmetro f caracterizava o conteúdo de frequência do sinal, enquanto A_p e A_t descreviam, respectivamente, a área de pico e área de cauda da envoltória normalizada. Essas áreas são limitadas pela função de envoltória normalizada $h_{pu}^*(t)$, desde o início até o ponto de máxima amplitude e deste ponto até seu final, conforme pode ser observado na Figura 3.20.

Figura 3.20 – Função envoltória normalizada, área de pico e área de cauda demonstradas na envoltória de três sinais de DP: (a) Sinal de DP assimétrico com cauda em direção a direita. (b) Sinal de DP assimétrico com cauda em direção a esquerda. (c) Sinal de DP simétrico.

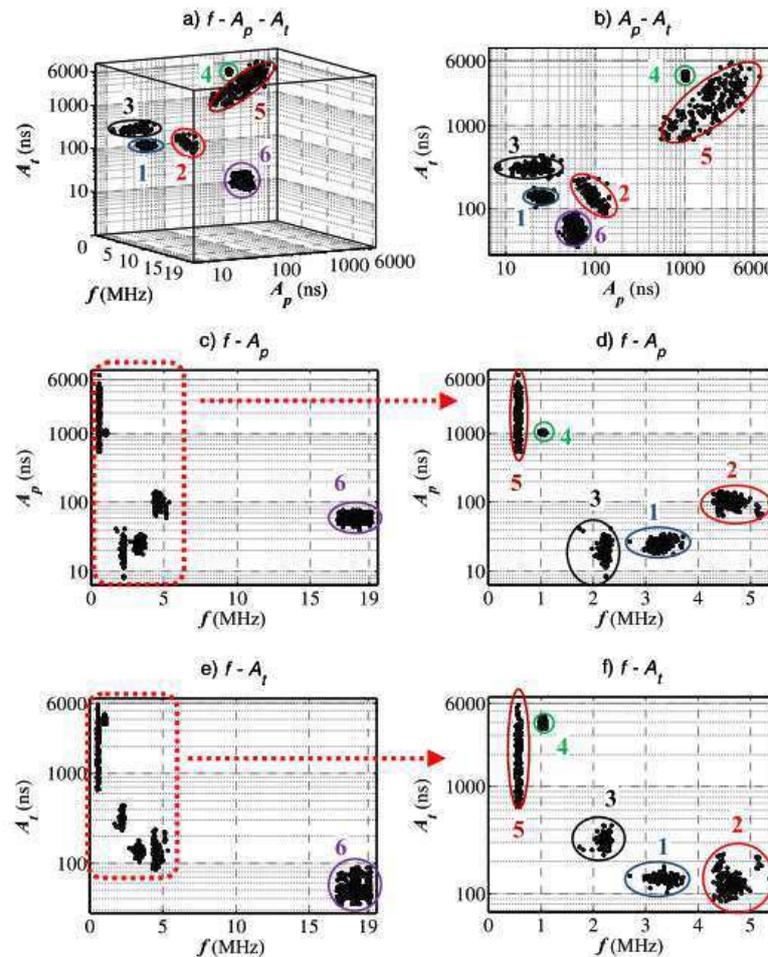


Fonte: Adaptado de Alvarez et al. (2016).

A fim de analisar a sensibilidade dos parâmetros representativos f , A_p e A_t para discriminar diferentes fontes de pulsos, três tipos de fontes de DP foram gerados por Alvarez et al. (2016): uma descarga interna (em uma cavidade de cabo XLPE), um defeito de isolamento de superfície externa e descargas corona. Além disso, três tipos de ruído estiveram presentes durante o teste: uma fonte de ruído foi gerada pelos IGBTs do sistema ressonante usado para aplicar alta tensão; ruído do tipo pulso eletrônico com comportamento repetitivo foi produzido pelo chaveamento dos transistores de um dispositivo eletrônico de potência conectado à rede elétrica do laboratório; e uma quantidade significativa de sinais em forma de pulso aleatórios conduzidos pela rede de cabos de terra foram medidos. O diagrama 3D (f - A_p - A_t) e os diagramas 2D (A_p - A_t , f - A_p e f - A_t) mostrados na Figura 3.21 permitem visualizar claramente os clusters formados. As Figuras 3.21(d) e 3.21(f) mostram uma ampliação em alta resolução da área marcada em vermelho nas Figuras 3.21(c) e 3.21(e), a fim de melhor visualizar os aglomerados

que se formaram. Com os resultados obtidos por Alvarez et al. (2016) foi possível concluir que a identificação das fontes de DP e de ruídos foi realizada de maneira satisfatória.

Figura 3.21 –Diagramas 3D e 2D para os parâmetros $(f-A_p-A_t)$. a) 3D $(f-A_p-A_t)$, b) 2D $(A_p - A_t)$, c) 2D $(f-A_p)$, d) vista detalhada do diagrama $f-A_p$, e) 2D (A_t-f) e f) vista detalhada do diagrama $f-A_t$.

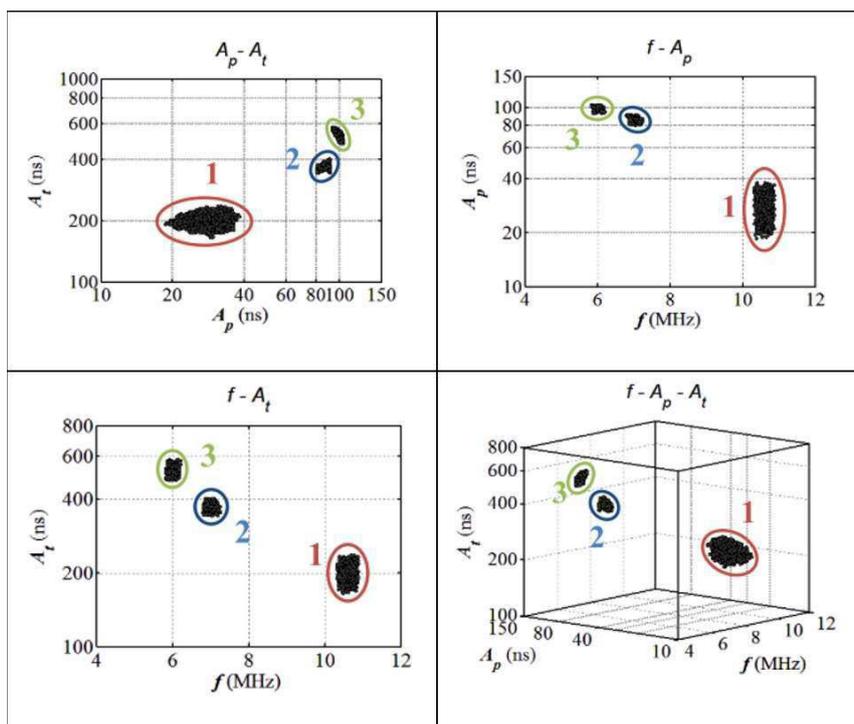


Fonte: Alvarez et al. (2016).

No trabalho de Alvarez, Garnacho, Khamlichi e Ortego (2016), a técnica de classificação de sinais de DP apresentada em Alvarez et al. (2016) é aplicada. A fim de provar a eficácia dos parâmetros de classificação na separação de diferentes fontes de pulso, os autores realizaram medições de DP em uma instalação real de Alta Tensão (AT) utilizando sensores HFCT. Os sinais contínuos de ruído de fundo foram removidos usando um filtro Wavelet como Alvarez et al. (2016). Os valores calculados de f , A_p e A_t para os pulsos medidos foram representados em diagramas 2D e 3D, assim os sinais foram diferenciados conforme pode ser observado na Figura 3.22. Os padrões PRPD correspondentes são mostrados na Figura 3.23. Ao analisar os padrões, três fontes de DP

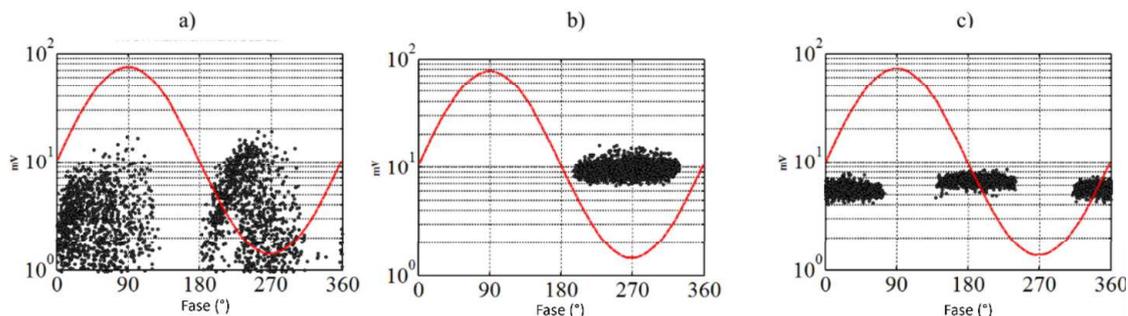
foram identificadas: defeito interno em cabo isolado; efeito corona na linha aérea e eletrodo com potencial flutuante. Dessa maneira, a partir dos resultados obtidos, Alvarez, Garnacho, Khamlichi e Ortego (2016) concluíram que o modelo descrito foi bem-sucedido na identificação de fontes de DP.

Figura 3.22 - Representação dos parâmetros f , A_p e A_t em diagramas 2D e 3D para a classificação de pulsos de DP em *clusters*.



Fonte: Alvarez, Garnacho, Khamlichi e Ortego (2016).

Figura 3.23 - a) Padrão de DP do cluster 1 (defeito interno), b) Padrão de DP do cluster 2 (efeito corona) c) Padrão PD do cluster 3 (eletrodo com potencial flutuante).

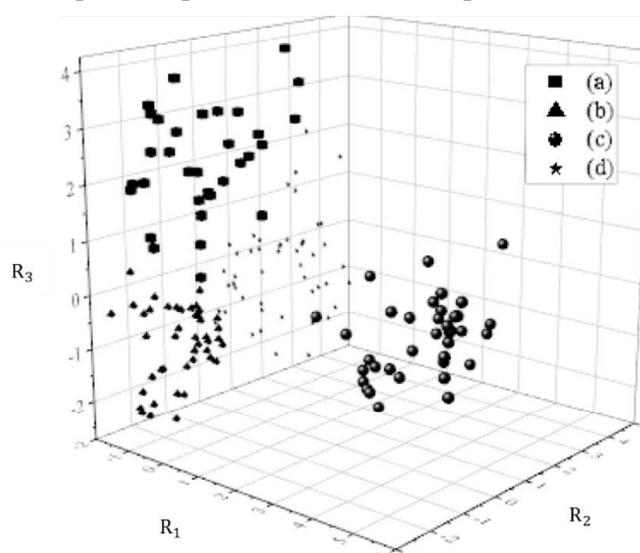


Fonte: Alvarez, Garnacho, Khamlichi e Ortego (2016).

No trabalho Han et al. (2019), os autores promoveram a separaram de diferentes defeitos a partir de atributos extraídos das envoltórias dos sinais radiométricos de DP. A partir da forma de onda suavizada do sinal radiométrico de DP, os autores extraíram os

seguintes parâmetros: valor de pico, valor RMS (do inglês: *Root Mean Square*), amplitude média e amplitude da raiz quadrada. Utilizando esses parâmetros, os seis recursos utilizados na identificação dos defeitos foram obtidos, são eles: distorção, curtose, fator de forma, fator de crista, fator de impulso e fator de liberação. Os seis tipos de valores próprios dos sinais de defeito típicos obtidos foram reduzidos por Análise Discriminante Linear (LDA- do inglês: *Linear discriminant analysis*) e denotados por R1, R2, R3 no novo espaço de recursos. A distinção dos defeitos em clusters pode ser observada na Figura 3.24, onde: (a) representa defeito de protrusão de metal; (b) representa defeitos por partículas de metal livres; (c) representa defeito em eletrodos; (d) representa defeitos de entreferro.

Figura 3.24 - Quatro tipos de representação de defeito após redução de dimensionalidade.



Fonte: Adaptado de Han et al. (2019).

Por fim, os autores selecionaram aleatoriamente 200 grupos de amostras contendo os 4 tipos de defeitos e testaram com 52 conjunto de dados. Trinta testes foram realizados para obter uma acurácia de classificação mais estável, a acurácia da classificação foi expressa em 5 e a acurácia média foi de cerca de 83,16%.

Em Palo et al. (2020) um método de reconhecimento de padrões foi desenvolvido para classificar os sinais de RF registrados em uma subestação de alta tensão de 220 kV. Quatro antenas bicônicas de banda larga foram instaladas próximas a diversas fontes potenciais de descargas como barramentos e buchas. Além disso, um emulador artificial de DP foi instalado na área monitorada e acionado com frequência de 50 Hz. O agrupamento foi realizado por meio de um método não supervisionado chamado

Agrupamento Hierárquico Aglomerativo (HAC, do inglês: *Hierarchical agglomerative clustering*). Os eventos foram agrupados com base na matriz de correlação cruzada, usando o critério de Ward. Ao todo, 9 grupos de eventos foram identificados, e localizados usando a diferença de tempo de chegada (TDOA, do inglês: *Time Difference Of Arrival*) em uma grade 2D. Além disso, uma rede neural foi treinada para reconhecer adequadamente o padrão existente entre um número selecionado de atributos e para classificar eventos de entrada de acordo com as classes de destino (ou seja, os *clusters*). Os seguintes atributos foram extraídos: forma de onda, envoltória, fase, energia, SNR, e tempos de pulso. Os resultados evidenciariam que o atributo forma de onda apresentou a melhor acurácia absoluta (AA) de 95% e uma acurácia relativa (AR) de 87% ou mais. Com diferentes combinações de atributos (SNR, potência, fase e tempos de pulso) o AA variou de 54 a 84%. As acurácias mais baixas foram encontradas usando apenas os tempos de pulsos, com esta configuração, os eventos de três clusters nunca foram classificados corretamente. Um aumento de acurácia ocorreu quando a envoltória é adotada, sozinha ou combinado com outros atributos. Neste caso, AA varia em 88-95%, com AR maioritariamente superior a 80%. Em particular, os sinais do emulador PD são reconhecidos em 92-96% dos casos. Apesar da utilização de um emulador de DP, destaca-se como uma das principais contribuições do trabalho a utilização de sinais detectados em ambiente de subestação de alta tensão. Uma contribuição adicional seria a utilização da envoltória dos sinais como atributo para o algoritmo.

Uma vez que a técnica radiométrica tem a vantagem de detecção sem influenciar a operação normal do equipamento, ela pode ser considerada uma abordagem eficaz para medir a ocorrência de DP em buchas. Em Jiang et al. (2021), são investigados 16 atributos no domínio do tempo e da frequência de sinais UHF de diferentes tipos de defeitos de DP em buchas de 110 kV. A detecção dos sinais de DP foi feita por meio de sensores UHF conectados a um módulo amplificador de sinal e um osciloscópio para aquisição de dados. Além disso, um detector de DP foi adotado para inspecionar o nível de descarga durante o teste. Para adquirir a forma de onda do sinal UHF foi utilizada uma taxa de amostragem de 10 GS/s, e o período de amostragem foi de 1 μ s. Para cada tipo de DP, foram realizadas 1000 aquisições.

A classificação dos sinais de DP realizada por Jiang et al. (2021) envolveu três etapas distintas. Primeiramente, os autores empregaram diferentes técnicas de geração de envoltória, como interpolação por spline cúbica e suavização por função gaussiana, visando reduzir o excesso de informações dos sinais. Em seguida, foram extraídos 16

atributos nos domínios do tempo e da frequência, incluindo medidas como valor médio absoluto, valor médio quadrático, variância, tempo de subida e tempo de queda no domínio do tempo, e valor médio absoluto, valor médio quadrático, variância, valor máximo absoluto correspondente à amplitude e à frequência, energia do espectro, assimetria e curtose no domínio da frequência (faixa UHF). Esses parâmetros foram calculados para cada tipo de envoltória e posteriormente reduzidos utilizando técnicas como Análise de Componentes Principais (PCA) e Árvores Aleatórias (ET) para facilitar a classificação e o diagnóstico. Por fim, um modelo foi construído e a classificação de DP foi realizada por meio do SVM, utilizando as características selecionadas por PCA e ET como entrada para treinamento e classificação. O aumento do número de atributos de entrada contribuiu para melhorar a acurácia da classificação dos 4 tipos de falhas, demonstrando a representatividade das características selecionadas. Embora o estudo ofereça uma solução eficaz para detecção e diagnóstico de DP em buchas com óleo impregnado em transformadores de potência, é importante ressaltar que a extração de envoltória durante a detecção (utilizando hardware adequado) em vez de após a detecção poderia permitir a aquisição dos sinais com uma menor taxa de amostragem, resultando em redução de custos operacionais e computacionais.

Wotzka, Sikorski, Szymczak (2022) avaliaram o impacto do tipo de antena utilizada e do tipo de algoritmo de metodologi supervisionado na eficácia da classificação de DP. Para tanto, foram utilizadas na pesquisa quatro antenas adaptadas para instalação no tanque do transformador (sensor de disco UHF, sensor de válvula de drenagem UHF, antena fractal curva de Hilbert e antena planar meandered-F invertido). Adicionalmente, foi utilizada uma antena log-periódica de banda larga, que serviu de referência para as demais antenas. Essas antenas registraram os sinais UHF gerados por cinco tipos de DP que ocorrem no isolamento papel-óleo do transformador, ou seja, DP em gap de óleo, DP em óleo, DP em bolhas de ar no óleo e descargas superficiais. Para os pulsos de DP registrados, foram extraídos nove atributos no domínio da frequência e quatro no domínio Wavelet. Dentre os métodos disponíveis de aprendizado de máquina supervisionado, foram selecionados seis algoritmos: *Bayes* (BY), *Tree* (TREE), *Ensemble* (EN), *K-Nearest Neighbor* (KNN), *Linear Discriminant* (LD) e *Support Vector Machine* (SVM). A contribuição mais importante do artigo foi a demonstração de que não há efeito do projeto da antena no desempenho da classificação. Independentemente do tipo de antena, obteve-se uma eficácia média acima de 89,7%. Uma segunda contribuição significativa para o conhecimento dos diagnósticos de descarga registrados em UHF é que apenas a

frequência de pico precisou ser computada para realizar a classificação com altos níveis de acurácia, atingindo o valor de 99,7% para os defeitos selecionados.

Nesta seção, foram abordados e discutidos diversos estudos relacionados à extração de atributos, separação e classificação de sinais de DP. Esses estudos representam avanços significativos no reconhecimento de descargas parciais, demonstrando a evolução das técnicas de processamento de sinal e aprendizado de máquina na identificação e classificação de fontes de DP em diferentes contextos e ambientes. Na próxima seção, será apresentado um resumo das contribuições das pesquisas que aplicam a técnica de detecção de envoltória, destacando também as contribuições desta tese.

3.4 RESUMO DAS CONTRIBUIÇÕES DOS TRABALHOS

PESQUISADOS

Ao longo deste capítulo foram apresentados os principais trabalhos que aplicaram a técnica de detecção de envoltória de sinais de DP para se atingir diferentes objetivos, tais como: reduzir interferências em medições de DP (CHEN et al., 2003; LI-XUE et al., 2008; YUNPENG et al., 2007); reduzir a taxa de amostragem do sistema de medição de DP (CHEN et al., 2003; LI-XUE et al., 2008; PINPART; JUDD, 2010; YUNPENG et al., 2007); localizar fontes de DP (KHAN et al., 2020; MOHAMED et al., 2021; WU et al., 2019) e distinguir diferentes sinais de DP utilizando para isso a energia das envoltórias dos sinais (BAKER; JUDD; MCARTHUR, 2010) ou o coeficiente de similaridade calculado a partir da forma da envoltória do sinal (PINPART; FLETCHER; JUDD, 2008; PINPART; JUDD, 2010).

Observou-se, contudo, uma lacuna significativa na literatura: nenhum desses estudos testou a eficácia da técnica de detecção de envoltória de sinais de DP em subestações, o que é essencial para validar a robustez da técnica em condições práticas de campo. O ambiente de subestação impõe desafios como maior intensidade de ruído eletromagnético e interferências. Portanto, a aplicação da técnica em subestações é fundamental para garantir sua aplicabilidade no monitoramento de DP em condições reais, facilitando sua adoção em larga escala.

Além disso, ainda são escassas as pesquisas que realizam a classificação de sinais de DP a partir da extração de atributos da envoltória do sinal radiométrico, com apenas os estudos de Li-Xue et al. (2008), Han et al. (2019) e Jiang et al. (2021) identificados nesse contexto. Embora Jiang et al. (2021) e Han et al. (2019) tenham proposto soluções para detecção e diagnóstico de DP, ambos utilizaram algoritmos computacionais para extrair as envoltórias dos sinais em uma etapa posterior à detecção, com o objetivo de reduzir informações redundantes. Isso impediu que houvesse uma redução nos requisitos de *hardware* do sistema de aquisição de DP.

No processo de extração de atributos uma investigação exaustiva deve ser realizada, para que uma maior quantidade de informações representativas do sinal possa ser extraída e, dessa forma, a classificação possa ser implementada de maneira eficiente. No entanto, em Li-Xue et al. (2008) apenas sete atributos foram extraídos, dos quais cinco estavam diretamente relacionados a informações temporais do sinal. Outros atributos, como amplitude, energia do sinal e fator de crista, que poderiam agregar informações para o processo de classificação dos sinais, não foram investigados. Além disso, as medições de DP em Li-Xue et al. (2008) foram realizadas em uma GIS, cujo sinal apresenta componentes de frequência distintos comparados à detecção em equipamentos elétricos isolados a óleo, tais como transformadores de potência e transformadores de instrumento (JUDD et al., 1999). Portanto, um sistema de suavização de sinais de DP em GIS não é necessariamente aplicável em outros equipamentos.

No presente trabalho, desenvolveu-se um sistema baseado em *hardware* e algoritmos que promove a separação e classificação de sinais radiométricos de DP a partir de atributos extraídos das envoltórias dos sinais, visando a classificação de sinais de DP em ambiente de subestação. Para isso, realizou-se uma investigação exaustiva para que fossem extraídos e, posteriormente, selecionados, atributos capazes de promover uma separação e classificação eficiente dos sinais radiométricos de DP. Por fim, também são contribuições alcançadas fornecer uma minimização nos níveis de ruído, possibilitar a redução da taxa de amostragem do sistema de aquisição de dados e validar o sistema em campo, por meio de medições em subestações, servindo como uma prova de princípio para a utilização do sistema em uma rede de sensores.

Na Tabela 3.1 é apresentada uma síntese das contribuições dos principais estudos relacionados à extração de atributos para separação ou classificação de DP utilizando as envoltórias dos sinais, bem como as contribuições almeçadas nesta pesquisa.

Tabela 3.1 – Contribuições constatadas nos trabalhos que utilizam detecção de envoltória da revisão bibliográfica e as almejadas nesta pesquisa.

Pesquisadores	Contribuições						
	1	2	3	4	5	6	7
Li-Xue et al. (2008)	✓	✓	✓			✓	
Pinpart, Fletcher e Judd (2010)	✓	✓	✓			✓	
Baker et al. (2010)	✓	✓	✓			✓	
Han et al. (2019)			✓	✓			
Jiang et al. (2021)			✓	✓	✓		
Esta Pesquisa	✓	✓	✓	✓	✓	✓	✓

Descrição das Contribuições

1. Reduz interferências na detecção de sinais radiométricos de DP;
2. Desenvolve e/ou aplica um sistema de detecção com placa de sensoriamento com detector de envoltória;
3. Realiza a extração de atributos das envoltórias dos sinais de DP para separação e ou classificação de fontes de DP;
4. Seleciona dentre os atributos extraídos quais são mais efetivos para separação e/ou classificação;
5. Avalia diferentes técnicas de aprendizado de máquina para separação e classificação de sinais radiométricos de DP;
6. Reduz os requisitos de *hardware* do sistema de aquisição de dados.
7. Testa o sistema em condições de subestação.

Neste capítulo foi apresentada uma revisão bibliográfica com o objetivo de mapear e compreender o estado da arte em que esta tese se insere. Esse levantamento permitiu identificar os avanços, as principais tendências e as lacunas existentes na literatura, oferecendo uma base sólida para o desenvolvimento deste estudo e contribuindo para uma compreensão mais profunda das abordagens e metodologias atualmente empregadas na área. No próximo capítulo será apresentada a metodologia aplicada no desenvolvimento desta tese.

4 METODOLOGIA

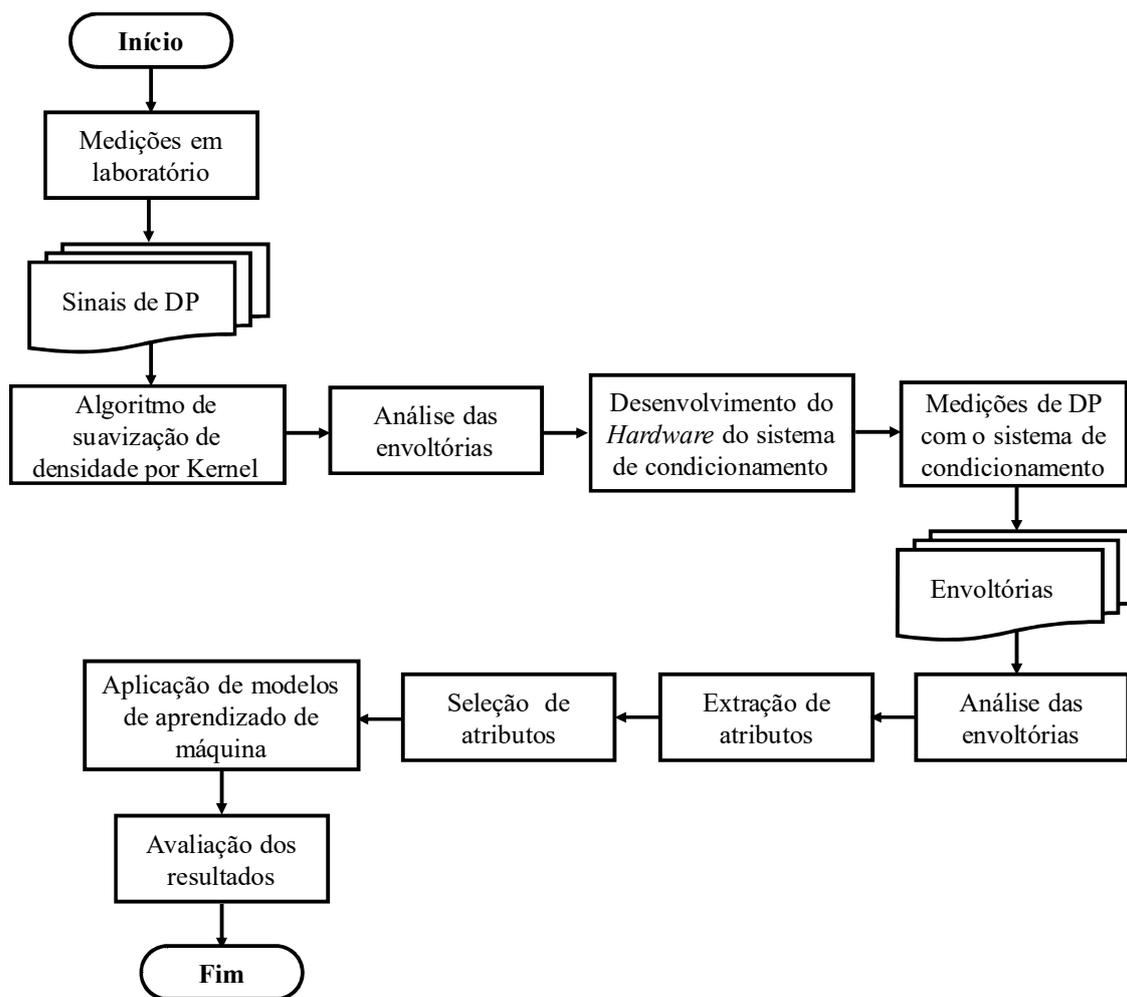
Neste capítulo é descrita a metodologia aplicada para alcançar os objetivos traçados nesta tese. A metodologia se baseia nos procedimentos adotados para o desenvolvimento de um sistema de condicionamento de sinais que utiliza a técnica de detecção de envoltória-

Inicialmente, os sinais de DP medidos foram suavizados utilizando um algoritmo de densidade por Kernel para geração das envoltórias. Esse procedimento foi fundamental para avaliar a redução dos requisitos de *hardware* proporcionada pela eliminação dos componentes de alta frequência. Além disso, essa análise permitiu verificar a viabilidade da técnica de detecção de envoltória em armazenar informações suficientes para a separação e classificação dos sinais. Após a análise das envoltórias por meio de procedimentos computacionais, o *hardware* do sistema de condicionamento de sinal foi desenvolvido e avaliado através de medições em campo e em laboratório.

Por fim, as envoltórias dos sinais detectados passaram por um processo de extração e seleção de atributos. Os atributos selecionados foram aplicados em algoritmos de aprendizado de máquina com o objetivo de avaliar a capacidade de separação e classificação dos sinais de DP, utilizando métricas de desempenho para verificar a eficácia dos modelos.

Os principais procedimentos adotados na metodologia estão resumidos no fluxograma da Figura 4.1

Figura 4. 1 – Fluxograma representativo da metodologia.



Fonte: Autoria própria.

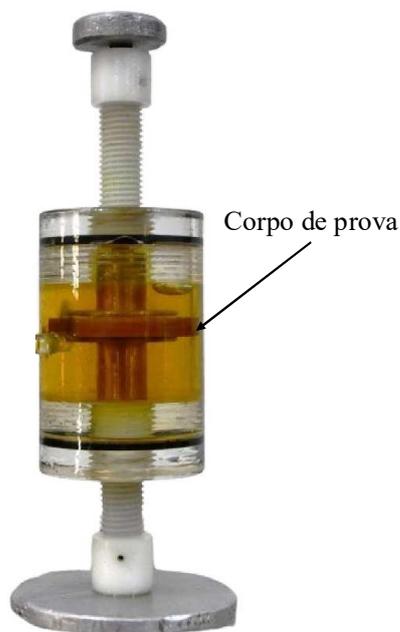
A seguir, é descrita a metodologia utilizada, estruturada nas seguintes etapas: procedimentos experimentais para medição de DP com diferentes objetos de teste; procedimentos computacionais para geração de envoltórias utilizando algoritmo de suavização de densidade; desenvolvimento e teste do *hardware* do sistema de condicionamento de sinais, tratamento dos dados; extração e seleção de atributos das envoltórias; e aplicação e análise de modelos de aprendizado de máquina para separação e classificação dos sinais.

4.1 PROCEDIMENTOS EXPERIMENTAIS

A fim de se gerar um banco de dados para testes preliminares, inicialmente foi elaborado um arranjo experimental para a medição de sinais de DP utilizando o método

elétrico convencional definido pela norma IEC 60270 (2000) e o método radiométrico. Os sinais de DP detectados foram emitidos a partir de três diferentes objetos de teste: um disco de fenolite com cavidades internas imerso em óleo, barra de hidrogerador e um TP. Nas Figuras 4.1 - 4.5, as fotografias dos objetos de teste podem ser observadas.

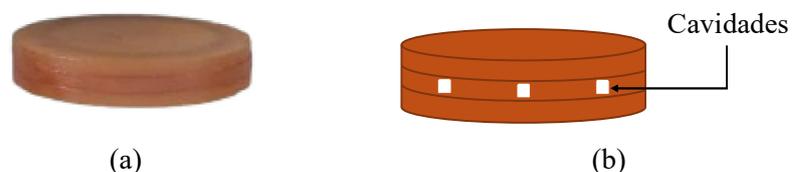
Figura 4.1 – Fotografia da célula cilíndrica de acrílico com corpo de prova imerso em óleo.



Fonte: A autoria própria.

Um corpo de prova de fenolite, emulando uma região de isolamento defeituoso, criado e disponibilizado para o laboratório de alta tensão da UFCG por Macedo et al. (2012), foi colocado no espaço entre os eletrodos da célula, conforme Figura 4.1. O corpo de prova é composto pela sobreposição de placas circulares de material isolante, em que o defeito de isolamento constitui-se da perfuração de três furos de 2 mm na camada intermediária do conjunto. O espaço ao redor do corpo de prova e dos eletrodos foi preenchido com óleo de transformador para evitar descargas superficiais e minimizar corona. Na Figura 4.2, são apresentados a fotografia do corpo de prova utilizado e o diagrama de configuração dos defeitos, utilizado para a geração de descargas parciais (DP).

Figura 4.2 - Corpo de prova: (a) fotografia do corpo de prova utilizado e (b) diagrama de configuração dos defeitos.



Fonte: Autoria própria.

O segundo objeto de teste utilizado, a barra de hidrogerador, compreende um pedaço de bobina de múltiplas espiras retirado do estator de um hidrogerador. A barra de hidrogerador foi alocada entre duas canaletas que funcionam como referência de terra para a medição de DP no isolamento da barra. Para garantir um bom contato superficial do isolamento externo da barra com as canaletas, similar ao que ocorre em um hidrogerador, foram utilizadas duas peças de alumínio fixadas por parafusos para aplicar pressão. A Figura 4.3 apresenta uma fotografia da barra de hidrogerador acoplada entre as canaletas metálicas.

Figura 4.3 – Fotografia de uma barra de hidrogerador utilizada como fonte de DP.



Fonte: Autoria própria.

Na Figura 4.4 pode-se observar uma vista da seção transversal da barra de hidrogerador que é composta por um conjunto de 5 espiras, isoladas entre si. Cada espira possui 8 condutores de cobre, também isolados entre si.

Figura 4.4 –Fotografia da vista da seção transversal da barra de hidrogerador.



Fonte: Autoria própria.

O terceiro objeto de teste foi um TP com isolamento em resina epóxi e classe de tensão de 36 kV, retirado de operação por suspeitas de não conformidades. A Figura 4.5 mostra o TP utilizado nas medições de DP em laboratório.

Figura 4.5 – Fotografia do transformador de potencial de 36 kV utilizado como fonte emissora de DP.

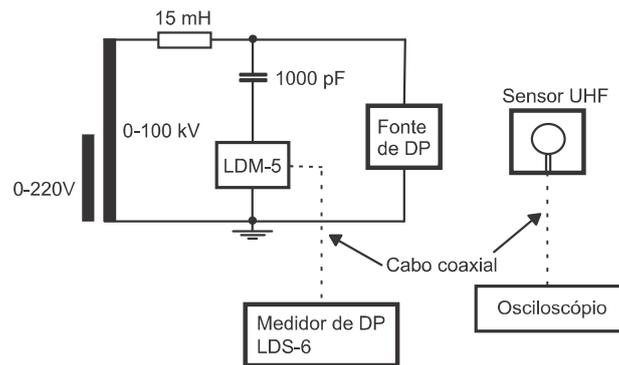


Fonte: Autoria própria.

Na Figura 4.6, é apresentado o diagrama do circuito utilizado para detecção de DP, conforme fotografia do arranjo na Figura 4.7. O procedimento adotado para medição de DP consistiu em um aumento gradativo da tensão, por meio do transformador de alta tensão com tensão nominal de saída de até 100 kV, até que a atividade de DP fosse gerada nos objetos de testes e detectada pela antena, posicionada à distância de 1 m das fontes de DP, e pelo método elétrico disponível na norma IEC 60270 (2000). Para rejeição de ruídos provenientes da rede, foi conectado ao circuito um indutor de 15 mH.

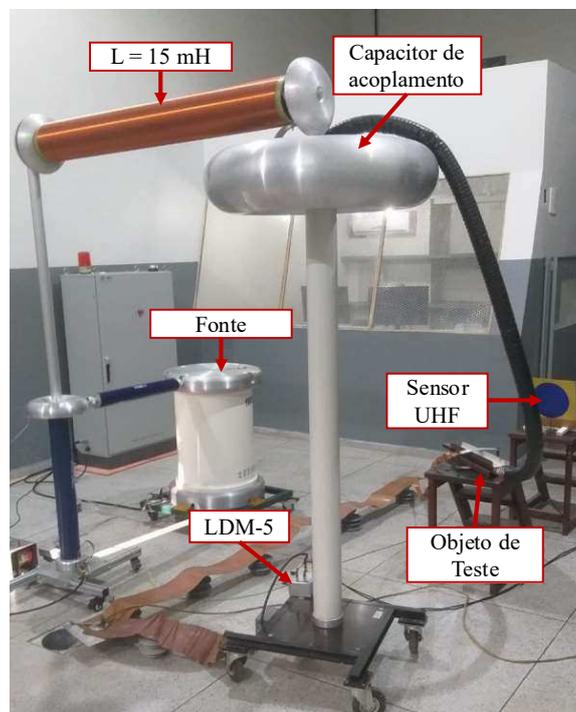
Para medição de DP utilizando o método elétrico, foi utilizado um capacitor de acoplamento de 1000 pF e tensão de isolamento de 300 kV e uma impedância de medição LDM-5, produzida pela Doble Lemke, em paralelo com o objeto de teste. O LDM-5 possui largura de banda de 100 kHz a 20 MHz, tempo de subida menor que 20 ns e corrente máxima permitida de 5 A. Internamente, a impedância de medição é composta por um circuito ressonante, cuja função é prolongar os impulsos de corrente no domínio do tempo para facilitar a sua detecção. Na Figura 4.8 é apresentada uma fotografia da impedância de medição LDM-5.

Figura 4.6 – Diagrama esquemático para medição para detecção de DP.



Fonte: Autoria própria.

Figura 4.7 – Fotografia do arranjo de medição de descargas parciais.



Fonte: Autoria própria.

Figura 4.8 - Fotografia da impedância de medição LDM-5.

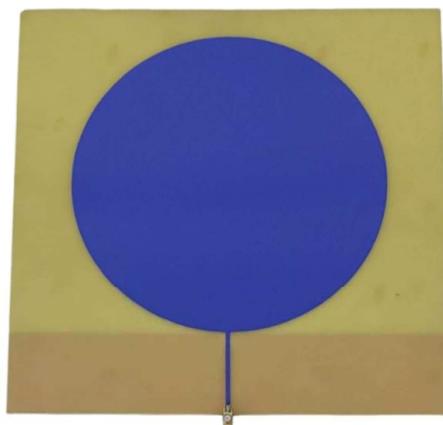


Fonte: Doble Lemke.

Os pulsos captados pelo LDM-5, são amplificados pelo detector de descargas parciais LDS-6 que faz a aquisição dos pulsos de corrente e calcula os equivalentes de carga, em picocoulombs. Para a aquisição dos sinais utilizando o método radiométrico, um sensor no espectro UHF foi posicionado em direção ao objeto de teste, conforme ilustrado nas Figura 4.6 e 4.7.

A antena utilizada nos ensaios é uma antena monopolo impressa circular (XAVIER et al., 2019), apta para aplicação nos testes de detecção de DP, devido à sua largura de banda de operação na faixa de 300 MHz a 1500 MHz, e valor de ganho médio de 3,4 dB. Na Figura 4.9 pode ser verificada a fotografia da antena monopolo circular.

Figura 4.9 – Fotografia da antena monopolo impressa circular.



Fonte: Autoria própria.

Os pulsos de DP detectados pelo sensor UHF foram adquiridos usando um osciloscópio digital InfiniiVision DSO-X 3104A da Agilent Technologies que possui largura de banda de 1 GHz, taxa de amostragem de 5 GSa/s e quatro canais. Antes da energização do sistema, os procedimentos de calibração estabelecidos pela norma IEC 60270 (2000) foram executados para determinação da relação entre a tensão medida e a carga efetivamente injetada no sistema. Para isso, o calibrador LDC-5 da Doble Lemke foi conectado aos terminais do objeto sob teste e a calibração do sistema foi realizada todas as vezes em que a fonte de DP sob teste foi alterada. Os dados de calibração obtidos para os objetos de teste utilizados são apresentados nas Tabelas 4.1 – 4.3.

Tabela 4.1-Dados de calibração para a barra de hidrogerador.

Carga (pC)	Tensão (mV)
20	24,12
100	130,7
500	525,2

Fonte: Autoria própria.

Tabela 4.2- Dados de calibração para a cuba de óleo com eletrodos do tipo ponta-plano.

Carga (pC)	Tensão (mV)
20	17,29
100	86,4
500	426,1

Fonte: Autoria própria.

Tabela 4.3 – Dados de calibração para o transformador de potencial.

Carga (pC)	Tensão (mV)
20	25,33
100	102,1
500	590,2

Fonte: Autoria própria.

Por meio dos resultados apresentados nas Tabelas 4.1 – 4.3 é possível observar que há uma proporcionalidade entre os valores medidos de tensão (mV) e de carga (pC), assim o processo de geração e detecção de DP foi realizado.

As medições de DP obtidas formaram um banco de dados a ser utilizado na etapa que consiste na aplicação e avaliação de um algoritmo de geração de envoltória para suavização do sinal radiométrico de DP.

4.2 MÉTODO DE SUAVIZAÇÃO DO SINAL DE DP –

PROCEDIMENTOS COMPUTACIONAIS

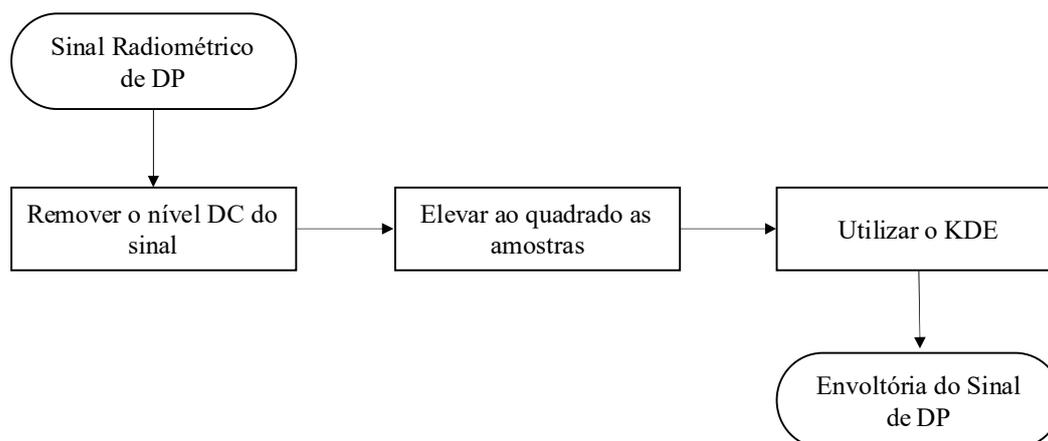
Nesta pesquisa, o detector de envoltória é utilizado com o objetivo de suavizar a curva característica do pulso de DP, para então realizar a diminuição da taxa de

amostragem necessária à obtenção do pulso, mantendo suas formas e características relevantes, tais como energia, duração do pulso e tempo de subida do sinal.

Neste trabalho, a suavização do sinal de DP foi inicialmente avaliada utilizando o método de suavização de densidade por Kernel (KDE – do inglês: *Kernel Density Estimation*) (WEGLARCZYK, 2018) discutido na seção 2.2.

Um diagrama de blocos do algoritmo de geração de envoltória implementado é apresentado na Figura 4.10.

Figura 4.10 – Diagrama de blocos do algoritmo de geração de envoltória utilizando KDE.



Fonte: Autoria própria.

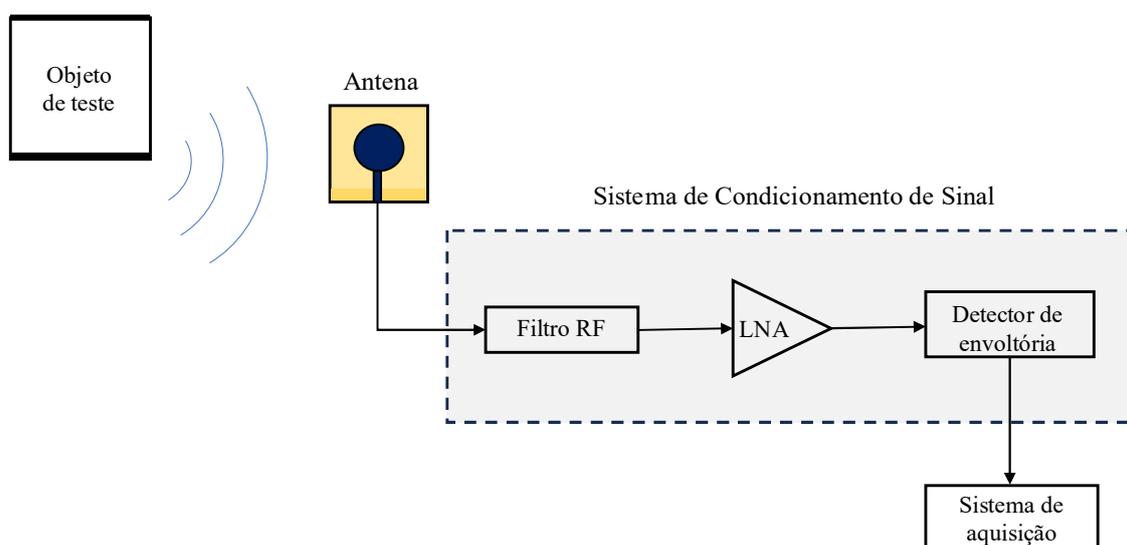
O algoritmo de geração de envoltória de sinais radiométricos de DP foi implementado em um *software* para cálculo numérico e científico de visualização de alta performance., de acordo com os procedimentos descritos no diagrama de blocos da Figura 4.10. Como entrada do algoritmo de detecção de envoltória, foram utilizados os sinais obtidos nas medições de DP realizadas em laboratório, conforme os procedimentos descritos na seção 4.1.

As envoltórias dos sinais de DP geradas foram submetidas a uma análise quanto à capacidade de separação das fontes. Nesse contexto, foram extraídos cinco atributos básicos relacionados à forma do sinal: energia, amplitude, tempo de duração da envoltória, tempo de subida e tempo de descida. Posteriormente, uma análise visual foi conduzida por meio de gráficos em três e duas dimensões. Essa abordagem possibilitou uma análise preliminar da capacidade de separação de sinais com base nos atributos extraídos das envoltórias, a fim de que um sistema baseado em *hardware* pudesse ser desenvolvido. Os resultados e discussões obtidos são apresentados no Capítulo 5.

4.3 SISTEMA DE CONDICIONAMENTO DE SINAIS

Após a avaliação do detector de envoltória via simulação, foi especificado um sistema de condicionamento de sinais para suavização analógica do sinal obtido a partir da antena. O sistema foi projetado para capturar sinais no espectro UHF e gerar envoltórias com frequência reduzida (até 100 MHz), preservando informações suficientes para a análise dos sinais de DP. Na Figura 4.11 é mostrado o esquema de detecção de DP com o sistema de condicionamento de sinais projetado.

Figura 4.11 – Esquemático de detecção de DP com o sistema de condicionamento de sinais.

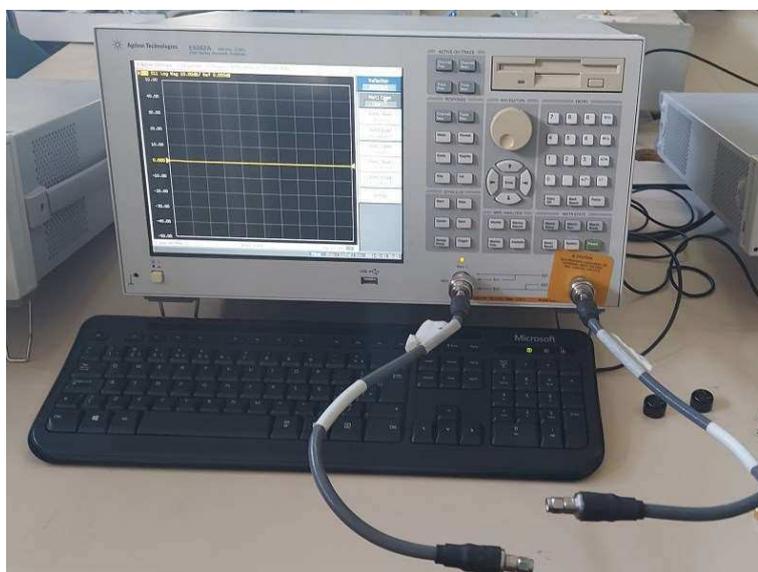


Fonte: Autoria própria.

Conforme apresentado na Figura 4.11, o sinal emitido pelo objeto de teste é detectado pelo sensor UHF em série com o sistema de condicionamento de sinais, composto por um filtro passa-alta, um amplificador RF de baixo ruído (LNA, do inglês: *Low Noise Amplifier*) e um circuito detector de envoltória. O filtro passa-alta de RF aplicado é um filtro Butterworth de 7ª ordem com frequência de corte de 100 MHz, denominado CHPFL-0100, do fabricante Cristek Microwave. Para aumentar a sensibilidade na detecção de sinais DP, foi utilizado um amplificador de RF com faixa de frequência de 30 MHz a 4000 MHz e 40 dB de amplificação. Finalmente, para detectar sinais no espectro UHF, foi utilizado o circuito detector de envoltória ADL5511, do fabricante Analog Devices, que apresenta um dispositivo não linear adequado, o diodo Schottky. O circuito detector de envelope pode operar de DC a 6 GHz em sinais com largura de banda de envoltória de até 130 MHz.

O analisador de rede ENA RF E5062A, Figura 4.12, foi usado para medir o coeficiente de transmissão, S_{21} , tanto do filtro de RF quanto do amplificador de RF, bem como o coeficiente de reflexão, S_{11} , do circuito detector de envoltória.

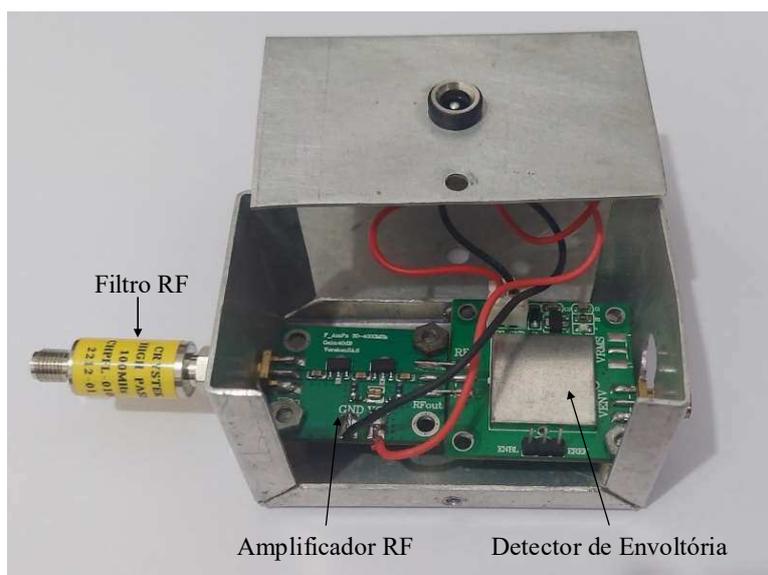
Figura 4.12 - Analisador de rede utilizado para medir os coeficientes de transmissão e reflexão.



Fonte: Autoria própria.

Utilizando o sistema de condicionamento de sinais desenvolvido e analisado, novos ensaios de DP foram realizados em laboratório e em subestação. Na Figura 4.13 pode ser observado a fotografia do sistema de condicionamento de sinal desenvolvido.

Figura 4.13 – Fotografia do sistema de condicionamento de sinal.



Fonte: Autoria própria.

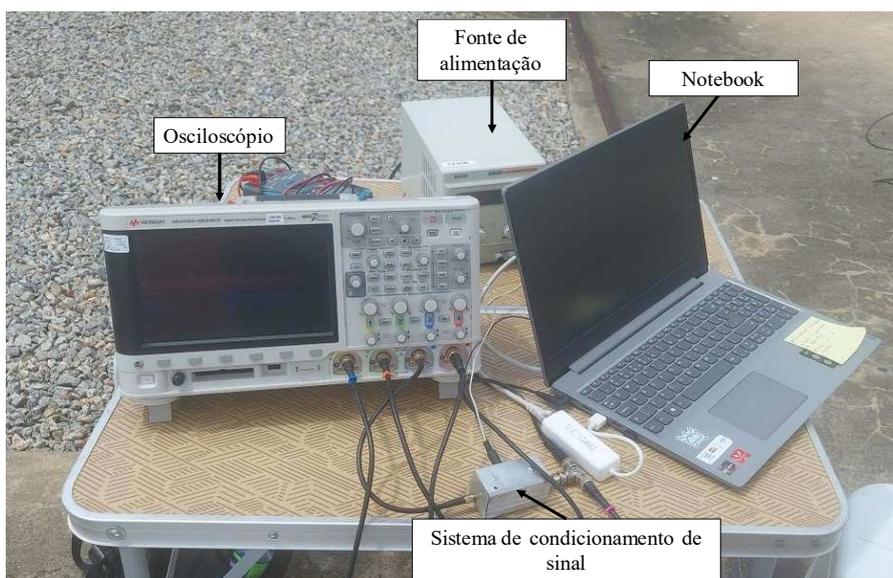
Após a realização das medições de DP em laboratório, de acordo com os procedimentos descritos na Seção 4.1, com o sistema de condicionamento de sinais, as envoltórias de sinais de DP adquiridos dos três objetos de teste foram utilizados na etapa de extração e seleção de atributos a ser discutida na seção 4.5.

4.4 MEDIÇÃO EM SUBESTAÇÃO DE 230 kV

A fim de avaliar o desempenho do sistema em condições de subestação, foram realizadas medições de DP em uma subestação de 230 kV. Durante a inspeção a antena monopolo circular impressa foi direcionada aos equipamentos e os sinais observados no osciloscópio. Dessa forma, detectou-se um aumento na intensidade do sinal próximo a um compensador síncrono, um para-raios e um TC. Em seguida, a aquisição do sinal foi realizada com o sistema de condicionamento de sinais conectado, conforme apresentado na Figura 4.14.

Os sinais radiométricos detectados pela antena foram conectados ao sistema de condicionamento de sinais, que foi utilizado para suavizar os sinais detectados. Adicionalmente, um HFCT foi conectado ao cabo de aterramento do para-raios e do transformador de corrente para confirmar se o sinal detectado pela antena também era captado pelo HFCT. Medições subsequentes confirmaram os resultados obtidos na detecção de DP dos equipamentos analisados.

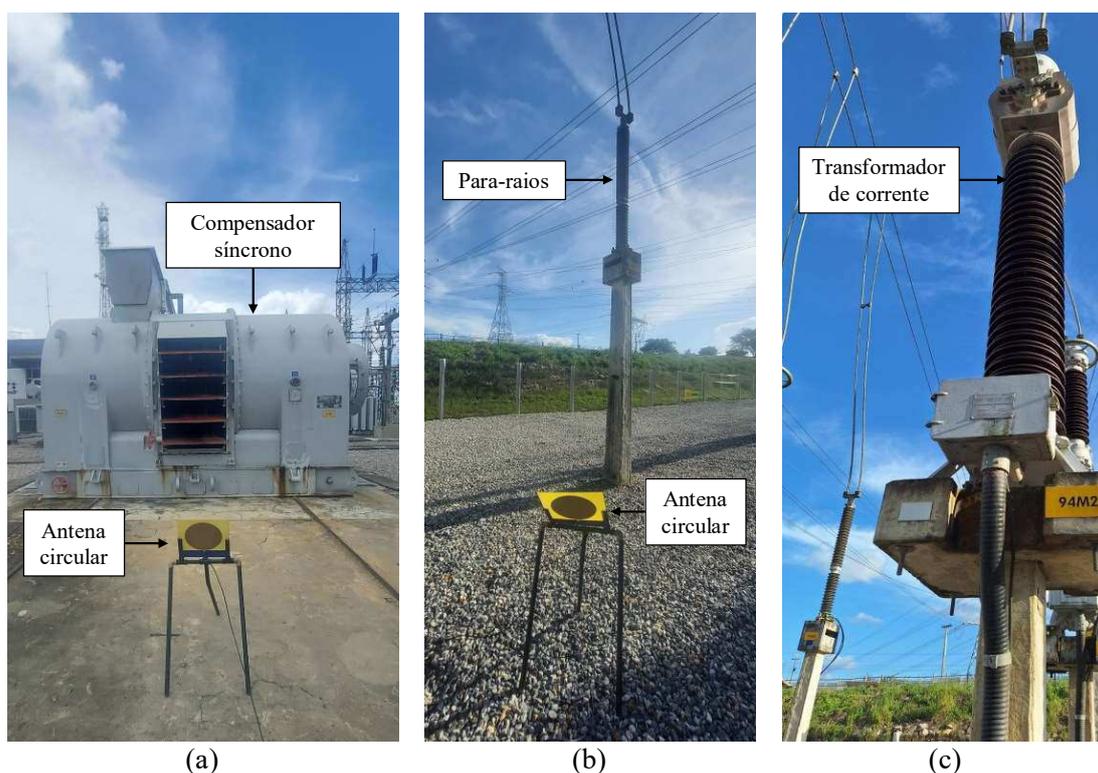
Figura 4.14 – Fotografia do sistema de aquisição de dados durante medição em subestação.



Fonte: Autoria própria.

Os sinais foram adquiridos usando um osciloscópio digital Agilent Technologies InfiniiVision DSO-X 3104A, que possui largura de banda de 1 GHz, taxa de amostragem de 5 GSa/s e quatro canais. Na Figura 4.15 são apresentadas fotografias do compensador síncrono e do para-raios durante a medição.

Figura 4.15 - Fotografia da medição no (a) compensador síncrono, no (b) para-raios e no (c) transformador de corrente.



Fonte: Autoria própria.

As envoltórias dos sinais adquiridos na subestação foram submetidas a um processo de extração e seleção de atributos, conforme descrito na seção 4.5. Os atributos selecionados foram então utilizados nos modelos de separação e classificação.

4.5 EXTRAÇÃO E SELEÇÃO DE ATRIBUTOS

O processo de extração de atributos das envoltórias de sinais de DP foi realizado utilizando um *software* para cálculo numérico. A rotina de extração de atributos foi desenvolvida para processar os sinais de DP obtidos a partir das medições em laboratório e em campo.

Na rotina de extração de atributos, vetores foram inicializados para armazenar os seguintes atributos dos sinais:

- Valor de pico (V_p);
- Valor RMS (V_{RMS});
- Amplitude Média (A_{med});
- Amplitude da Raíz Quadrada (A_{r2});
- Fator de Crista (F_c);
- Fator de Liberação (F_L);
- Fator de Impulso (F_I);
- Fator de Forma (F_F);
- Assimetria (*Skewness* – S_k);
- Curtose (*Kurtosis* – K_u);
- Energia (E_s);
- Duração do sinal (T_t);
- Tempo de subida (T_s);
- Tempo de descida (T_d).

Em seguida, um laço foi implementado para carregar cada arquivo, extrair o sinal, calcular os atributos conforme as equações descritas na seção 2.3, e armazená-los nos respectivos vetores. A rotina processou um total de 2400 arquivos medidos em laboratório e 501 arquivos medidos em subestação. Ao final, os resultados foram exibidos para cada atributo calculado, permitindo uma análise detalhada das características dos sinais de DP.

4.5.1 SELEÇÃO DE ATRIBUTOS

A etapa de seleção de atributos foi realizada utilizando a linguagem de programação Python. Os atributos foram selecionados com a finalidade de investigar sua qualidade em promover a separação de fontes de DP em grupos, detectar padrões semelhantes entre diferentes variáveis e, dessa forma, melhorar a eficiência dos algoritmos de classificação. Nesta tese, os atributos foram selecionados com base nos resultados fornecidos por meio dos métodos RFE, Informação Mútua e Análise de Correlação.

Inicialmente, os dados foram normalizados para garantir que todos os atributos estivessem na mesma escala, evitando que atributos com maior magnitude fossem

indevidamente favorecidos durante processo de seleção. Em seguida, os métodos RFE e informação mútua foram aplicados.

A rotina do RFE iniciou com o carregamento dos dados obtidos na etapa de extração de atributos. Esses dados foram normalizados utilizando o método “MinMaxScaler” da classe “Preprocessing” da biblioteca “Scikit-learn”, ajustando os valores para um intervalo entre -1 e 1. Isso assegura que todos os atributos contribuam de forma equilibrada na análise subsequente.

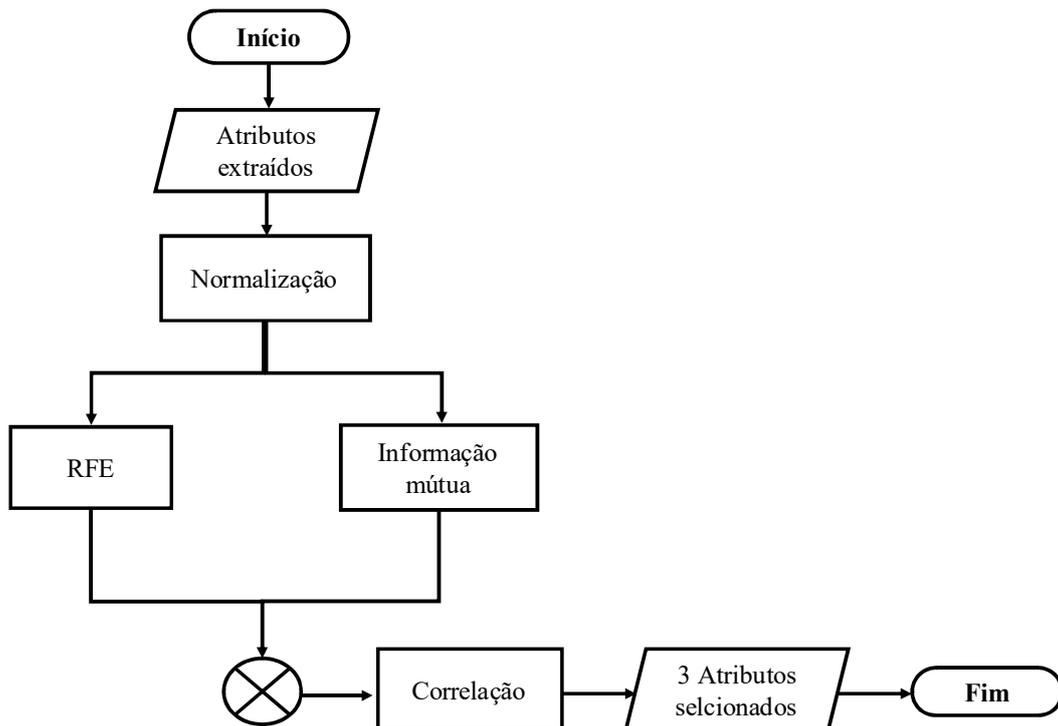
Uma lista de rótulos foi criada para representar as classes correspondentes aos dados, caracterizando um problema de classificação multiclasse. Para a seleção de atributos, foi selecionado o modelo de regressão logística multinomial “LogisticRegression”, configurado com o solver “lbfgs”, adequado para problemas de múltiplas classes. O RFE foi ajustado para selecionar os cinco atributos com maior capacidade de distinguir entre as classes.

Para o algoritmo de informação mútua, foi utilizada a função “mutual_info_classif” para calcular a informação mútua entre os atributos e os rótulos de treinamento. Os valores de informação mútua, calculados para cada atributo, foram encapsulados em um objeto “Series” do Pandas, o que permite associar cada valor de informação mútua ao respectivo atributo. Esses valores foram então organizados em ordem decrescente, de modo a priorizar os atributos com maior contribuição para a distinção entre as classes. Por fim, A função “SelectKBest” foi aplicada, utilizando a informação mútua como critério, para selecionar os 5 atributos maior capacidade de promover a classificação dos dados.

Os atributos selecionados pelo RFE e informação mútua foram analisados por meio de análise de correlação para selecionar os atributos menos redundantes. Essa etapa visa garantir a escolha de atributos que não apenas apresentem variabilidade individual significativa, mas também sejam complementares e menos correlacionados entre si.

O número final de atributos escolhidos foram três, justificados por dois motivos principais. Em primeiro lugar, limitar a seleção a apenas um ou dois atributos pode tornar o modelo excessivamente dependente desses atributos, o que pode resultar em um desempenho insatisfatório. A opção por três atributos aumenta a robustez do modelo, garantindo uma separação e classificação mais equilibradas. Em segundo lugar, limitar a quantidade de atributos em três permite uma representação gráfica mais clara dos algoritmos de agrupamento, facilitando a interpretação dos resultados. O fluxograma da Figura 4.16 resume o processo de seleção de atributos.

Figura 4.16 - Fluxograma de seleção de atributos.



Fonte: Autoria própria

O procedimento adotado para seleção de atributos fornece uma abordagem abrangente e robusta que considera tanto a importância individual quanto a inter-relação entre os atributos. Após a aplicação da seleção de atributos, algoritmos de aprendizado de máquina foram utilizados para classificar e separar as fontes de DP.

4.6 SEPARAÇÃO E CLASSIFICAÇÃO

Nesta tese, diferentes técnicas de aprendizado de máquina foram empregadas como ferramentas para avaliar o sistema de condicionamento de sinais quanto à sua capacidade de preservar informações de sinais de DP suficientemente para separação e classificação de sinais. Portanto, os algoritmos de aprendizagem supervisionada SVM, Random Forest e Regressão Logística e os algoritmos não supervisionados K-means, GMM e Mean shift foram implementados utilizando a linguagem de programação Python no ambiente de desenvolvimento JupyterLab. Os atributos extraídos e selecionados das envoltórias dos sinais de DP foram usados como entradas para esses algoritmos.

Para os modelos supervisionados, o banco de dados foi particionado da seguinte forma: 30% das amostras foram utilizadas para teste e 70% para treinamento. A eficácia

dos modelos foi avaliada por meio da acurácia média, precisão, recall e explicitamente detalhada na matriz de confusão.

O modelo SVM foi implementado utilizando a classe “SVC” da biblioteca Scikit-Learn, com a função kernel *Radial Basis Function* (RBF). A função RBF foi aplicada devido à sua flexibilidade e capacidade de modelagem de dados não lineares.

Para o Random Forest, empregou-se o 'RandomForestClassifier' do módulo ensemble da Scikit-Learn. A fim de determinar o número ideal de árvores, variou-se o parâmetro “n_estimators” de 1 a 19, calculando-se a acurácia para cada configuração. Esse processo permitiu ajustar e avaliar o modelo de forma sistemática, garantindo a seleção de parâmetros que maximizam o desempenho do modelo em dados de teste. O modelo final foi treinado com 5 árvores, com base na análise de desempenho preliminar.

A Regressão Logística, um método de aprendizado supervisionado utilizado para modelar a probabilidade de uma classe de saída em função de uma ou mais variáveis independentes, foi implementada por meio da biblioteca Scikit-Learn. Inicialmente, variou-se o número de iterações máximas, ajustando o modelo para cada valor e calculando a acurácia nos dados de teste. O desempenho do modelo foi visualizado plotando a acurácia em função do número de iterações, o que revelou que a convergência adequada foi atingida com 100 iterações.

Para os modelos não supervisionados o Índice de Rand Ajustado (ARI, do inglês: *Adjusted Rand Index*) foi calculado para avaliar a similaridade entre os rótulos verdadeiros e os rótulos previstos pelos algoritmos K-means, GMM e Mean-Shift. O ARI ajusta a medida de Rand para evitar a similaridade por acaso.

O algoritmo K-Means foi utilizado para realizar o agrupamento dos dados em clusters. O K-Means é um método de aprendizado não supervisionado que particiona o conjunto de dados em k clusters, onde k é um parâmetro definido pelo usuário. O objetivo é minimizar a soma das distâncias quadradas entre os pontos de dados e os centros dos clusters. Assim, para a criação do modelo foram importadas as bibliotecas necessárias, incluindo KMeans do módulo cluster da Scikit-Learn. O parâmetro “n_clusters” foi definido, indicando o número de clusters desejados e o parâmetro “n_init” foi configurado como 10, assegurando múltiplas execuções do algoritmo com diferentes centroides iniciais para garantir a melhor solução. Por fim, o parâmetro “random_state” foi definido como 0 para garantir reprodutibilidade dos resultados. A visualização dos resultados foi realizada por meio de gráficos de dispersão, permitindo observar a distribuição dos pontos de dados entre os clusters e a localização dos centros.

Para o modelo GMM, a biblioteca “GaussianMixture” do módulo “mixture” da Scikit-Learn foi importada. Assim como para o K-means, no GMM o parâmetro “n_components” foi definido com a quantidade de fontes de DP, indicando o número de componentes gaussianas (*clusters*) desejadas. O parâmetro “random_state” também foi definido como 0 para garantir a reprodutibilidade dos resultados.

Por fim, para implementar o modelo Mean shift, foi importada a biblioteca “MeanShift” do módulo cluster da Scikit-Learn. O Mean Shift requer um parâmetro de largura de banda. Assim, para determinar a largura de banda ideal, foi criada uma função para testar diferentes valores de largura de banda.

Os resultados fornecidos pelos algoritmos não supervisionados foram visualizados utilizando gráficos de dispersão interativo, onde cada ponto foi colorido de acordo com o cluster ao qual pertence.

A metodologia delineada neste capítulo abrangeu uma série de etapas fundamentais para o desenvolvimento desta tese. No capítulo seguinte, os resultados obtidos serão discutidos e analisados, visando avaliar a possibilidade efetiva de reduzir os requisitos de amostragem do sistema de aquisição. Além disso, será examinado o potencial dos atributos extraídos e selecionados das envoltórias dos sinais de DP em promover a separação e classificação eficaz das DP.

5 RESULTADOS E ANÁLISES

Neste capítulo são apresentados os resultados obtidos utilizando a metodologia descrita no capítulo anterior. Para tanto, na seção 5.1, os resultados obtidos na etapa de geração de envoltórias utilizando o algoritmo de estimação de densidade por Kernel são apresentados e discutidos. Na seção 5.2 é realizada uma análise sobre os sinais detectados utilizando o sistema de condicionamento de sinais desenvolvido. Na seção 5.3 são apresentados e analisados os resultados sobre a extração e seleção de atributos das envoltórias dos sinais de DP. Por fim, na seção 5.4 são apresentados e discutidos os resultados obtidos no processo de separação e classificação de fontes de DP detectadas em laboratório e em campo, utilizando os atributos extraídos e selecionados das envoltórias dos sinais.

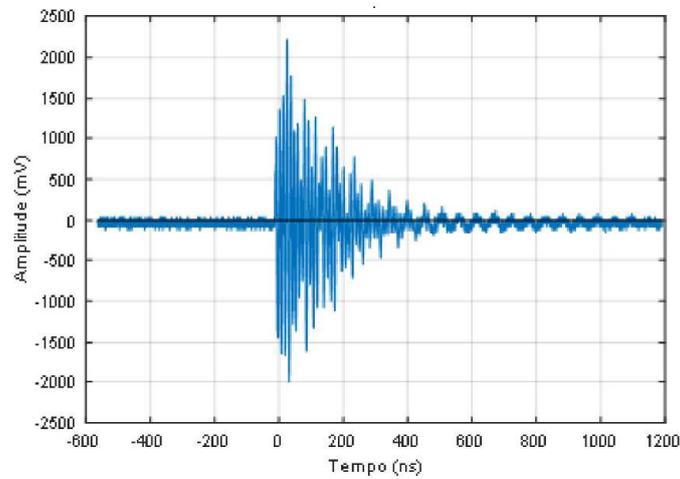
5.1 ALGORITMO DE GERAÇÃO DE ENVOLTÓRIAS

Nesta seção, são apresentados e analisados os resultados obtidos dos processos de geração de envoltória de sinais radiométricos de DP baseado no método de estimação de densidade por Kernel. Além disso, discutem-se os resultados dos procedimentos utilizados para avaliar a capacidade de separação dos sinais com base nos atributos extraídos das envoltórias.

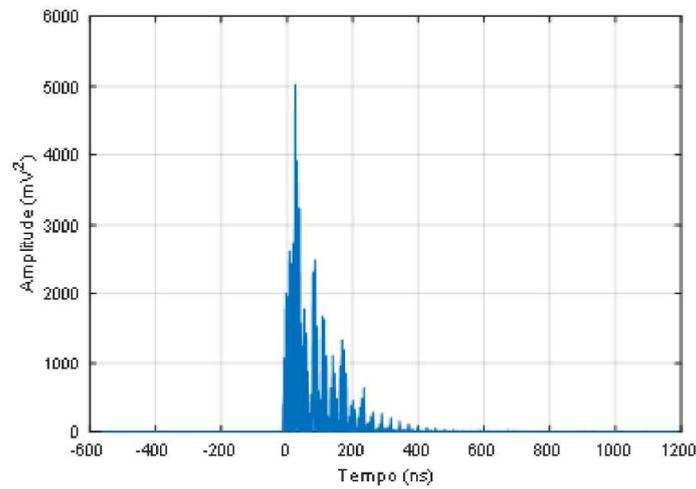
Por meio do banco de dados gerado a partir dos testes iniciais realizados em laboratório, conforme descrito na seção 4.1, um grupo de 48 envoltórias provenientes da atividade de DP nos três objetos de teste foram geradas de acordo com as etapas indicadas no fluxograma apresentado na Figura 4.10 da seção 4.2. Nas Figuras 5.1 – 5.3, é possível verificar os resultados da aplicação do algoritmo de suavização de densidade por Kernel em sinais de DP provenientes das três fontes de DP utilizadas nas medições: barra de hidrogerador, corpo de prova de fenolite com cavidades e transformador de potencial.

As duas primeiras etapas do algoritmo de geração de envoltória consistem remoção do nível CC dos sinais e em seguida na elevação ao quadrado dos pontos de dados de tensão dos sinais amostrados. Os resultados dessas etapas podem ser visualizados nas Figuras 5.1 (b), 5.2 (b) e 5.3 (b).

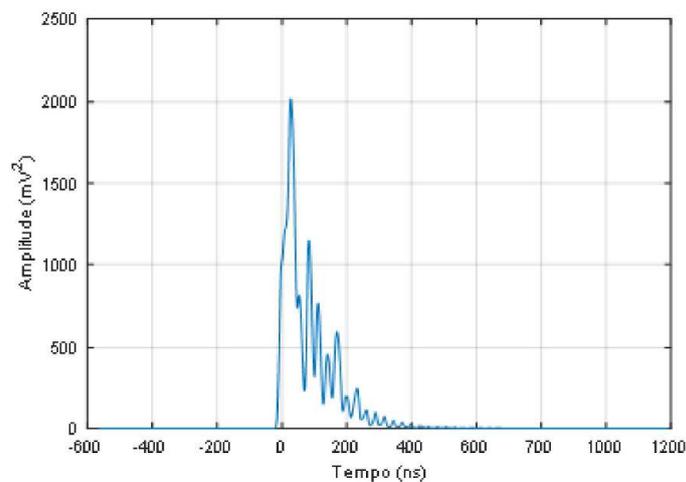
Figura 5.1 – Resultado da aplicação do algoritmo de densidade por Kernel: (a) Sinal radiométrico de DP emitido pela barra de hidrogerador; (b) Sinal radiométrico de DP após a remoção do nível CC e elevação ao quadrado; (c) Envoltória do sinal DP.



(a)



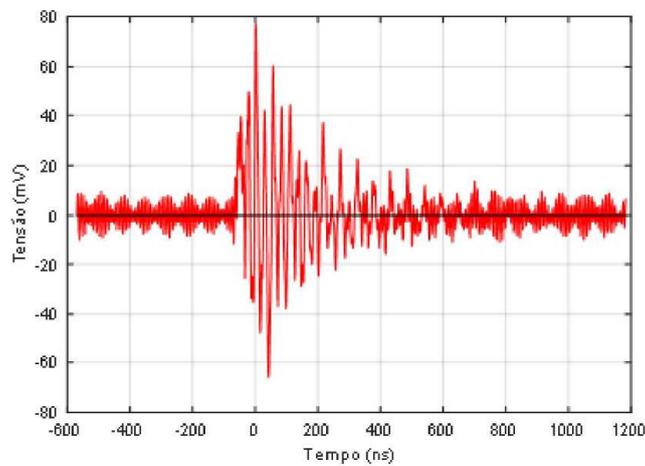
(b)



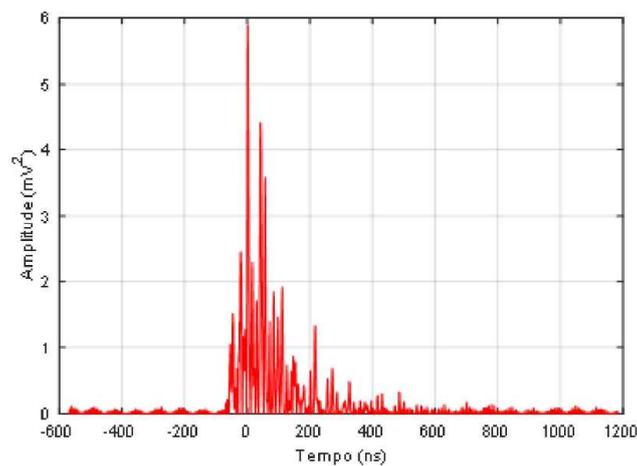
(c)

Autoria própria.

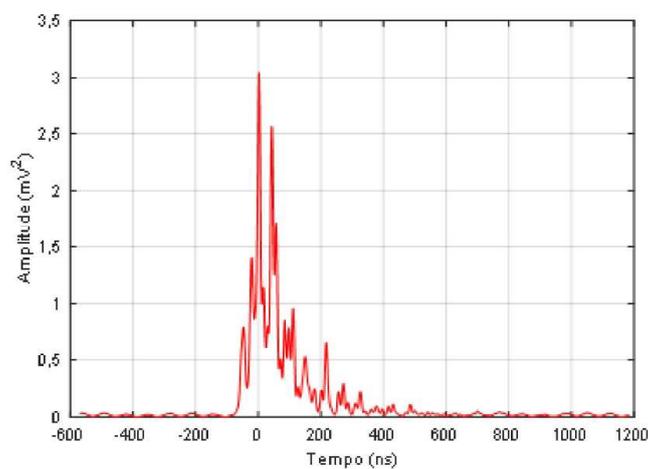
Figura 5.2 - Resultado da aplicação do algoritmo de densidade por Kernel: (a) Sinal radiométrico de DP emitido pelo corpo de prova; (b) Sinal radiométrico de DP após a remoção do nível CC e elevação ao quadrado; (c) Envoltória do sinal DP.



(a)



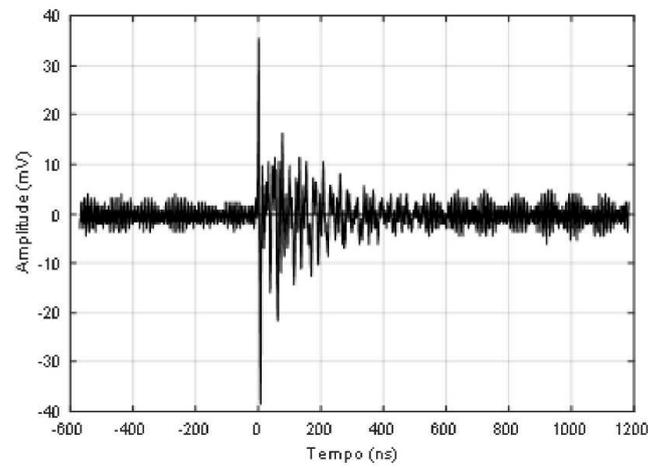
(b)



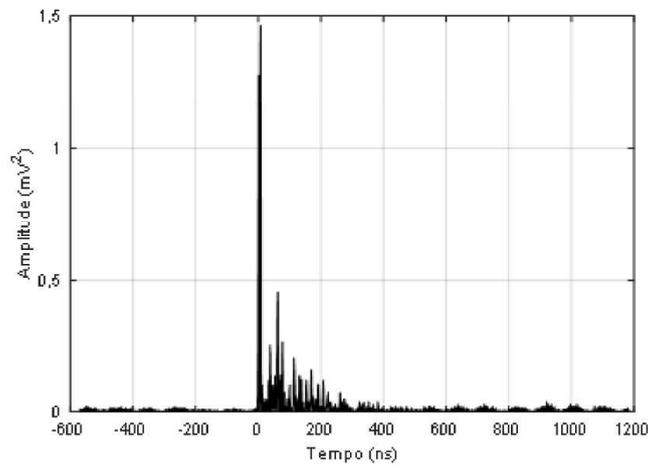
(c)

Fonte: Autoria própria.

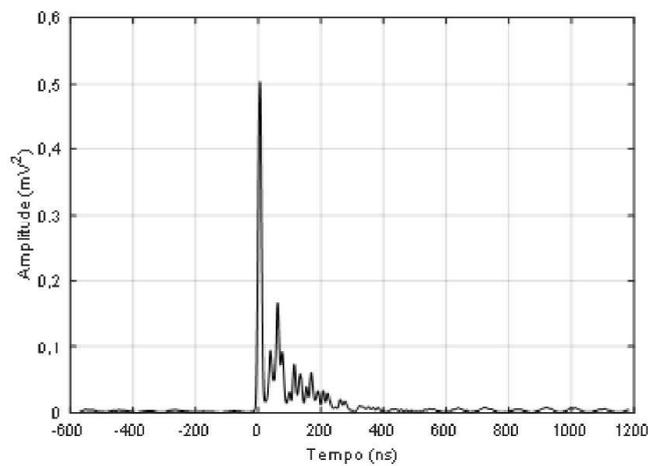
Figura 5.3 – Resultado da aplicação do algoritmo de densidade por Kernel: (a) Sinal radiométrico de DP emitido pelo TP; (b) Sinal radiométrico de DP após a remoção do nível CC e elevação ao quadrado; (c) Envoltória do sinal DP.



(a)



(b)



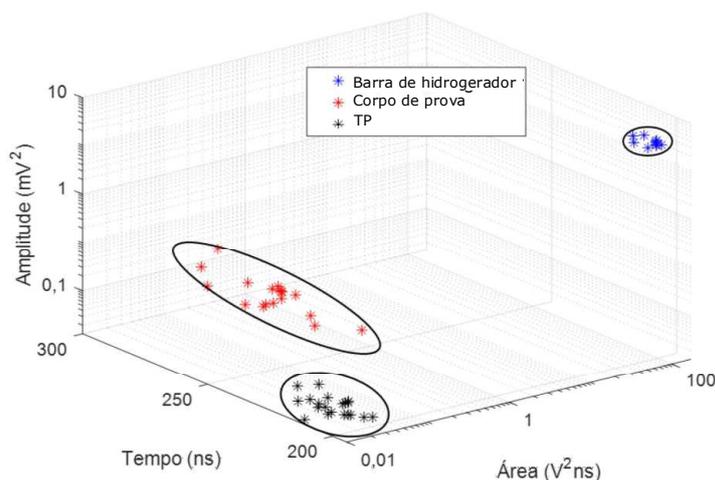
(c)

Autoria própria,

O terceiro passo do algoritmo consiste em implementar o estimador por Kernel. O resultado desta etapa pode ser visualizado nas Figuras 5.1 (c), 5.2 (c) e 5.3 (c).

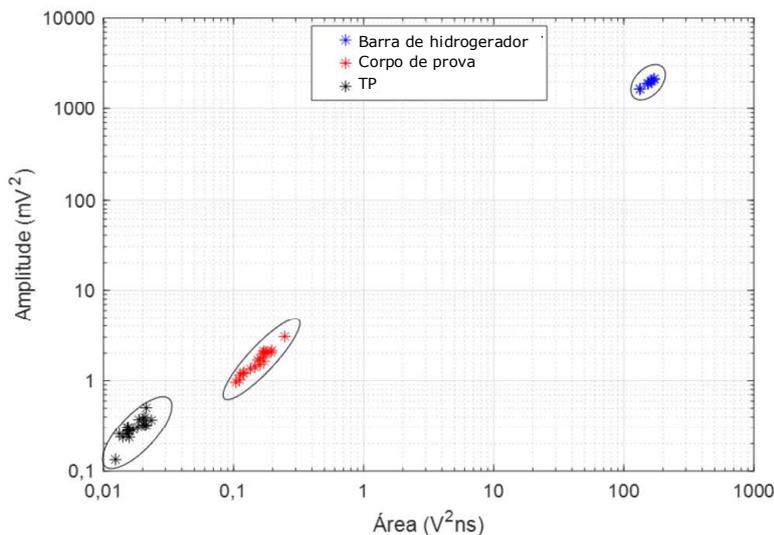
Uma maneira de avaliar a separação dos diferentes sinais de DP capturados e, dessa forma, prever a possibilidade de separação e classificação, é a partir da utilização de atributos característicos extraídos das envoltórias dos sinais. Nesta etapa do trabalho, foram calculados, para cada uma das 48 envoltórias geradas, os seguintes atributos: energia (área sob a curva), amplitude, tempo de duração da envoltória, tempo de subida e tempo de descida. Os gráficos tridimensionais (3D) e bidimensionais (2D) mostrados nas Figuras 5.4 – 5.7 permitem visualizar claramente os clusters formados.

Figura 5.4 – Gráfico 3D para os atributos amplitude, energia (área sob a curva), tempo de duração do sinal.



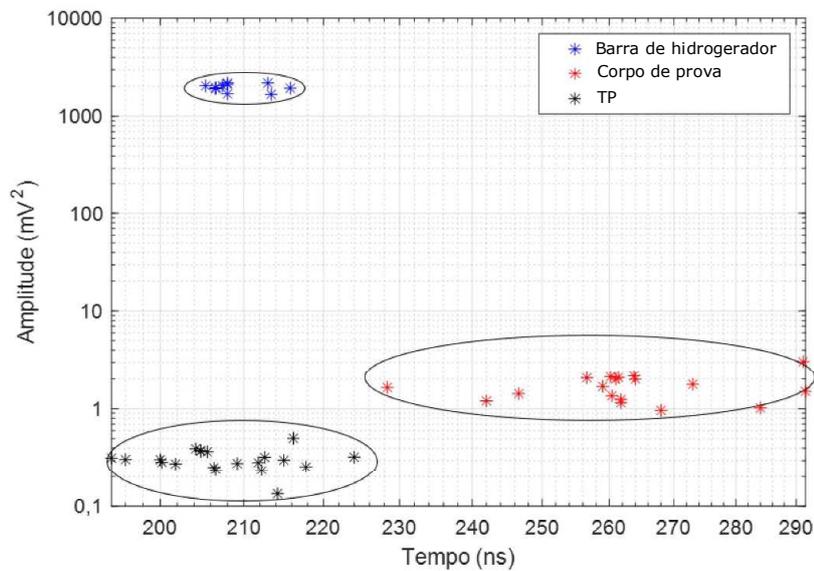
Fonte: Autoria própria.

Figura 5.5 – Gráfico 2D para os atributos amplitude e energia (área sob a curva).



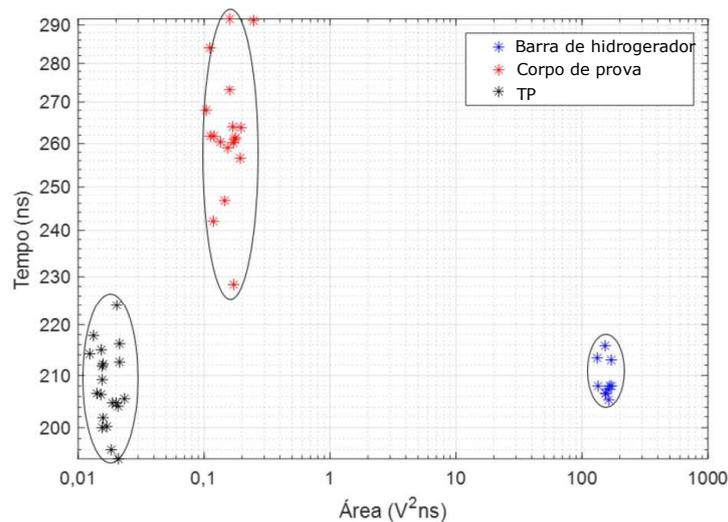
Fonte: Autoria própria.

Figura 5.6 – Gráfico 2D para os atributos amplitude e tempo de duração do sinal.



Fonte: Autoria própria.

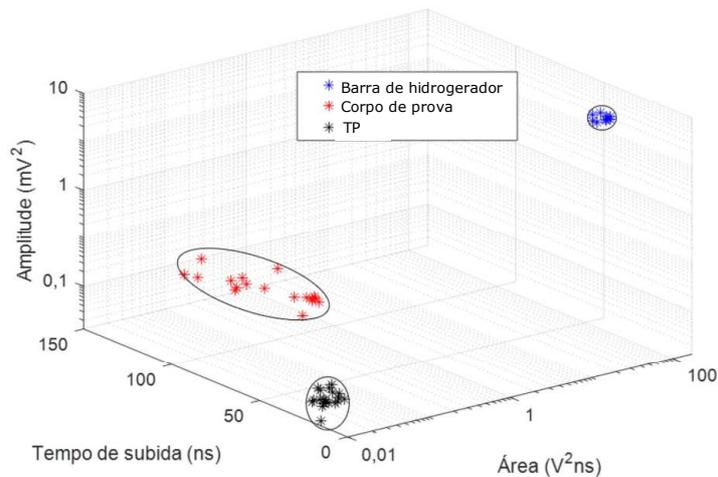
Figura 5.7 – Gráfico 2D para os atributos tempo e energia.



Fonte: Autoria própria.

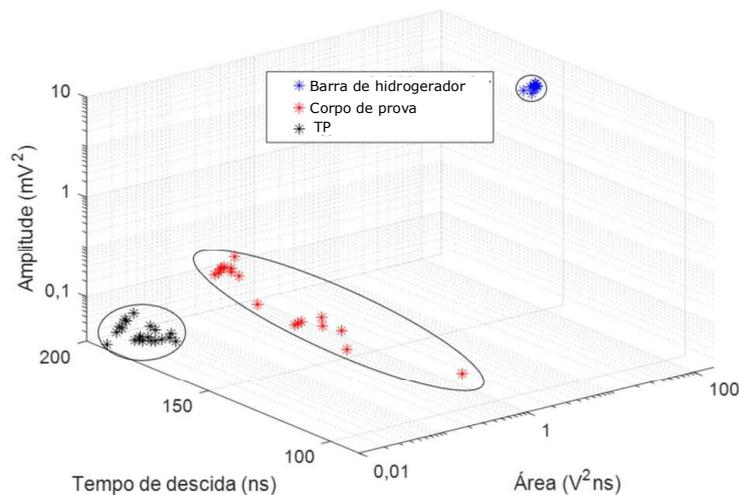
Por meio dos gráficos das Figuras 5.4 – 5.7, verificou-se que todos os atributos utilizados são capazes de definir três regiões distintas, indicando assim as três fontes de descargas parciais submetidas a ensaios. Adicionalmente, foi realizada uma análise considerando os atributos tempo de subida e tempo descida. Assim, o atributo tempo de duração da envoltória foi substituído pelo tempo de subida e, posteriormente pelo tempo de descida da envoltória obtendo os gráficos 3D que podem ser visualizados nas Figuras 5.8 e 5.9.

Figura 5.8 – Gráfico 3D para os atributos amplitude, tempo de subida e energia (área sob a curva).



Fonte: Autoria própria.

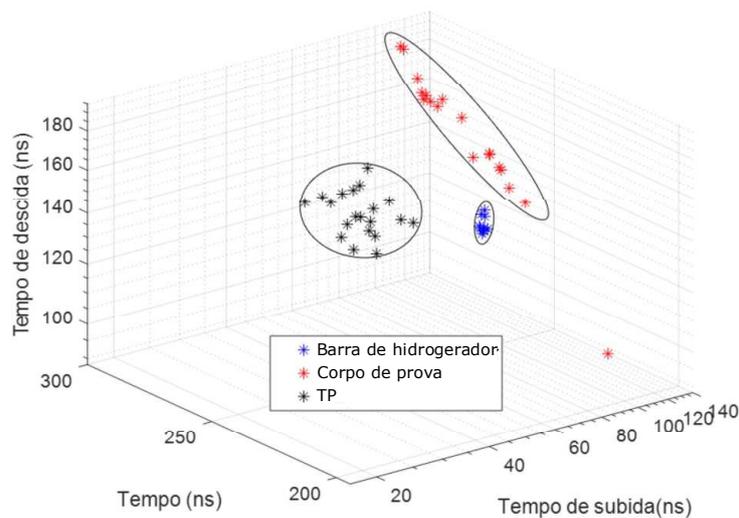
Figura 5.9 – Gráfico 3D para os atributos amplitude, tempo de descida e energia (área sob a curva).



Fonte: Autoria própria.

No monitoramento de DP em campo, sabe-se que é possível que existam situações em que sinais de DP gerados em diferentes equipamentos elétricos apresentem valores de amplitude aproximados. Portanto, foi esboçado um gráfico 3D considerando apenas as características temporais do sinal, como mostrado na Figura 5.10.

Figura 5.10 – Gráfico 3D para os atributos tempo de descida, tempo de duração do sinal e tempo de subida.



Fonte: Autoria própria.

Ao analisar todos os gráficos produzidos, nota-se que embora o banco de dados possa ser considerado pequeno, todos os cinco atributos extraídos das envoltórias dos sinais de DP foram capazes de promover uma separação satisfatória entre as fontes de DP. No entanto, ao modificar os atributos, notou-se uma mudança sutil na concentração e separação dos clusters, sugerindo a necessidade de uma etapa de investigação para otimização da extração e seleção de atributos. A geração de envoltórias por software utilizando o KDE foi uma etapa crucial no desenvolvimento desta tese, confirmando que, embora as envoltórias perdessem informações dos sinais originais, ainda mantinham atributos capazes de fornecer uma separação eficaz.

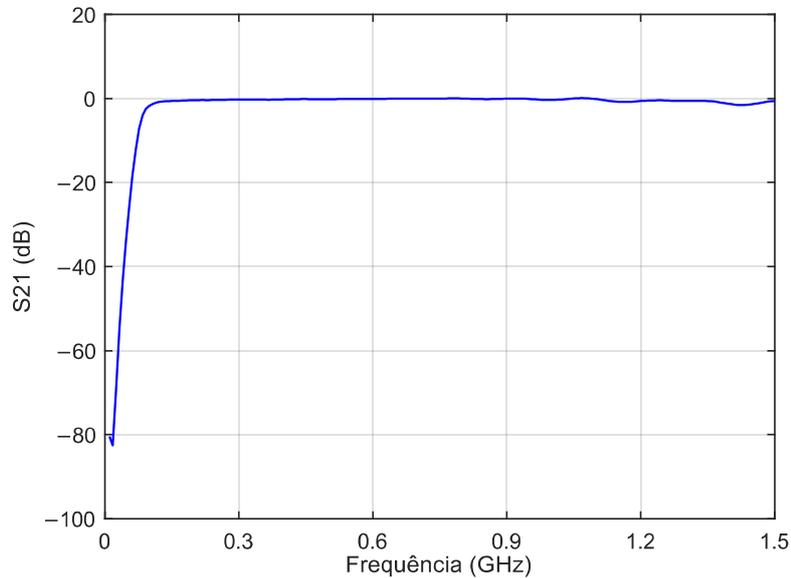
5.2 SISTEMA DE CONDICIONAMENTO DE SINAIS

A partir dos resultados satisfatórios obtidos na seção 5.1, a etapa seguinte da pesquisa consistiu em introduzir o sistema de condicionamento de sinais para detecção de envoltória dos sinais radiométricos nos arranjos de medição.

Inicialmente, os componentes que compõem o sistema de condicionamento de sinais foram analisados utilizando o analisador de rede ENA RF E5062A. As Figuras 5.11 a 5.13 mostram os gráficos que representam a magnitude do coeficiente S_{21} para o filtro

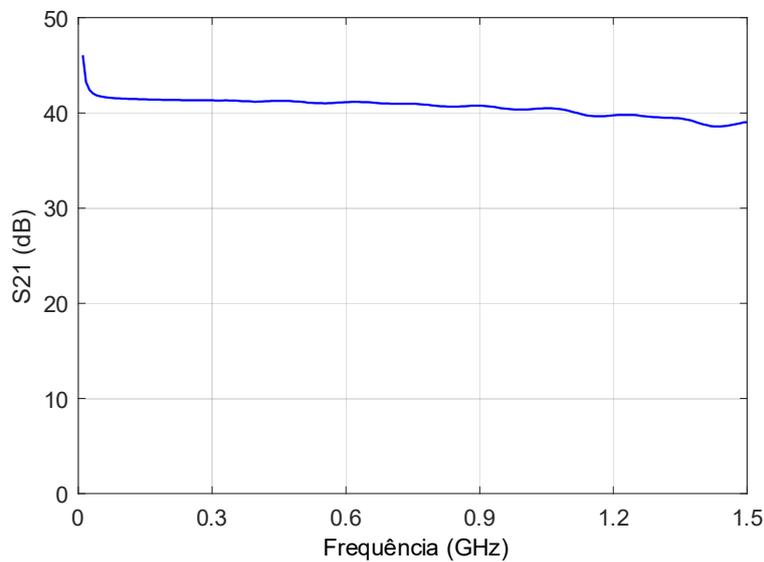
e amplificador de RF, e a magnitude do coeficiente S_{11} para o detector de envoltória, respectivamente.

Figura 5. 11 – Magnitude do coeficiente de transmissão S_{21} do filtro RF.



Fonte: Autoria própria.

Figura 5. 12 – Magnitude do coeficiente de transmissão S_{21} do amplificador RF.

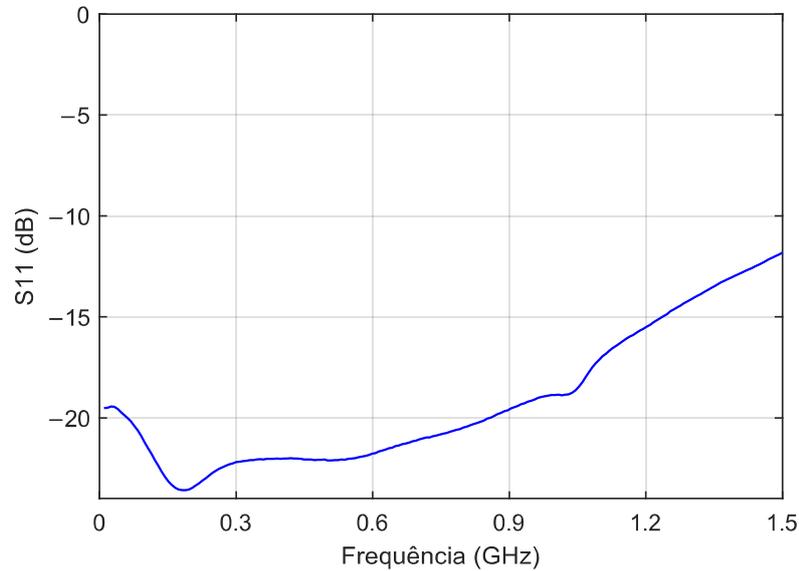


Fonte: Autoria própria.

O coeficiente de transmissão S_{21} indica como a linha de transmissão transmite o sinal e está relacionado à perda por inserção. A análise realizada indica que o filtro apresenta baixa perda por inserção, inferior a 0,43 dB, na faixa de frequência de 300 MHz

a 1.500 MHz. O amplificador de RF apresenta ganho superior a 40 dB até a frequência de 1,1 GHz, com ganho mínimo de 38,5 dB entre 1,1 GHz e 1,5 GHz.

Figura 5. 13 - Magnitude do coeficiente de reflexão S_{11} do circuito detector de envoltória.

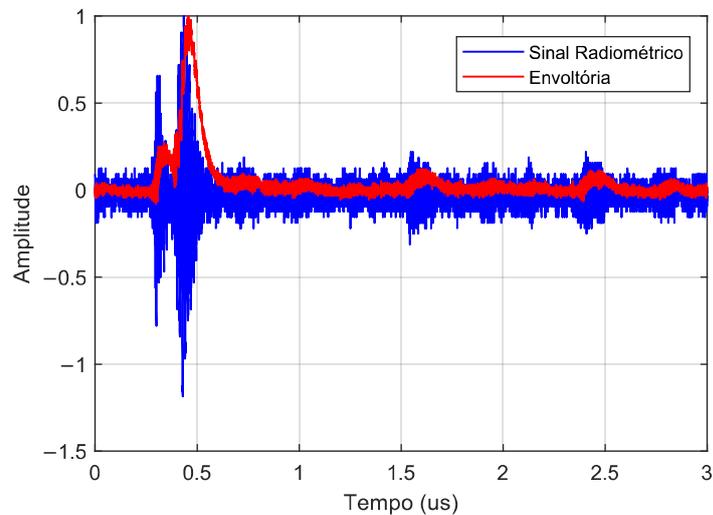


Fonte: Autoria própria.

O coeficiente S_{11} representa a relação entre a potência refletida do detector de envelope e a potência entregue à linha de transmissão. O detector de envelope apresentou coeficientes de reflexão abaixo de -10 dB entre 0,3 GHz e 1,5 GHz, mostrando-se adequado para detecção de DP.

Com o sistema de condicionamento de sinal devidamente caracterizado, foram realizadas medições de DP com o sistema desenvolvido. Na Figura 5.14 pode-se observar um dos sinais radiométricos de DP do TP e sua respectiva envoltória detectada pelo sistema de condicionamento de sinais. Nota-se que o sinal medido na saída do sistema de condicionamento de sinais segue o envelope do sinal original, demonstrando a eficácia do sistema de condicionamento de sinal proposto.

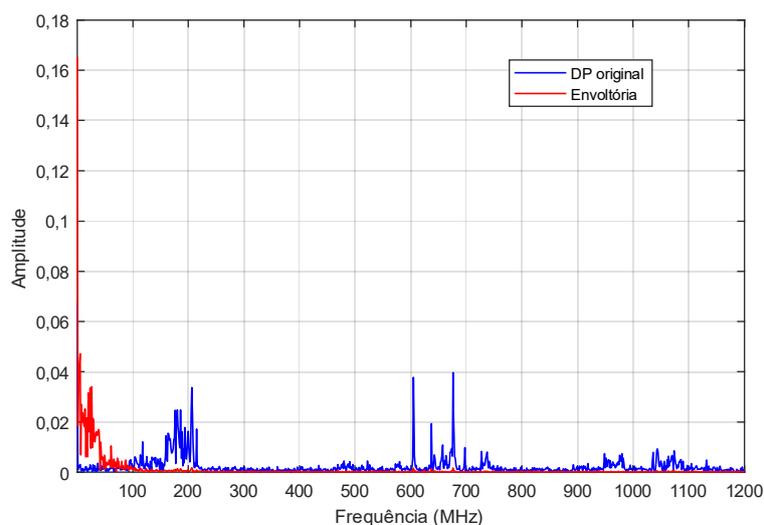
Figura 5.14 -Sinal radiométrico de DP capturado do TP e sua respectiva envoltória detectados durante o ensaio.



Fonte: Autoria própria.

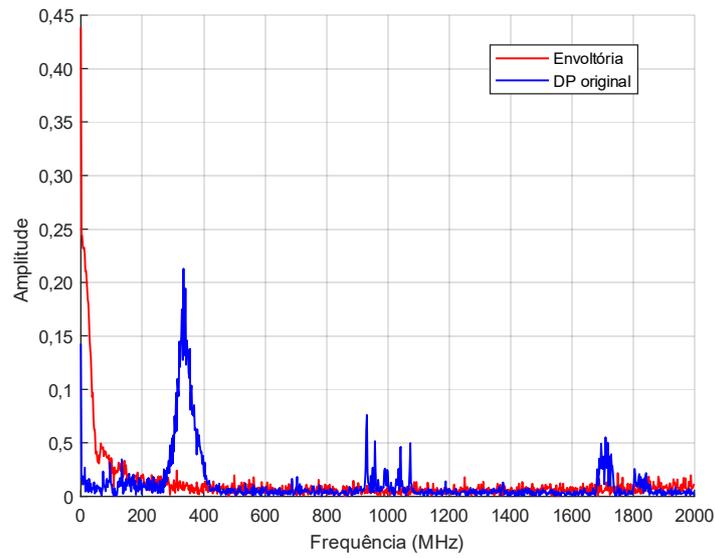
Com o objetivo de avaliar o nível de frequência dos sinais antes e após a detecção de envoltória, foi aplicada a Transformada Rápida de Fourier (FFT – do inglês: *fast Fourier transform*) nos sinais radiométrico de DP capturados pela antena sem o detector de envoltória e, em seguida, nos sinais suavizados. O resultado da decomposição dos sinais radiométricos de DP e de suas envoltórias, detectados em laboratório e em subestação, podem ser verificados nas Figuras 5.15 – 5.18.

Figura 5.15 – FFT do sinal radiométrico de DP capturado do TP e de sua envoltória.



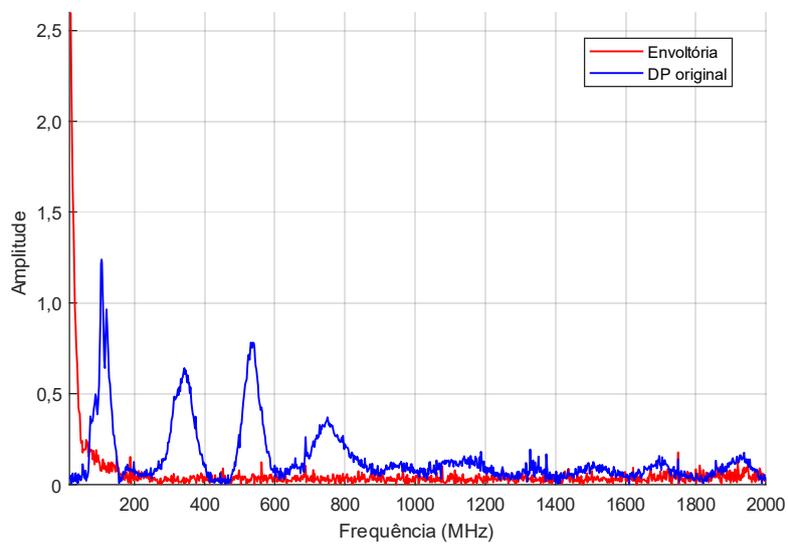
Fonte: Autoria própria.

Figura 5. 16 – FFT do sinal radiométrico de DP capturado do corpo de prova de fenolite com cavidades e de sua envoltória.



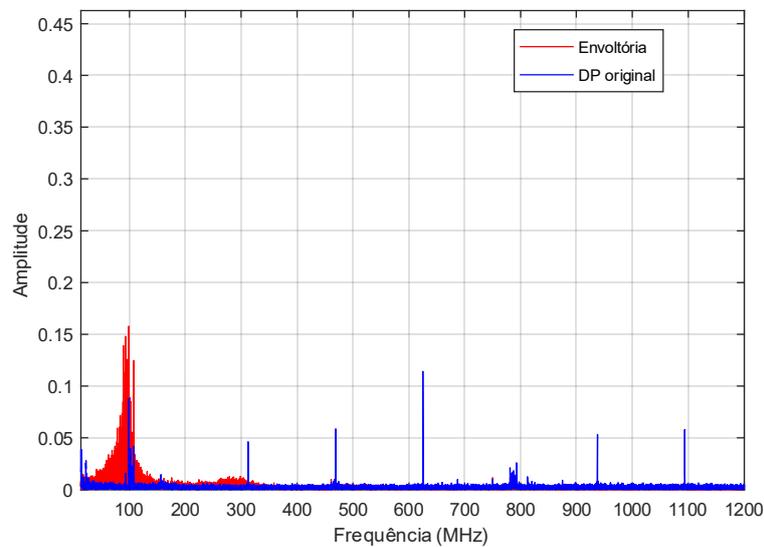
Fonte: Autoria própria.

Figura 5. 17 - FFT do sinal radiométrico de DP capturado da barra de hidrogerador e de sua envoltória.



Fonte: Autoria própria.

Figura 5. 18 - FFT do sinal radiométrico de DP capturado na subestação e sua respectiva envoltória.



Fonte: A autoria própria.

A partir dos resultados, pode-se constatar que as altas componentes do sinal estavam concentradas até a faixa de aproximadamente 1 GHz . Por outro lado, após a detecção de envoltória, as altas componentes do sinal estão localizadas até aproximadamente 100 MHz , indicando uma redução de cerca de 900 MHz no nível de frequência e nos requisitos de taxa de amostragem do equipamento de aquisição.

Como parte da análise de frequência, foi evidenciada uma redução substancial do nível de ruído devido à utilização do sistema de condicionamento de sinais. A redução do ruído aumenta a sensibilidade na detecção de sinais de DP e permite identificar padrões específicos, garantindo assim uma detecção com maior confiabilidade. Com níveis de ruído mais baixos, uma relação sinal-ruído mais alta pode ser alcançada, melhorando a capacidade de diferenciar e isolar os sinais de interesse.

5.3 EXTRAÇÃO E SELEÇÃO DE ATRIBUTOS

A extração de atributos dos sinais detectados em laboratório gerou um conjunto de dados com 14 colunas e 2.400 linhas, resultando em 14 atributos para cada conjunto de 800 amostras de uma fonte específica de DP. Dessa forma, inicialmente o processo de seleção e extração de atributos foi realizado considerando o banco de dados.

O método RFE foi aplicado até que cinco atributos fossem definidos. Foram selecionados os seguintes atributos: amplitude média, amplitude de raiz quadrada, duração do sinal, tempo de subida e tempo de descida. A partir da aplicação do algoritmo de informação mútua, foram selecionados os seguintes atributos: amplitude média, energia, duração do sinal, tempo de subida e tempo de descida.

Os seis atributos definidos pela união de características selecionadas por RFE e informações mútuas foram analisados quanto à sua correlação. A Tabela 5.1 apresenta a matriz dos coeficientes de correlação.

Tabela 5.1 – Matriz de coeficientes de correlação.

	A_a	A_{r2}	E_s	T_t	T_s	T_d
A_a	1	0.64	-0.05	0.03	0.31	0.01
A_{r2}	0.64	1	0.02	-0.01	0.14	-0.01
E_s	-0.05	0.02	1	-0.34	-0.70	-0.32
T_t	0.03	0.01	-0.34	1	0.20	1.0
T_s	0.31	0.14	-0.70	0.20	1	0.16
T_d	0.01	-0.01	-0.31	0.99	0.16	1

Fonte: Autoria própria.

Após analisar a correlação entre os atributos selecionados pelo RFE e pelo algoritmo de informação mútua, constatou-se que os seguintes atributos apresentaram a menor correlação entre elas: amplitude de raiz quadrada, energia e duração do sinal.

O mesmo procedimento de extração e seleção de atributos foi realizado com os dados medidos em campo, na subestação de 230 kV. O banco de dados gerado em campo foi composto por 501 envoltórias, das quais 199 foram detectadas do compensador síncrono, 115 do transformador de corrente e 187 do para-raios. Seguindo a mesma metodologia de extração e seleção, dos 14 atributos extraídos das envoltórias, o RFE selecionou: assimetria, curtose, fator de forma, duração e tempo de descida. A informação mútua selecionou: amplitude média, valor de pico, valor RMS, duração e tempo de subida. Aplicando a análise de correlação ao conjunto de atributos selecionados, os seguintes atributos foram definidos: duração do sinal, assimetria e tempo de subida.

Na próxima seção, os atributos selecionados serão avaliados usando os modelos de aprendizado de máquina implementados.

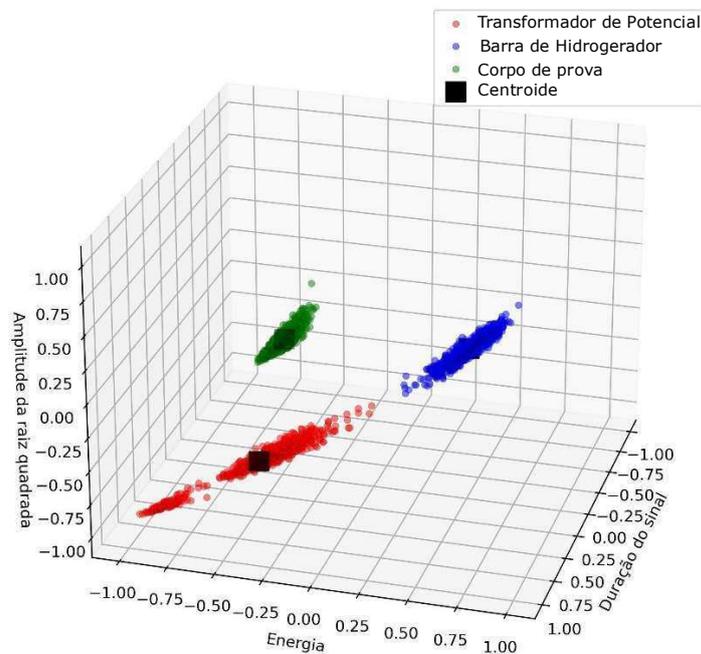
5.4 SEPARAÇÃO E CLASSIFICAÇÃO DAS ENVOLTÓRIAS

A separação e classificação das envoltórias foi realizada considerando dois cenários: as medições realizadas em laboratório e as medições realizadas em campo. Na seção 5.4.1 são apresentados e discutidos os resultados dos modelos de agrupamento e classificação realizados com o banco de dados criado a partir das medições das envoltórias dos sinais detectados em laboratório. Na seção 5.4.2 serão discutidos os resultados obtidos a partir do banco de dados adquirido nas medições em subestação.

5.4.1 DADOS DETECTADOS EM LABORATÓRIO

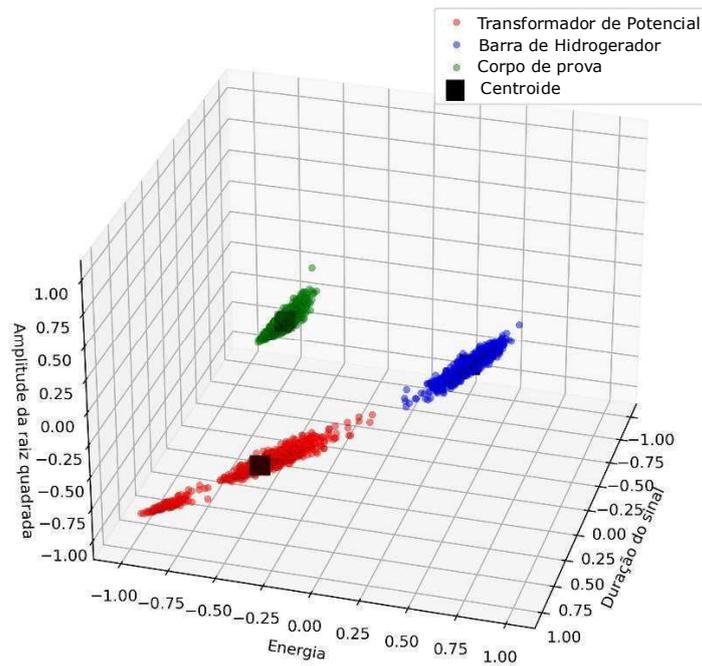
Nesta tese, os algoritmos de agrupamento K-means, GMM e Mean Shift foram usados para separar os diferentes objetos de teste a partir dos atributos seleccionados previamente. As Figuras 5.19 – 5.21 mostram os gráficos de dispersão tridimensionais dos algoritmos K-means, GMM e Mean Shift, ilustrando a eficácia de cada método na identificação e separação dos clusters de dados.

Figura 5.19 - Gráfico de dispersão tridimensional do algoritmo K-means com os dados medidos em laboratório.



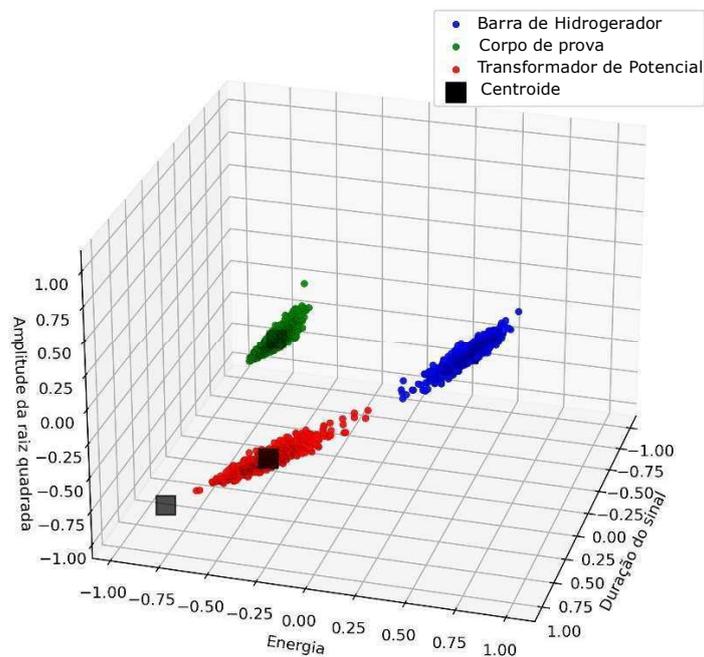
Fonte: Autoria própria.

Figura 5.20 - Gráfico de dispersão tridimensional do algoritmo GMM com os dados medidos em laboratório.



Fonte: Autoria própria.

Figura 5.21 - Gráfico de dispersão tridimensional do algoritmo Mean Shift com os dados medidos em laboratório.



Fonte: Autoria própria.

O algoritmo K-means demonstrou uma clara separação entre os clusters, evidenciada pela distinção de cores. Os centróides estão corretamente posicionados no

centro dos clusters, indicando um bom desempenho na identificação dos grupos principais. No entanto, K-means pode ser sensível à inicialização dos centróides e requer a especificação prévia do número de clusters, o que pode não ser ideal em todas as situações.

O GMM conseguiu agrupar os dados de forma similar ao K-means, mas com uma abordagem probabilística que permite modelar a incerteza dentro dos clusters. Este método pode ser mais flexível ao lidar com *clusters* de formas variadas e tamanhos diferentes, embora também exija a especificação do número de componentes. Na Figura 5.20, é evidenciada uma correspondência satisfatória com os *clusters* esperados, destacando a eficácia do GMM na identificação de agrupamentos em dados complexos.

O algoritmo Mean Shift identificou os *clusters* corretamente, mas também detectou um centroide adicional isolado, sem pontos de dados ao seu redor. Este fato pode ocorrer devido à suavização excessiva da densidade dos dados ou à presença de *outliers*. Apesar disso, o Mean Shift não requer a especificação prévia do número de clusters, o que é vantajoso em cenários onde o número de grupos não é conhecido, podendo a análise de um operador identificar a inconsistência de grupos criados devido à presença de *outliers*.

De maneira geral, os três algoritmos tiveram claramente um bom desempenho na separação das fontes de DP, utilizando atributos selecionados das envoltórias dos sinais. O Índice Rand ajustado (ARI - Adjusted Rand Index) foi igual a 1 para os três algoritmos, indicando uma perfeita concordância entre os agrupamentos gerados e os rótulos verdadeiros dos dados. Em outras palavras, os *clusters* identificados pelo algoritmo coincidiram exatamente com os clusters reais presentes nos dados. A perfeita correspondência entre os clusters e os rótulos verdadeiros sugere que os dados possuem características bem definidas e distinguíveis, facilitando a tarefa de clusterização. Isso demonstra que o sistema de condicionamento de sinais desenvolvido é capaz de promover a separação de diferentes fontes de DP utilizando para isso os atributos extraídos e selecionados das envoltórias.

Para validar se os atributos selecionados poderiam caracterizar as diferentes fontes de DP, foi aplicado os algoritmos SVM, Random Forest e Regressão Logística. A eficácia dos métodos foi avaliada por meio da acurácia média, precisão, recall e detalhada na matriz de confusão, conforme mostrado nas Tabelas 5.2 a 5.4.

Tabela 5.2 - Matriz de confusão, precisão, recall e acurácia média para o modelo SVM dos dados detectados em laboratório.

		Valores Previstos			Recall
		Barra de Hidrogerador	TP	Corpo de prova	
Valores Reais	Barra de Hidrogerador	240	0	0	1
	TP	0	192	48	0,80
	Corpo de prova	0	7	233	0,97
	Precisão	1	0,96	0,830	
		Acurácia = 0,92			

Fonte: Autoria própria.

A partir da matriz de confusão, pode-se inferir que o modelo SVM alcançou uma acurácia média de 0,92, indicando um bom desempenho do modelo. A acurácia representa o desempenho geral do modelo, indicando a proporção de previsões corretas feitas pelo modelo em comparação ao número total de previsões feitas.

Os valores de recall e precisão também são fornecidos para cada classe. A precisão da Barra hidrogerador é 1, indicando que não há falsos positivos nas previsões feitas pelo modelo. A precisão para o TP foi de 0,96, indicando que 96% das instâncias identificadas como TP pelo modelo estavam corretas, enquanto para o corpo de prova a precisão foi de 0,83, indicando 83% de precisão na identificação de instâncias como corpo de prova de fenolite com cavidades. A métrica de avaliação Recall mede a proporção de instâncias verdadeiras positivas identificadas corretamente pelo modelo entre todas as instâncias positivas reais. Para a Barra de hidrogerador, todas as instâncias positivas foram identificadas corretamente, resultando em um recall de 1. Para o TP, o modelo identificou 80% de instâncias positivas verdadeiras, resultando em um recall de 0,80. Da mesma forma, para o corpo de prova de fenolite com cavidades, o modelo alcançou uma recuperação de 0,97, identificando corretamente 97% dos casos positivos.

Na Tabela 5.3 são apresentadas a matriz de confusão e as métricas de avaliação: acurácia, precisão e recall para o modelo Random Forest.

Tabela 5.3 - Matriz de confusão, precisão, recall e acurácia média para o modelo Random Forest dos dados detectados em laboratório.

		Valores Previstos			Recall
		Barra de Hidrogerador	TP	Corpo de prova	
Valores Reais	Barra de Hidrogerador	240	0	0	1
	TP	0	240	0	1
	Corpo de prova	0	0	240	1
	Precisão	1	1	1	
		Acurácia = 1.0			

Fonte: A autoria própria.

Os resultados apresentados na Tabela 5.3 indicam que o modelo Random Forest é altamente eficiente e preciso na classificação dos dados nas classes Barra de Hidrogerador, TP e Corpo de prova de fenolite com cavidades. A combinação de acurácia, precisão e recall perfeitos para todas as classes, demonstra que o modelo é robusto e confiável para a tarefa de classificar as fontes de DP a partir dos atributos extraídos e selecionados das envoltórias.

Por fim, na Tabela 5.4 podem ser observados os resultados obtidos para o modelo de Regressão Logística.

Tabela 5.4 - Matriz de confusão, precisão, recall e acurácia média para o modelo de Regressão Logística dos dados detectados em laboratório.

		Valores Previstos			Recall
		Barra de Hidrogerador	TP	Corpo de prova	
Valores Reais	Barra de Hidrogerador	240	0	0	1
	TP	0	200	40	0,83
	Corpo de prova	0	15	225	0,94
	Precisão	1	0,93	0,85	
		Acurácia = 0,92			

Fonte: A autoria própria.

A análise da Tabela 5.4 revela que o modelo de Regressão Logística apresentou um desempenho adequado na classificação dos dados, com uma acurácia média de 92%. A precisão foi perfeita para a classe Barra de Hidrogerador (1.0), indicando que todas as instâncias previstas como pertencentes a esta classe estavam corretas. Para a classe TP, a precisão foi de 0.93, enquanto para Corpo de prova foi de 0.85, demonstrando uma boa, mas não perfeita, capacidade de identificar corretamente as instâncias destas classes. O recall de 1.0 para Barra de Hidrogerador indica que todas as instâncias reais desta classe

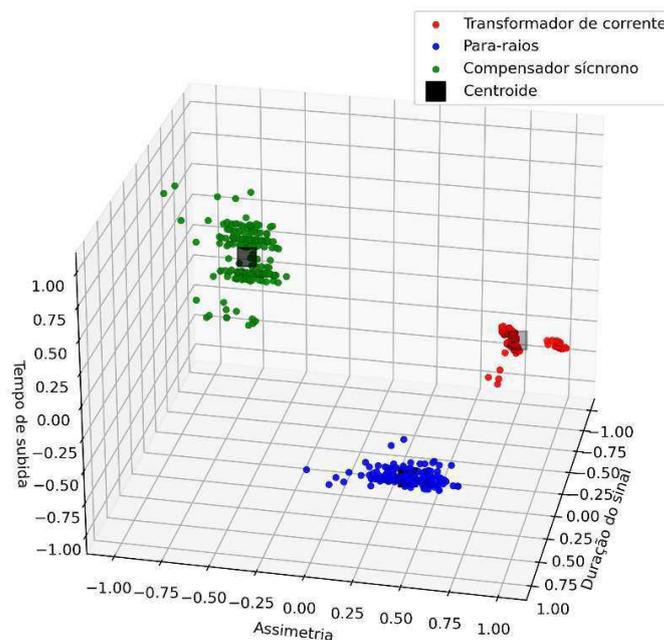
foram corretamente identificadas. No entanto, a classe TP teve um recall de 0.83, e Corpo de prova teve um recall de 0.94, o que sugere a presença de alguns falsos negativos, especialmente na classe TP. Esses resultados evidenciam, que, apesar de algumas limitações, a Regressão Logística foi uma ferramenta eficaz para a classificação das fontes de DP.

Os resultados indicam que os atributos extraídos e selecionados das envoltórias dos sinais são altamente eficazes na separação das diferentes fontes de DP detectadas em laboratório. O Random Forest se destacou como o método mais eficiente na classificação dos dados, com acurácia, precisão e recall perfeitos, superando os outros métodos avaliados. Na seção seguinte, o sistema de condicionamento de sinal será avaliado quanto à separação e classificação de sinais detectados em campo.

5.4.2 DADOS DETECTADOS EM CAMPO

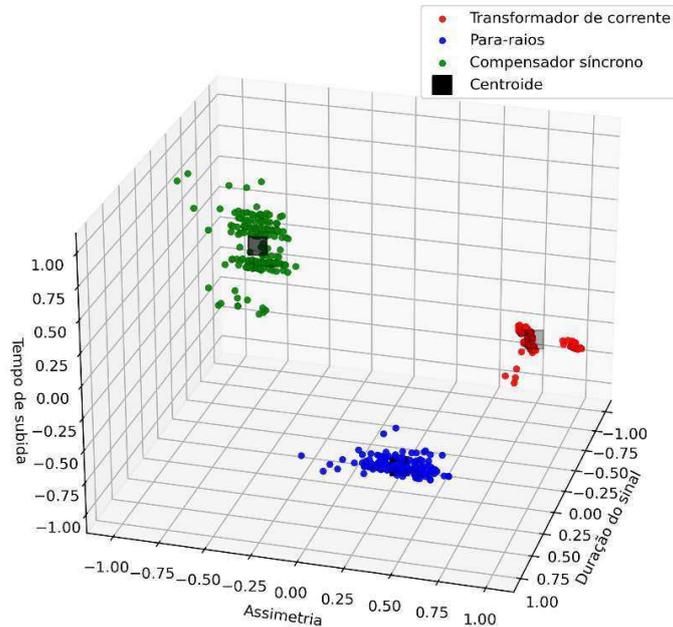
A fim de avaliar o desempenho do sistema de condicionamento de sinal em condições de subestação, os algoritmos de aprendizado de máquina utilizados para separação e classificação das envoltórias detectados em laboratório foram também aplicados para os sinais detectados em campo. Nas Figuras 5.22 a 5.24 são exibidos os gráficos de dispersão tridimensionais dos algoritmos K-means, GMM e Mean Shift.

Figura 5.22 - Gráfico de dispersão tridimensional do algoritmo K-means com os dados medidos em laboratório.



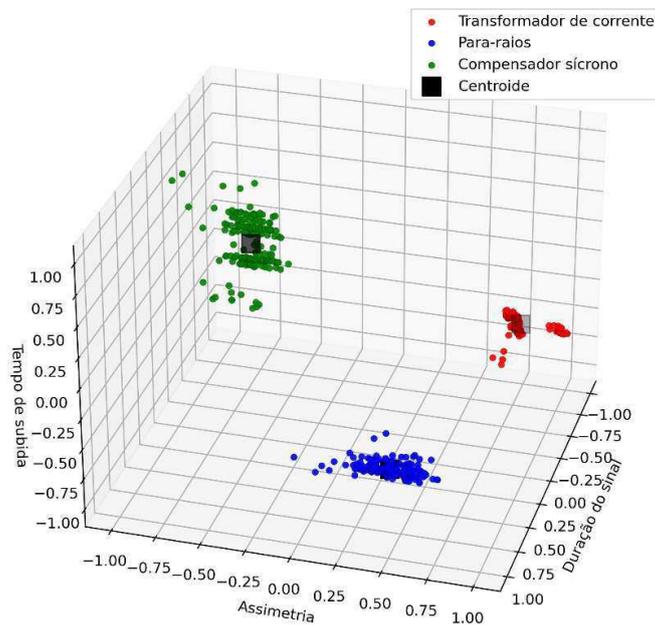
Fonte: Autoria própria.

Figura 5.23 - Gráfico de dispersão tridimensional do algoritmo GMM com os medidos em campo.



Fonte: Autoria própria.

Figura 5.24 - Gráfico de dispersão tridimensional do algoritmo Mean Shift com os dados medidos em campo.



Fonte: Autoria própria.

Os resultados evidenciaram que todos os três algoritmos separaram claramente os *clusters* de forma adequada, como ilustrado nos gráficos tridimensionais apresentados nas Figuras 5.22 – 5.24. Assim como para os dados detectados em laboratório, o ARI foi igual

a 1 para os três algoritmos, indicando uma perfeita concordância entre os agrupamentos gerados e os rótulos verdadeiros dos dados. Além disso, os gráficos resultantes apresentaram uma alta semelhança entre si, corroborando a consistência e a robustez dos algoritmos na tarefa de clusterização.

Os algoritmos supervisionados SVM, Random Forest e Regressão Logística foram também aplicados aos dados detectados em campo. A eficácia dos métodos foi avaliada por meio da acurácia média, precisão, recall e detalhada na matriz de confusão, conforme mostrado nas Tabelas 5.5 a 5.7.

Tabela 5.5 - Matriz de confusão, precisão, recall e acurácia média para o modelo SVM dos dados detectados em campo.

		Valores Previstos			
		Compensador síncrono	TC	Para-raios	Recall
Valores Reais	Compensador síncrono	60	0	0	1
	TC	0	21	14	0,60
	Para-raios	0	2	55	0,96
	Precisão	1	0,91	0,80	
		Acurácia = 0,89			

Fonte: Autoria própria.

O modelo SVM apresentou uma acurácia média de 0,89, com precisão perfeita para o compensador síncrono e alta precisão para os para-raios (0,80) e TC (0,91). O recall foi perfeito para o compensador síncrono (1) e muito alto para os para-raios (0,96), mas relativamente baixo para o TC (0,60), indicando que o modelo teve dificuldades em classificar corretamente todos os casos de TC. O desempenho inferior na classificação de TC pode ser atribuído a uma menor quantidade de dados para esta classe e possivelmente à maior complexidade ou variabilidade nos sinais associados a TC, que tornam sua identificação mais desafiadora para o modelo SVM.

Tabela 5.6 - Matriz de confusão, precisão, recall e acurácia média para o modelo Random Forest dos dados detectados em campo.

		Valores Previstos			
		Compensador síncrono	TC	Para-raios	Recall
Valores Reais	Compensador síncrono	60	0	0	1
	TC	0	35	0	1
	Para-raios	0	0	57	1
	Precisão	1	1	1	
		Acurácia = 1.0			

Fonte: Autoria própria.

O modelo Random Forest obteve um desempenho perfeito, com acurácia de 1.0. Este resultado significa que o modelo classificou corretamente todos os exemplos de teste. Esses resultados destacam a robustez do Random Forest, especialmente sua capacidade de lidar bem com dados desequilibrados. A combinação de múltiplas árvores de decisão treinadas em subconjuntos diferentes dos dados ajuda a reduzir variância e aumentar a capacidade de generalização do modelo.

Tabela 5.7 - Matriz de confusão, precisão, recall e acurácia média para o modelo de Regressão Logística dos dados detectados em campo.

		Valores Previstos			
		Compensador síncrono	TC	Para-raios	Recall
Valores Reais	Compensador síncrono	60	0	0	1
	TC	0	22	13	0,63
	Para-raios	0	5	52	0,91
	Precisão	1	0,81	0,80	
		Acurácia = 0,88			

Fonte: Autoria própria.

O modelo de Regressão Logística apresentou uma acurácia de 0,88, ligeiramente inferior ao SVM, mas ainda alta. com precisão perfeita para o compensador síncrono e alta para os para-raios (0,80), mas menor para o TC (0,81). O recall foi perfeito para o compensador síncrono (1) e alto para os para-raios (0,91), mas relativamente baixo para o TC (0,63), semelhante ao SVM.

A análise dos dados detectados em campo revelou que os algoritmos de aprendizado de máquina, tanto não supervisionados quanto supervisionados, foram capazes de desempenhar bem suas tarefas de clusterização e classificação mesmo em um ambiente não controlado, onde há presença de ruído e interferências. O algoritmo Random Forest foi o mais eficaz, obtendo uma acurácia perfeita de 1.0. Contudo, os algoritmos SVM e Regressão Logística, apesar de terem apresentado boas precisões e recalls em geral, mostraram dificuldades na classificação correta de todos os exemplos de TC. Esses resultados corroboram a eficácia e a robustez dos algoritmos aplicados, especialmente em condições de subestação, evidenciando a capacidade do sistema de condicionamento de sinal em fornecer dados de qualidade para a aplicação de técnicas avançadas de aprendizado de máquina.

Neste capítulo, foram analisados os resultados obtidos por meio da aplicação da metodologia descrita no capítulo 4. Na seção 5.1, foram detalhados os resultados da

geração de envoltórias de sinais de descargas parciais (DP) utilizando o método de estimação de densidade por Kernel (KDE). Em seguida, a seção 5.2 apresentou a análise do sistema desenvolvido utilizando o analisador de rede ENA RF E5062A e a avaliação da resposta em frequência do sistema na detecção de DP, evidenciando a eficácia do sistema em reduzir os requisitos de *hardware* dos sistemas de aquisição. Na seção 5.3, os resultados da extração e seleção de atributos das envoltórias dos sinais de DP foram apresentados e discutidos. Finalmente, a seção 5.4 abordou a separação e classificação das fontes de DP detectadas, com a aplicação de algoritmos de agrupamento e modelos de aprendizado de máquina. Os resultados demonstraram que os métodos analisados foram eficazes na separação e identificação das fontes de DP, confirmando a robustez e a eficácia da metodologia desenvolvida. No próximo capítulo, serão apresentadas as conclusões gerais e as implicações dos resultados obtidos para a área de estudo.

6 CONCLUSÕES

Esta tese foi motivada pelo objetivo de desenvolver um sistema capaz de adquirir os sinais radiométricos de DP com menos requisitos de *hardware* a partir da obtenção das envoltórias dos sinais, mas sem perder as informações necessárias para extrair e selecionar atributos relevantes para separação e classificação das DP; possibilitando assim, aumentar a aplicabilidade do método radiométrico de detecção e classificação de DP em subestações, tornando-o mais acessível e confiável em termos de implementação.

A partir dos resultados obtidos utilizando o algoritmo de geração de envoltórias, foi demonstrado que, embora o sinal de DP sofresse uma suavização, características dos sinais, como energia e duração, foram mantidas. Assim, a separação e classificação dos sinais ainda é viável. As simulações computacionais para avaliação das envoltórias dos sinais de DP forneceram um conhecimento inicial e indicaram quão promissora seria a separação de sinais utilizando apenas atributos extraídos das envoltórias dos sinais.

Para a geração de um banco de dados composto de envoltórias de sinais de DP, testes foram realizados em laboratório e em campo, utilizando o sistema de condicionamento de sinais desenvolvido. O sistema proposto é composto por um filtro RF passa-altas, um amplificador RF e um circuito detector de envoltória. Todos os componentes do sistema de condicionamento de sinal foram especificados e avaliados considerando a aquisição de sinais na faixa UHF.

As medições em laboratório e em campo com o sistema de condicionamento de sinais permitiram analisar a possibilidade efetiva de redução dos requisitos de amostragem do sistema de aquisição. Além disso, a análise de frequência após a detecção de envoltória revelou uma redução significativa no nível de frequência dos sinais, contribuindo para uma detecção de DP mais efetiva e confiável.

A etapa de extração e seleção de atributos foi fundamental para a posterior separação e classificação das envoltórias, pois determinou os atributos com menor redundância, e maior capacidade discriminatória e preditiva para a identificação das fontes de DP. A aplicação de métodos como *Recursive Feature Elimination* e Informação Mútua permitiu a seleção dos atributos mais relevantes para a identificação das diferentes fontes de DP. Posteriormente, a análise de correlação entre esses atributos possibilitou a identificação dos atributos menos redundantes.

A identificação dos atributos significativos não apenas contribuiu para uma melhor acurácia e eficiência dos modelos, mas também reduziu a complexidade computacional, eliminando redundâncias e ruídos nos dados. Este processo assegurou que os modelos desenvolvidos fossem mais robustos e interpretáveis, contribuindo significativamente para a qualidade e a confiabilidade dos resultados obtidos.

Nos estudos de separação e classificação das envoltórias, os resultados dos modelos de aprendizado de máquina aplicados aos dados detectados em laboratório e em campo mostraram que os algoritmos como K-means, GMM e Mean Shift foram eficazes na separação dos *clusters* de dados. Paralelamente, os algoritmos supervisionados como SVM, Random Forest e Regressão Logística apresentaram altas taxas de acurácia na classificação das fontes de DP. Dentre eles, o modelo Random Forest destacou-se, obtendo uma acurácia perfeita na classificação dos dados.

Os resultados obtidos nesta tese demonstram que os objetivos traçados foram atingidos, uma vez que o sistema proposto é capaz de promover uma detecção e classificação confiável de DP utilizando apenas atributos extraídos das envoltórias dos sinais radiométricos, evidenciando a capacidade do sistema de condicionamento de sinais em fornecer dados de qualidade para a aplicação de técnicas avançadas de aprendizado de máquina.

Conclui-se que esta tese contribuiu para o avanço no monitoramento e diagnóstico de equipamentos elétricos sujeitos a DP, fornecendo uma abordagem metodológica robusta e ferramentas eficazes para a identificação e classificação de DP. Ao desenvolver um sistema de condicionamento de sinais simples e de menor custo, que preserva as informações necessárias para a análise de DP, o trabalho torna a detecção e classificação utilizando o método radiométrico mais acessível e escalável. Isso aumenta sua viabilidade para aplicação prática em subestações, onde o monitoramento de DP pode ser aplicado para o monitoramento da integridade dos equipamentos elétricos.

Ademais, os resultados e conclusões apresentados servirão como base para futuras pesquisas e aplicações práticas na área de manutenção preditiva e segurança operacional em sistemas elétricos, como a implementação do *hardware* desenvolvido em um sistema de monitoramento *online*, integrado a soluções de IoT, viabilizando avanços na manutenção preditiva e na confiabilidade do sistema elétrico.

6.1 TRABALHOS A SEREM DESENVOLVIDOS NO FUTURO

Como continuação da pesquisa realizada nesta tese, propõe-se:

- Avaliar o sistema de condicionamento de sinais na medição de DP com diferentes antenas, incluindo aquelas com característica de maior diretividade e faixas de frequência distintas;
- Analisar a eficácia do sistema de condicionamento de sinal na localização de DP em subestações;
- Implementar a aquisição de sinais detectados pelo sistema de condicionamento de sinais, utilizando um sistema de aquisição de dados (DAQ) integrado a um computador industrial;
- Desenvolver uma rede de sensores, instalada em locais otimizados previamente definidos, que seja capaz de detectar DP utilizando o sistema de condicionamento de sinal e transmitir as informações para um sistema de gerenciamento de ativos dedicado.

7 REFERÊNCIAS

60270: 2000, IEC. High-voltage test techniques. Partial discharge measurements (IEC 60270:2000). *[S. l.]*, p. 53, 2000.

ALBARRACIN, R.; ROBLES, G.; MARTINEZ-TARIFA, J. M.; ARDILA-REY, J. Separation of sources in radiofrequency measurements of partial discharges using time-power ratio maps. **ISA Transactions**, *[S. l.]*, v. 58, p. 389–397, 2015. DOI: 10.1016/j.isatra.2015.04.006. Disponível em: <http://dx.doi.org/10.1016/j.isatra.2015.04.006>.

ALI, J.; KHAN, R.; AHMAD, N.; MAQSOOD, I. Random forests and decision trees. **IJCSI International Journal of Computer Science Issues**, *[S. l.]*, v. 9, n. 5, p. 272–278, 2012.

ALVAREZ, F.; GARNACHO, F.; KHAMLIHI, A.; ORTEGO, J. Classification of partial discharge sources by the characterization of the pulses waveform. **Proceedings of the 2016 IEEE International Conference on Dielectrics, ICD 2016**, *[S. l.]*, v. 1, p. 514–519, 2016. a. DOI: 10.1109/ICD.2016.7547655.

ÁLVAREZ, F.; GARNACHO, F.; ORTEGO, J.; SÁNCHEZ-URÁN, M. Á. Application of HFCT and UHF Sensors in On-Line Partial Discharge Measurements for Insulation Diagnosis of High Voltage Equipment. **Sensors (Switzerland)**, *[S. l.]*, v. 15, n. 4, p. 7360–7387, 2015. DOI: 10.3390/s150407360.

ALVAREZ, F.; ORTEGO, J.; GARNACHO, F.; SANCHEZ-URAN, M. A. A clustering technique for partial discharge and noise sources identification in power cables by means of waveform parameters. **IEEE Transactions on Dielectrics and Electrical Insulation**, *[S. l.]*, v. 23, n. 1, p. 469–481, 2016. b. DOI: 10.1109/TDEI.2015.005037.

ÁLVAREZ, F.; ORTEGO, J.; GARNACHO, F.; SÁNCHEZ-URÁN, M. A. A Clustering Technique for Partial Discharge and Noise Sources Identification in Power Cables by Means of Waveform Parameters. *[S. l.]*, v. 23, n. 1, p. 469–481, 2016. DOI: 10.1109/TDEI.2015.005037.

ARDILA-REY, J. A.; MARTÍNEZ-TARIFA, J. M.; ROBLES, G.; ROJAS-MORENO, M. Partial Discharge and Noise Separation by Means of Spectral-power Clustering Techniques. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 20, p. 1436–1443, 2013. DOI: 10.1109/TDEI.2013.6571466.

ARDILA-REY, J. A.; CERDA-LUNA, M. P.; ROZAS-VALDERRAMA, R. A.; DE CASTRO, B. A.; ANDREOLI, A. L.; MUHAMMAD-SUKKI, F. Separation techniques of partial discharges and electrical noise sources: A review of recent progress. **IEEE Access**, [S. l.], v. 8, n. November, p. 199449–199461, 2020. DOI: 10.1109/ACCESS.2020.3035249.

ASSEF, A. A.; FERREIRA, B. M.; MAIA, J. M.; COSTA, E. T. Modeling and FPGA-based implementation of an efficient and simple envelope detector using a Hilbert Transform FIR filter for ultrasound imaging applications. **Research on Biomedical Engineering**, [S. l.], v. 34, n. 1, p. 87–92, 2018. DOI: 10.1590/2446-4740.02417.

BAKER, P. C.; JUDD, M. D.; MCARTHUR, S. D. J. A frequency-based RF partial discharge detector for low-power wireless sensing. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 17, n. 1, p. 133–140, 2010. DOI: 10.1109/TDEI.2010.5412011.

BANFIELD, J. D.; RAFTERY, A. E. Model-Based Gaussian and Non-Gaussian Clustering. **Biometrics, International Biometric Society**, [S. l.], v. 49, n. 3, p. 803–821, 1993.

BARTNIKAS, R. Partial discharges their mechanism, detection and measurement. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 9, n. 5, p. 763–808, 2002. DOI: 10.1109/TDEI.2002.1038663.

BERNARD, S.; HEUTTE, L.; ADAM, S. On the selection of decision trees in Random forests. **Proceedings of the International Joint Conference on Neural Networks**, [S. l.], p. 302–307, 2009. DOI: 10.1109/IJCNN.2009.5178693.

BHAVSAR, H.; PANCHAL, M. H. A Review on Support Vector Machine for Data Classification. **International Journal of Advanced Research in Computer Engineering & Technology**, [S. l.], v. 1, n. 10, p. 2278–1323, 2012.

BLUM, A. L.; LANGLEY, P. Selection of Relevant Features and Examples in Machine Learning. **Artificial Intelligence, ELSEVIER**, [S. l.], p. 245–271, 1997. DOI: 10.1097/00000637-199310000-00024.

BREIMAN, L. Random Forests. *In: Machine Learning*. [s.l.] : Kluwer Academic Publishers, 2001. v. 45p. 5–32. DOI: 10.1007/978-3-030-62008-0_35.

CAVALLINI, A.; CONTIN, A.; MONTANARI, G. C.; PULETTI, F. Advanced PD Inference in On-Field Measurements . Part I : Noise Rejection. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 10, n. 2, p. 216–224, 2003. a.

CAVALLINI, A.; MONTANARI, G. C.; CONTIN, A.; PULETTI, F. A new approach to the diagnosis of solid insulation systems based on PD signal inference. **IEEE Electrical Insulation Magazine**, [S. l.], v. 19, n. 2, p. 23–30, 2003. b. DOI: 10.1109/MEI.2003.1192033.

CHAI, H.; PHUNG, B. T.; MITCHELL, S. Application of UHF sensors in power system equipment for partial discharge detection: A review. **Sensors (Switzerland)**, [S. l.], v. 19, n. 5, 2019. DOI: 10.3390/s19051029.

CHANDRA, M. A.; BEDI, S. S. Survey on SVM and their application in image classification. **International Journal of Information Technology (Singapore)**, [S. l.], v. 13, n. 5, p. 1867–1877, 2021. DOI: 10.1007/s41870-017-0080-1. Disponível em: <https://doi.org/10.1007/s41870-017-0080-1>.

CHEN, Q.; GONG, X.; GAO, W.; LI, F.; TAN, K. The UHF Method for Measurement of Partial Discharge in Oil-Impregnated Insulation. *In: 7TH LNTEMATIANAL CONFERENCE ON PROPELRIES AND APPLICATIONS OF DIELECTRIC MATERIALS 2003, Nagoya*. **Anais [...]**. Nagoya p. 451–454.

CHENG, Y. Mean Shift, Mode Seeking, and Clustering. **IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE**, [S. l.], v. 17, n. 8, p. 790–799, 1995.

CIGRE WORKING GROUP A2.27. Recommendations for condition monitoring and condition assessment facilities for transformers. [S. l.], 2008. DOI: .1037//0033-

2909.I26.1.78.

CIGRE WORKING GROUP A2.37. **Transformer Reliability Survey**. [s.l.] : Brochure 642, 2015.

COENEN, S.; TENBOHLEN, S. Location of PD Sources in Power Transformers by UHF and Acoustic Measurements. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 19, n. 6, p. 1934–1940, 2012. DOI: 10.1109/TDEI.2012.6396950.

COMANICIU, Dorin.; MEER, P. Mean shift: A Robust Approach Toward Feature Space Analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S. l.], v. 24, n. 5, p. 603–619, 2002. DOI: 10.1109/34.1000236.

CONTIN, A.; CAVALLINI, A.; MONTANARI, G. C.; PASINI, G.; PULETTI, F. Digital detection and fuzzy classification of partial discharge signals. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 9, n. 3, p. 335–348, 2002. DOI: 10.1109/TDEI.2002.1007695.

CORTES, C.; VAPNIK, V. Support-Vector Networks. [S. l.], v. 297, p. 273–297, 1995.

COSTA, E. G. Da; NEVES, W. L. A. **Apostila do curso de engenharia elétrica - Descargas Parciais**. Campina Grande.

DAN, C.; MORAR, R. Partial discharge measurements on 110kV current transformers. Setting the control value. Case study. **IOP Conference Series: Materials Science and Engineering**, [S. l.], v. 200, n. 1, 2017. DOI: 10.1088/1757-899X/200/1/012002.

DASH, M.; LIU, H. Feature selection for classification. **Intelligent Data Analysis**, [S. l.], v. 1, n. 3, p. 131–156, 1997. DOI: 10.3233/IDA-1997-1302.

DE SOUZA NETO, J. M. R.; DA ROCHA NETO, J. S.; MACEDO, E. C. T.; GLOVER, I. A.; JUDD, M. D. An envelope detector as a trading cost technique for radiometric partial discharge detection. , " **2014 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings**, [S. l.], p. 1584–1589, 2014. DOI: 10.1109/I2MTC.2014.6861013.

DENISSOV, D.; KÖHLER, W.; TENBOHLEN, S.; GRUND, R.; KLEIN, T. Wide and

narrow band PD detection in plug-in cable connectors in the UHF range. **Proceedings of 2008 International Conference on Condition Monitoring and Diagnosis, CMD 2008**, [S. l.], p. 1056–1059, 2008. DOI: 10.1109/CMD.2008.4580464.

DREISEITL, S.; OHNO-MACHADO, L. Logistic regression and artificial neural network classification models: A methodology review. **Journal of Biomedical Informatics**, [S. l.], v. 35, n. 5–6, p. 352–359, 2002. DOI: 10.1016/S1532-0464(03)00034-0.

ESTER, M.; KRIEGEL, H. P.; SANDER, J.; XU, X. A Density-Based Algorithm for Discovering Clusters A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. **Proceedings - 2nd International Conference on Knowledge Discovery and Data Mining, KDD 1996**, [S. l.], p. 226–231, 1996.

FENG, Q.; SHAO, Z. Identification of Partial Discharge Fault Type and Sensitivity Analysis of Joint Detection Based on Clustering Algorithm. **Proceedings - 2021 3rd International Conference on Artificial Intelligence and Advanced Manufacture, AIAM 2021**, [S. l.], p. 359–365, 2021. DOI: 10.1109/AIAM54119.2021.00079.

FRONTIN, S. O. **Equipamentos de Alta Tensão - Prospecção e Hierarquização de Inovações Tecnológicas**. 1º ed. Brasília: Goya Editora LTDA, 2013.

FUKUNAGA, K.; HOSTETLER, L. D. The Estimation of the Gradient of a Density Function, with Applications in Pattern Recognition. **IEEE Transactions on Information Theory**, [S. l.], v. 21, n. 1, p. 32–40, 1975. DOI: 10.1109/TIT.1975.1055330.

GAN, G.; MA, C.; WU, J. **Data clustering: theory, algorithms, and applications**. [s.l.] : Society for Industrial and Applied Mathematics., 2007. v. 01

GE, Y.; FU, X.; YIN, Y.; EL-SANKARY, K. Design of a high-speed RF envelope detector with dynamic load and derivative superposition techniques. **NEWCAS 2020 - 18th IEEE International New Circuits and Systems Conference, Proceedings**, [S. l.], p. 62–65, 2020. DOI: 10.1109/NEWCAS49341.2020.9159825.

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn , Keras & TensorFlow**. Second Edi ed. [s.l.] : O'Reilly Media, 2022.

GHANAKOTA, Krishna Chaitanya; YADAM, Yugandhara Rao; RAMANUJAN, Sarathi; VISHNU PRASAD, V. J.; ARUNACHALAM, Kavitha. Study of Ultra High Frequency Measurement Techniques for Online Monitoring of Partial Discharges in High Voltage Systems. **IEEE Sensors Journal**, [S. l.], v. 22, n. 12, p. 11698–11709, 2022. DOI: 10.1109/JSEN.2022.3172173.

GUIMARÃES, D. A.; SOUZA, R. A. A. Exploring Practical Aspects of the FSK Modulation with Non-Coherent Matched Filter Detection. **Revista de Tecnologia da Informação e Comunicação**, [S. l.], v. 5, n. 1, p. 22–28, 2015. DOI: 10.12721/2237-5112/rtic.v5n1p22-28.

GULSKI, E.; KREUGER, F. H. Computer-aided recognition of Discharge Sources. **IEEE Transactions on Electrical Insulation**, [S. l.], v. 27, n. 1, p. 82–92, 1992.

GULSKI, E.; KRIVDA, A. Neural Networks as a Tool for Recognition of Partial Discharges. [S. l.], v. 28, n. 8, 1993.

GUYON, I.; ELISSEEFF, A. An Introduction to Variable and Feature Selection Isabelle. **Journal of Machine Learning Research** 3, [S. l.], p. 1157–1182, 2003. DOI: 10.1016/j.aca.2011.07.027.

GUYON, I.; WESTON, J.; BARNHILL, S. Gene Selection for Cancer Classification using Support Vector Machines. **The Journal of Machine Learning**, [S. l.], v. 46, p. 389–242, 2002. DOI: 10.1007/978-3-540-88192-6_8.

HALL, M. A. **Correlation-based Feature Selection for Discrete and Numeric Class Machine Learning**. 2000. University of Waikato, [S. l.], 2000.

HAMPTON, B. F.; IRWIN, T.; LIGHTLE, D. **Diagnostic measurements at ultra high frequency in gis**. Cigré, Paper 15/33-01., , 1990.

HAMPTON, B. F.; MEATS, R. J. Diagnostic Measurements At Uhf in Gas Insulated Substations. **IEE Proceedings C: Generation Transmission and Distribution**, [S. l.], v. 135, n. 2, p. 137–144, 1988. DOI: 10.1049/ip-c.1988.0017.

HAMPTON, B. F.; PEARSON, J. S.; PARIHAH, O.; TAKACH, G. **Diagnostic monitoring of gas insulated substations**. CEPSI, , 1990.

HAN, L.; YAN, J.; FAN, S.; XU, M.; LIU, Z.; GENG, Y.; GUAN, C. Feature Extraction of UHF PD Signals Based on Diode Envelope Detection and Linear Discriminant Analysis. **5th International Conference on Electric Power Equipment - Switching Technology: Frontiers of Switching Technology for a Future Sustainable Power System, ICEPE-ST 2019**, [*S. l.*], p. 598–602, 2019. a. DOI: 10.1109/ICEPE-ST.2019.8928690.

HAN, L.; YAN, J.; FAN, S.; XU, M.; LIU, Z.; GENG, Y.; GUAN, C. Feature Extraction of UHF PD Signals Based on Diode Envelope Detection and Linear Discriminant Analysis. **5th International Conference on Electric Power Equipment – Switching Technology**, [*S. l.*], p. 598–602, 2019. b.

HAO, L.; LEWIN, P. L. Partial Discharge Source Discrimination using a Support Vector Machine. **IEEE Trans. Dielectr. Electr. Insul.**, [*S. l.*], v. 17, n. 1, p. 189–197, 2010.

HAO, L.; LEWIN, P. L.; HUNTER, J. A.; SWAFFIELD, D. J.; CONTIN, A.; WALTON, C.; MICHEL, M. Discrimination of multiple PD sources using wavelet decomposition and principal component analysis. **IEEE Transactions on Dielectrics and Electrical Insulation**, [*S. l.*], v. 18, n. 5, p. 1702–1711, 2011. DOI: 10.1109/TDEI.2011.6032842.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. Second Edi ed. [s.l: s.n.].

HE, X.; XIE, G.; JIANG, Y. Online partial discharge detection and location system using Wireless Sensor Network. **Energy Procedia**, [*S. l.*], v. 12, p. 420–428, 2011. DOI: 10.1016/j.egypro.2011.10.056.

HUNTER, J. A.; HAO, L.; LEWIN, P. L. Comparison of two partial discharge classification methods. **2010 IEEE International Symposium on Electrical Insulation**, [*S. l.*], p. 1–5, 2010. DOI: 10.1109/ELINSL.2010.5549736.

HUSSEIN, R.; SHABAN, K. B.; EL-HAG, A. H. Denoising different types of acoustic partial discharge signals using power spectral subtraction. **High Voltage**, [*S. l.*], v. 3, n. 1, p. 44–50, 2018. DOI: 10.1049/hve.2017.0119.

IEC60270. High-voltage test techniques – Partial discharge measurements. **International**

Electrotechnical Commission, Geneva, Switzerland, 2000.

JIANG, J.; CHEN, J.; LI, J.; YANG, X.; BIE, Y.; RANJAN, P.; ZHANG, C.; SCHWARZ, H. Partial Discharge Detection and Diagnosis of Transformer Bushing Based on UHF Method. **IEEE Sensors Journal**, [*S. l.*], v. 21, n. 15, p. 16798–16806, 2021. DOI: 10.1109/JSEN.2021.3066809.

JIANG, Z.; CHEN, W.; JIN, L.; ZHANG, H.; CUI, F.; LI, X. Effect of Humidity on the Detection of Dissolved Gases in Transformer Oil for Tin Oxide Based Gas Sensor. **ICHVE 2018 - 2018 IEEE International Conference on High Voltage Engineering and Application**, [*S. l.*], p. 1–4, 2019. DOI: 10.1109/ICHVE.2018.8642030.

JIN, L.; ZHENG, Y.; ZHAO, L.; SONG, Z. Detection Characteristics and Sensing Mechanism of Metal-doped SnO₂-based H₂ Gas Sensor. **7th IEEE International Conference on High Voltage Engineering and Application, ICHVE 2020 - Proceedings**, [*S. l.*], p. 15–18, 2020. DOI: 10.1109/ICHVE49031.2020.9280003.

JOHN, G. H.; KOHAVI, R.; PFLEGER, K. Irrelevant Features and the Subset Selection Problem. **Machine Learning Proceedings 1994**, [*S. l.*], p. 121–129, 1994. DOI: 10.1016/b978-1-55860-335-6.50023-4.

JOHNSON, S. C. Hierarchical Clustering Schemes. **Psychometrika**, [*S. l.*], v. 32, n. 3, p. 241- 254., 1967.

JUDD, M. D. Radiometric partial discharge detection. **Proceedings of 2008 International Conference on Condition Monitoring and Diagnosis, CMD 2008**, Beijing, China, p. 1025–1030, 2008. DOI: 10.1109/CMD.2008.4580457.

JUDD, M. D.; FARISH, O.; HAMPTON, B. F. The excitation of UHF signals by partial discharges in GIS. **IEEE Transactions on Dielectrics and Electrical Insulation**, [*S. l.*], v. 3, n. 2, p. 213–228, 1996. DOI: 10.1109/94.486773.

JUDD, M. D.; FARISH, O.; PEARSON, J. S.; BRECKENRIDGE, T.; PRYOR, B. M. Power transformer monitoring using UHF sensors: Installation and testing. **Conference Record of IEEE International Symposium on Electrical Insulation**, [*S. l.*], p. 373–376, 2000. DOI: 10.1109/ELINSL.2000.845528.

JUDD, M. D.; HUNTER, I. B. B. Partial Discharge Monitoring for Power Transformers Using UHF Sensors Part 1: Sensors and Signal Interpretation. **IEEE Electrical Insulation Magazine**, [*S. l.*], v. 21, n. 2, p. 5–14, 2005. DOI: 10.1109/MEI.2005.1412214.

JUDD, M. D.; PRYOR, B. M.; KELLY, S. C.; HAMPTON, B. F. Transformer monitoring using the UHF technique. **Eleventh International Symposium on High Voltage Engineering**, [*S. l.*], v. 5, n. 467, p. 362–365, 1999. a. DOI: 10.1049/cp:19990959.

JUDD, M. D.; PRYOR, B. M.; KELLY, S. C.; HAMPTON, B. F. Transformer monitoring using the UHF technique. **IEE Conference Publication**, [*S. l.*], v. 5, n. 467, p. 362–365, 1999. b. DOI: 10.1049/cp:19990959.

JUDD, M. D.; YANG, L.; HUNTER, I. B. B. Partial Discharge Monitoring for Power Transformers Using UHF Sensors Part 1: Sensors and Signal Interpretation. **IEEE Electrical Insulation Magazine**, [*S. l.*], v. 21, n. 2, p. 5–14, 2005. a. DOI: 10.1109/MEI.2005.1437603.

JUDD, M. D.; YANG, L.; HUNTER, I. B. B. Partial discharge monitoring for power transformers using UHF sensors Part 2: Field experience. **IEEE Electrical Insulation Magazine**, [*S. l.*], v. 21, n. 3, p. 5–13, 2005. b. DOI: 10.1109/MEI.2005.1437603.

KAYSER AZAM, S. M.; OTHMAN, M.; ILLIAS, H. A.; LATEF, T. A.; MAHADI, W. N. L. W.; FAHMI, D.; ZAKIR HOSSAIN, A. K. M.; AIN, M. F. Planar Sensor for Noise Cancellation during Partial Discharge Detection in Open Substation. **IEEE Sensors Journal**, [*S. l.*], v. 23, n. 14, p. 15552–15562, 2023. DOI: 10.1109/JSEN.2023.3279861.

KAZIZ, S.; SAID, M. H.; IMBURGIA, A.; MAAMER, B.; FLANDRE, D.; ROMANO, P.; TOUNSI, F. Radiometric Partial Discharge Detection: A Review. **Energies**, [*S. l.*], v. 16, n. 4, 2023. DOI: 10.3390/en16041978.

KHAN, U. F.; JANJUA, G. M. W.; AYUB, A.; ILYAS, M. A.; SHAHZAD, K.; MOHAMED, H. Use of optimized centroid and weighted centroid algorithms to locate a partial discharge source by using received signal strength. **International Symposium on Wireless Personal Multimedia Communications, WPMC**, [*S. l.*], v. 2020-Octob, n. 1,

p. 1–5, 2020. DOI: 10.1109/WPMC50192.2020.9309452.

KHAN, U. F.; LAZARIDIS, P. I.; MOHAMED, H.; ALBARRACÍN, R.; ZAHARIS, Z. D.; ATKINSON, R. C.; TACHTATZIS, C.; GLOVER, I. A. An efficient algorithm for partial discharge localization in high-voltage systems using received signal strength. **Sensors (Switzerland)**, *[S. l.]*, v. 18, n. 11, 2018. DOI: 10.3390/s18114000.

KIRKBAS, A.; DEMIRCALI, A.; KOROGLU, S.; KIZILKAYA, A. Fault diagnosis of oil-immersed power transformers using common vector approach. **Electric Power Systems Research**, *[S. l.]*, v. 184, n. February, p. 106346, 2020. DOI: 10.1016/j.epsr.2020.106346. Disponível em: <https://doi.org/10.1016/j.epsr.2020.106346>.

KLEINBAUM, D. G.; KLEIN, M. **Logistic Regression : A Self-Learning Text**. Second Edi ed. [s.l.] : Springer, 2002.

KRASKOV, A.; STÖGBAUER, H.; GRASSBERGER, P. Estimating mutual information. **Physical Review E - Statistical Physics, Plasmas, Fluids, and Related Interdisciplinary Topics**, *[S. l.]*, v. 69, n. 6, p. 16, 2004. DOI: 10.1103/PhysRevE.69.066138.

KREUGER, F. H. **Partial Discharge Detection in High-Voltage Equipment**. London: Butterworth-Heinemann, 1989.

KRIVDA, A. Automated Recognition of Partial Discharges. **IEEE Transactions on Dielectrics and Electrical Insulation**, *[S. l.]*, v. 2, n. 5, p. 796–821, 1995. DOI: 10.1109/94.469976.

KURRER, R.; KLUNZINGER, K.; FESER, K.; KOCK, N.; SOLOGUREN, D. Sensitivity of the UHF-method for Defects in GIS with Regard to On-line Partial Discharge Detection. **Conference Record of the 1996 IEEE International Symposium on Electrical Insulation**, *[S. l.]*, v. 1, p. 95–98, 1996.

LAVALLEY, M. P. Logistic regression. **Circulation**, *[S. l.]*, v. 117, n. 18, p. 2395–2399, 2008. DOI: 10.1161/CIRCULATIONAHA.106.682658.

LI-XUE, L.; CHENG-JUN, H.; YI, Z.; XIU-CHEN, J. Partial discharge diagnosis on GIS based on envelope detection. **WSEAS Transactions on Systems**, *[S. l.]*, v. 7, n. 11, p.

1238–1247, 2008.

LIGHTLE, D.; HAMTON, B.; T., Irwin. Monitoring of GIS at ultra high frequency. **6th International Symposium on High Voltage Engineering**, [S. l.], p. 6, 1989.

LIU, M.; LI, Z. An Online UHF PD Monitoring System for Power Transformer and Its Applications. **2010 Asia-Pacific Power and Energy Engineering Conference**, [S. l.], p. 1–4, 2010. DOI: 10.1109/APPEEC.2010.5449362.

LIU, W.; LIU, S.; HU, X. Feature extraction and pattern recognition of signals radiated from partial discharge. **5th Asia-Pacific Conference on Environmental Electromagnetics (CEEM)**, [S. l.], p. 114–117, 2009. DOI: 10.1109/CEEM.2009.5304189.

LLOYD, S. P. Least Squares Quantization in PCM. **IEEE Transactions on Information Theory**, [S. l.], v. 28, n. 2, p. 129–137, 1982. DOI: 10.1109/TIT.1982.1056489.

LONG, J.; WANG, X.; ZHOU, W.; ZHANG, J.; DAI, D.; ZHU, G. A Comprehensive Review of Signal Processing and Machine Learning Technologies for UHF PD Detection and Diagnosis (I): Preprocessing and Localization Approaches. **IEEE Access**, [S. l.], v. 9, n. 1, p. 69876–69904, 2021. DOI: 10.1109/ACCESS.2021.3077483.

LYONS, Richard. Digital Envelope Detection: The Good, the Bad, and the Ugly [Tips and Tricks]. **IEEE Signal Processing Magazine**, [S. l.], v. 34, n. 4, p. 183–187, 2017. DOI: 10.1109/MSP.2017.2690438.

MACÊDO, E. C. T. **Metodologia Para a Classificação de Descargas Parciais Utilizando Redes Neurais Artificiais**. 2014. Tese de Doutorado, Universidade Federal de Campina Grande, [S. l.], 2014.

MACEDO, E. C. T.; VILLANUEVA, J. M.; DA COSTA, E. G.; FREIRE, R. C. S.; ARAUJO, D. B.; DE SOUZA NETO, J. M. R.; GLOVER, I. A. Assessment of Dielectric Degradation by Measurement, Processing and Classification of Partial Discharges. **Proceedings of the 2012 IEEE International Power Modulator and High Voltage Conference, IPMHVC 2012**, [S. l.], v. 2, p. 587–590, 2012. DOI: 10.1109/IPMHVC.2012.6518812.

MACQUEEN, J. SOME METHODS FOR CLASSIFICATION AND ANALYSIS OF MULTIVARIATE OBSERVATIONS. **UNIVERSITY OF CALIFORNIA, Los ANGELES**, [S. l.], 1967. DOI: 10.1007/s11665-016-2173-6.

MAHMOOD NAJAFI, S. A.; PEIMANKAR, A.; SAADATI, H.; GOCKENBACH, E.; BORSI, H. The Influence of Corona Near to the Bushing of a Transformer on Partial Discharge Measurement with an Acoustic Emission Sensor. **2013 IEEE Electrical Insulation Conference, EIC 2013**, [S. l.], n. June, p. 295–298, 2013. DOI: 10.1109/EIC.2013.6554253.

MASAKI, K.; SAKAKIBARA, T.; MURASE, H.; AKAZAKI, M.; UEHARA, K.; MENJU, S. On-site measurement for the development of on-line partial discharge monitoring system in gis. **IEEE Transactions on Power Delivery**, [S. l.], v. 9, n. 2, p. 805–810, 1994. DOI: 10.1109/61.296260.

MEIJER, S.; GULSKI, E.; SMIT, J. J. Pattern analysis of partial discharges in SF6 GIS. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 5, n. 6, p. 830–842, 1998. DOI: 10.1109/94.740764.

MOHAMED, Hamd; KHAN, Umar; RAZA, Mohsin; ABOGILA, Khaoula; MOHAMMED, Mahmud; ALHAJ, Mohammed. An Analysis and Comparison of Partial Discharge Signal Detection and Localization using SDR and radiometric sensor. **2021 29th Telecommunications Forum, TELFOR 2021 - Proceedings**, [S. l.], p. 1–4, 2021. DOI: 10.1109/TELFOR52709.2021.9653331.

MOHAMMAD, W. N. A. W.; ROHANI, M. N. K. H.; ROSLE, N. F.; KHALID, K. N.; ROSMI, A. S.; ABDULLAH, A. Z.; JAMIL, M. K. M. Analysis on Multiple Acoustic and Electrical Emission of PD Signal Based on Signal to Noise Ratio (SNR) on Power Cable. **Proceeding - 2020 IEEE 8th Conference on Systems, Process and Control, ICSPC 2020**, [S. l.], n. December, p. 190–195, 2020. DOI: 10.1109/ICSPC50992.2020.9305756.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine Learning**. Second Edi ed. [s.l: s.n.].

NATTRASS, D. A. Partial Discharge Measurement and Interpretation. **IEE Electrical**

Insulation Magazine, 1988, v. 4, n. 3, p. 10–23, 1988.

NÓBREGA, L. A. M. M. **Novo Método para Monitoramento e Localização de Fontes de Descargas Parciais em Transformadores de Potência Utilizando Medições e Simulações na faixa UHF**. 2019. Tese de Doutorado, Universidade Federal de Campina Grande, [S. l.], 2019.

NOBREGA, L. A. M. M.; XAVIER, G. V. R.; AQUINO, M. V. D.; SERRES, A. J. R.; ALBUQUERQUE, C. C. R.; COSTA, E. G. Da. Design and development of a bio-inspired uhf sensor for partial discharge detection in power transformers. **Sensors (Switzerland)**, [S. l.], v. 19, n. 3, p. 1–16, 2019. a. DOI: 10.3390/s19030653.

NOBREGA, L. A. M. M.; XAVIER, G. V. R.; SERRES, Al. J. R.; DA COSTA, E. G. Investigating reflections and refractions effects in the UHF Location of partial discharges in power transformers using time domain simulation. **SBSE 2018 - 7th Brazilian Electrical Systems Symposium**, [S. l.], n. 1, p. 1–5, 2018. DOI: 10.1109/SBSE.2018.8395674.

NOBREGA, Luiz A. M. M.; COSTA, Edson G.; SERRES, Alexandre J. R.; XAVIER, George V. R.; AQUINO, Marcus V.D. UHF partial discharge location in power transformers via solution of the maxwell equations in a computational environment. **Sensors (Switzerland)**, [S. l.], v. 19, n. 15, p. 13–15, 2019. b. DOI: 10.3390/s19153435.

PALO, M.; SCHUBERT, B.; OGLIARI, E.; WEI, J.; GU, K.; LIU, W. Detection, Features Extraction and Classification of Radio-Frequency Pulses in a High-Voltage Power Substation: Results from a Measurement Campaign. **Proceedings of the 2020 IEEE 3rd International Conference on Dielectrics, ICD 2020**, [S. l.], p. 677–680, 2020. DOI: 10.1109/ICD46958.2020.9342022.

PEARSON, J. S.; FARISH, O.; HAMPTON, B. F.; JUDD, M. D.; TEMPLETON, D.; PRYOR, B. W.; WELCH, I. M. Partial Discharge Diagnostics for Gas Insulated Substations. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 2, n. 5, p. 893–905, 1995. DOI: 10.1109/94.469984.

PEARSON, J. S.; HAMPTON, B. F.; SELLARS, A. G. A Continuous UHF Monitor for Gas-insulated Substations. **IEEE Transactions on Electrical Insulation**, [S. l.], v. 26,

n. 3, p. 469–478, 1991. DOI: 10.1109/14.85119.

PEMEN, A. J. M.; RUTGERS, W. R.; RJIN, T. J. M.; FU, Y. H. ON-LINE PARTIAL DISCHARGE MONITORING OF HV COMPONENTS. **Eleventh International Symposium on High Voltage Engineering**, [*S. l.*], v. 5, p. 136–139, 1999.

PENG, X.; ZHOU, C.; HEPBURN, D.; JUDD, M. D.; SIEW, W. H. Application of K-Means method to pattern recognition in on-line cable partial discharge monitoring. **IEEE Transactions on Dielectrics and Electrical Insulation**, [*S. l.*], v. 20, n. 3, p. 754–761, 2013. DOI: 10.1109/TDEL.2013.6518945.

PING, S.; DAKE, X.; GUOLI, W.; YANMING, L. Application of neural network with genetic algorithm to UHF PD pattern recognition in transformers. **Conference on Electrical Insulation and Dielectric Phenomena (CEIDP), Annual Report**, [*S. l.*], p. 732–735, 2002. DOI: 10.1109/ceidp.2002.1048900.

PINPART, T. **Techniques for analysis and interpretation of UHF partial discharge signals**. 2010. University of Strathclyde, [*S. l.*], 2010.

PINPART, T.; FLETCHER, J. E.; JUDD, M. D. Methods for distinguishing between partial discharges based on the UHF detection technique. **Proceedings of 2008 International Conference on Condition Monitoring and Diagnosis, CMD 2008**, [*S. l.*], p. 1060–1064, 2008. a. DOI: 10.1109/CMD.2008.4580465.

PINPART, T.; FLETCHER, J. E.; JUDD, M. D. Methods for Distinguishing between Partial Discharges based on the UHF Detection Technique. **International Conference on Condition Monitoring and Diagnosis**, [*S. l.*], p. 1060–1064, 2008. b.

PINPART, T.; JUDD, M. D. Differentiating between partial discharge sources using envelope comparison of ultra-high-frequency signals. **IET Science, Measurement and Technology**, [*S. l.*], v. 4, n. 5, p. 256–267, 2010. DOI: 10.1049/iet-smt.2009.0064.

QIAN, S.; CHEN, H.; XU, Y.; SU, L. High Sensitivity Detection of Partial Discharge Acoustic Emission within Power Transformer by Sagnac Fiber Optic Sensor. **IEEE Transactions on Dielectrics and Electrical Insulation**, [*S. l.*], v. 25, n. 6, p. 2313–2320, 2018. DOI: 10.1109/TDEL.2018.007131.

RAJA, K.; FLORIBERT, T. Comparative Investigations on UHF and Acoustic PD Detection Sensitivity in Transformers. **Conference Record of IEEE International Symposium on Electrical Insulation**, Boston, p. 150–153, 2002. DOI: 10.1109/elinsl.2002.995900.

RASCHKA, S.; MIRJALILI, V. **Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2**. Third Edit ed. Mumbai: P, 2019.

ROBLES, G.; FRESNO, J. M.; MARTÍNEZ-TARIFA, J. M. Separation of radio-frequency sources and localization of partial discharges in noisy environments. **Sensors (Switzerland)**, [S. l.], v. 15, n. 5, p. 9882–9898, 2015. DOI: 10.3390/s150509882.

ROBLES, Guillermo; PARRADO-HERNÁNDEZ, Emilio; ARDILA-REY, Jorge; MARTÍNEZ-TARIFA, Juan Manuel. Multiple partial discharge source discrimination with multiclass support vector machines. **Expert Systems with Applications**, [S. l.], v. 55, p. 417–428, 2016. DOI: 10.1016/j.eswa.2016.02.014.

RODRIGUEZ-GALIANO, V. F.; LUQUE-ESPINAR, J. A.; CHICA-OLMO, M.; MENDES, M. P. Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods. **Science of the Total Environment**, [S. l.], v. 624, p. 661–672, 2018. DOI: 10.1016/j.scitotenv.2017.12.152. Disponible em: <https://doi.org/10.1016/j.scitotenv.2017.12.152>.

ROSLIZAN, N. D.; ROHANI, M. N. K. H.; WOOL, C. L.; ISA, M.; ISMAIL, B.; ROSMI, A. S.; MUSTAFA, W. A. A Review: Partial Discharge Detection using UHF sensor on High Voltage Equipment. **Journal of Physics: Conference Series**, [S. l.], v. 1432, n. 1, 2020. DOI: 10.1088/1742-6596/1432/1/012003.

RUTGERS, W.; FU, Y. **Uhf pd-detection in a power transformer**. 10th International Symposium on High Voltage Engineering, , 1997.

SCHICHLER, U. et al. Risk Assessment on Defects in GIS Based on PD Diagnostics Kurzfassung Defect properties Breakdown behaviour of gas-insulated. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 20, n. 6, p. 1–7, 2013.

SCHLAIKJER, M.; BAGGE, J. P.; SØRENSEN, O. M.; JENSEN, J. A. Trade off study on different envelope detectors for B-mode imaging. **Proceedings of the IEEE Ultrasonics Symposium**, [S. l.], v. 2, n. 1, p. 1938–1941, 2003. DOI: 10.1109/ultsym.2003.1293296.

SIEGEL, M.; BELTLE, M.; TENBOHLEN, S. PD monitoring of power transformers by UHF sensors. **VDE-Fachtagung Hochspannungstechnik 2016**, [S. l.], p. 366–371, 2016.

SIEGEL, M.; BELTLE, M.; TENBOHLEN, S.; COENEN, S. Application of UHF sensors for PD measurement at power transformers. **IEEE Transactions on Dielectrics and Electrical Insulation**, [S. l.], v. 24, n. 1, p. 331–339, 2017. DOI: 10.1109/TDEI.2016.005913.

STRACHAN, S. M.; MCARTHUR, S. D. J.; JUDD, M. D.; MCDONALD, J. R. Incremental knowledge-based partial discharge diagnosis in oil-filled power transformers. **Proceedings of the 13th International Conference on Intelligent Systems Application to Power Systems, ISAP'05**, [S. l.], v. 2005, p. 181–186, 2005. DOI: 10.1109/ISAP.2005.1599259.

SUBRAMANIAM, A.; RAMAN, S. J.; PANDA, S. K. Comparison of Partial Discharge signal in a Three phase Transformer by UHF, TEV and HFCT sensors. **ICPEE 2021 - 2021 1st International Conference on Power Electronics and Energy**, [S. l.], p. 9–12, 2021. DOI: 10.1109/ICPEE50452.2021.9358502.

SUN, C.; OHODNICKI, P. R.; STEWART, E. M. Chemical Sensing Strategies for Real-Time Monitoring of Transformer Oil: A Review. **IEEE Sensors Journal**, [S. l.], v. 17, n. 18, p. 5786–5806, 2017. DOI: 10.1109/JSEN.2017.2735193.

TAHA, I. B. M.; DESSOUKY, S. S.; GHONEIM, S. S. M. Transformer fault types and severity class prediction based on neural pattern-recognition techniques. **Electric Power Systems Research**, [S. l.], v. 191, n. October 2020, p. 106899, 2021. DOI: 10.1016/j.epsr.2020.106899. Disponível em: <https://doi.org/10.1016/j.epsr.2020.106899>.

TANG, J.; XU, Z.; ZHANG, X.; SUN, C. GIS partial discharge quantitative measurements using UHF microstrip antenna sensors. **Annual Report - Conference on**

Electrical Insulation and Dielectric Phenomena, CEIDP, [S. l.], p. 116–119, 2007. DOI: 10.1109/CEIDP.2007.4451454.

TANG, Z. G.; WANG, C. X.; CHEN, J. X.; WU, W. X.; LI, C. R. Pulse interferences elimination and classification of on-line UHF PD signals. **Gaodianya Jishu/High Voltage Engineering, [S. l.], v. 35, n. 5, p. 1026–1031, 2009.**

TEIKARI, I.; HALONEN, K. Effect of envelope detectors and filters on a digitally controlled RE predistortion system. **IEEE MTT-S International Microwave Symposium Digest, [S. l.], p. 1879–1882, 2006. DOI: 10.1109/MWSYM.2006.249781.**

TENBOHLEN, S. et al. Frequency Range of UHF PD Measurements in Power Transformers. *[S. l.]*, 2023.

TENBOHLEN, S.; BELTLE, M.; SIEGEL, Martin. PD Monitoring of power transformers by UHF sensors. **Proceedings of the International Symposium on Electrical Insulating Materials, [S. l.], v. 1, p. 303–306, 2017. DOI: 10.23919/iseim.2017.8088747.**

TENBOHLEN, S.; DENISSOV, D.; HOEK, S. M.; MARKALOUS, S. M. Partial discharge measurement in the ultra high frequency (UHF) range. **IEEE Transactions on Dielectrics and Electrical Insulation, [S. l.], v. 15, n. 6, p. 1544–1552, 2008. DOI: 10.1109/TDEI.2008.4712656.**

UPTON, D. W. et al. Wireless Sensor Network for Radiometric Detection and Assessment of Partial Discharge in High-Voltage Equipment. **Radio Science, [S. l.], v. 53, n. 3, p. 357–364, 2017. DOI: 10.1002/2017RS006507.**

VAPNIK, N. V. **The Nature of Statistical Learning Theory.** Second Edi ed. [s.l.] : Springer, 1999.

WANG, W.; LI, C. R.; TANG, Z.; LI, Z.; DING, Y. An On-line UHF PD Monitoring System for Power Transformers. **Conference Record of the 2004 IEEE International Symposium on Electrical Insulation, [S. l.], n. September, p. 50–53, 2004.**

WĘGLARCZYK, S. Kernel density estimation and its application. **ITM Web of Conferences, [S. l.], v. 23, p. 00037, 2018. DOI: 10.1051/itmconf/20182300037.**

WORKING GROUP 21.03 CIGRE. Recognition of Discharges. **Electra**, [S. l.], v. 11, p. 61–89, 1969.

WOTZKA, D.; SIKORSKI, W.; SZYMCZAK, C. Investigating the Capability of PD-Type Recognition Based on UHF Signals Recorded with Different Antennas Using Supervised Machine Learning. **Energies**, [S. l.], v. 15, n. 9, 2022. DOI: 10.3390/en15093167.

WU, F.; LUO, L.; JIA, T.; SUN, A.; SHENG, G.; JIANG, Xi. RSSI-Power-Based Direction of Arrival Estimation of Partial Discharges in Substations. **Energies**, [S. l.], v. 12, p. 1–14, 2019.

XAVIER, G. V. R. **Aplicação de Antenas Monopolo Impressas Bio-Inspiradas com Superstratos Metamateriais na Detecção e Localização de Descargas Parciais** George Victor Rocha Xavier **Aplicação de Antenas Monopolo Impressas Bio-Inspir.** 2021. Universidade Federal de Campina Grande, [S. l.], 2021.

XAVIER, G. V. R.; DA COSTA, E. G.; SERRES, A. J. R.; NOBREGA, L. A. M. M.; OLIVEIRA, A. C.; SOUSA, H. F. S. Design and Application of a Circular Printed Monopole Antenna in Partial Discharge Detection. **IEEE Sensors Journal**, [S. l.], v. 19, n. 10, p. 3718–3725, 2019. DOI: 10.1109/JSEN.2019.2896580.

XAVIER, G. V. R.; SILVA, H. S.; DA COSTA, E. G.; SERRES, A. J. R.; CARVALHO, N. B.; OLIVEIRA, A. S. R. Detection, classification and location of sources of partial discharges using the radiometric method: Trends, challenges and open issues. **IEEE Access**, [S. l.], v. 9, p. 110787–110810, 2021. DOI: 10.1109/ACCESS.2021.3102888.

YITONG, X.; ZHAO, C.; KAI, K. A Highly-Applicable Supply Modulator with a Highly-Linear Envelope Detector for WCDMA Envelope-Tracking Applications. **2016 IEEE MTT-S International Microwave Workshop Series on Advanced Materials and Processes for RF and THz Applications, IMWS-AMP 2016 - Proceeding**, [S. l.], p. 1–4, 2016. DOI: 10.1109/IMWS-AMP.2016.7588463.

YUEN, D. C. M.; CHAN, S. H. **UHF partial discharge monitoring of 400 kV GIS castle peak substation**. IEE International Conference on Advances in Power System Control, Operation and Management, , 1991.

YUNPENG, L.; JUAN, W.; FANGCHENG, L.; QINGYUM, J. On-line Monitoring System of Ultra-high-frequency PD in Transformer Based on Virtual Instrument Experiments and Results Analysis. **8th International Conference on Electronic Measurement and Instruments**, [S. l.], p. 283–286, 2007.

ZHANG, T.; RAMAKRISHNAN, R.; LIVNY, M. BIRCH: An Efficient Data Clustering Method for Very Large Databases. **SIGMOD Record (ACM Special Interest Group on Management of Data)**, [S. l.], v. 25, n. 2, p. 103–114, 1996. DOI: 10.1145/235968.233324.

