

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA**

**Algoritmo para Estimativa do Grau de Severidade de Descargas Parciais
em Isoladores de Alta Tensão**

Lucas de Paula Santos Petri

Itajubá, setembro de 2020

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA**

Lucas de Paula Santos Petri

**Algoritmo para Estimativa do Grau de Severidade de Descargas Parciais
em Isoladores de Alta Tensão**

**Dissertação submetida ao Programa de Pós-
Graduação em Engenharia Elétrica como
parte dos requisitos para obtenção do Título
de Mestre em Ciências em Engenharia
Elétrica.**

**Área de Concentração: Sistemas Elétricos de
Potência**

**Orientador: Prof. Dr. Estácio Tavares
Wanderley Neto**

Coorientador: Prof. Dr. José Feliciano Adami

**Setembro de 2020
Itajubá**

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA**

Lucas de Paula Santos Petri

**Algoritmo para Estimativa do Grau de Severidade de Descargas Parciais em
Isoladores de Alta Tensão**

Dissertação aprovada por banca examinadora em 25 de setembro de 2020, conferindo ao autor o título de **Mestre em Ciências em Engenharia Elétrica**.

Banca Examinadora:

Prof. Dr. Estácio Tavares Wanderley Neto (orientador)

Prof. Dr. José Feliciano Adami (coorientador)

Prof. Dr. Credson de Salles

Prof. Dr. Benedito Isaias Lima Fully

Prof. Dr. Edson Guedes da Costa (membro externo)

**Itajubá
2020**

AGRADECIMENTOS

Agradeço, primeiramente, a Deus o discernimento e a proteção ao longo de toda a minha vida;

à minha mãe o apoio constante, o amor e o carinho que me fizeram chegar até aqui;

aos meus amigos Fábio e Mayara o apoio e o companheirismo;

ao Branco e à Benerina o acolhimento, a atenção e a confiança;

ao meu orientador e ao meu coorientador o aprendizado, a confiança e a paciência;

aos membros da banca a disponibilidade e o aprendizado;

ao LAT-EFEI e à Unifei a oportunidade e a disponibilidade;

à equipe da HVEX o aprendizado e a parceria;

à Equatorial Energia e à Agência Nacional de Energia Elétrica (ANEEL) a oportunidade de fazer parte do Programa de Pesquisa & Desenvolvimento (P&D);

à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) o auxílio financeiro.

RESUMO

O presente estudo utiliza redes neurais artificiais, uma ferramenta de aprendizado de máquina – subárea da inteligência artificial –, para a classificação de sinais de descargas parciais em isoladores de alta tensão. Além disso, estes sinais também são analisados por meio de implementações em linguagem de programação Python, visando a definição de um grau de severidade da atividade de descargas parciais por meio de um sistema de inferência *fuzzy*. O caso de estudo deste trabalho é a cidade de São Luís, capital do estado do Maranhão, cujo sistema elétrico está sob concessão da Equatorial Energia. A área de serviço da concessionária compreende um sistema de transmissão de 69 kV, cujas estruturas empregam, em sua maioria, isoladores compostos do tipo pilar ou suspensão. As descargas parciais, além de provocarem a degradação da superfície polimérica dos isoladores, podem evoluir para arcos mais extensos, podendo levar a descargas disruptivas (*flashover*) que resultem em faltas no sistema e interrupções no fornecimento de energia. A proposta deste trabalho foi o desenvolvimento de algoritmos de aquisição e análise de sinais de descargas parciais para compor um equipamento de inspeção que possa ser utilizado em campo por meio de um sistema *software-hardware* compacto e portátil e de uma antena para a coleta dos sinais de interferência de radiofrequência oriundos da atividade de descargas. Desta forma, a equipe de manutenção da concessionária terá à disposição uma ferramenta de apoio à decisão para avaliar a condição das estruturas, permitindo o agendamento de rotinas de manutenção preventiva quando necessário, visando prevenir eventos de interrupção no fornecimento de energia. A partir de dados coletados em ensaios em laboratório e em campo, são apresentados resultados que demonstram a coerência dos parâmetros selecionados para o cálculo da severidade. O aumento do grau de severidade é observado com a intensificação da poluição superficial e com a elevação da umidade relativa.

Palavras-Chave: Inteligência Artificial, Aprendizado de Máquina, Redes Neurais Artificiais, Descargas Parciais, Isoladores de Alta Tensão.

ABSTRACT

This study makes use of artificial neural networks, a machine learning algorithm, for the classification of signals of partial discharges in high voltage insulators. In addition to that, these signals are further analyzed by means of implementations in Python programming language, seeking to define a severity degree for the partial discharge activity using a fuzzy inference system. The case study of this work is the city of São Luís, capital of the state of Maranhão, whose electric system is under concession of Equatorial Energia. The utility's service area comprises a 69 kV transmission system, whose structures employ composite line post or suspension insulators. Partial discharges not only cause the degradation of the polymeric surface of the insulators, but can also evolve to extensive arcing, which can further cause flashovers that result in system faults and energy supply interruptions. This work has proposed the development of data acquisition and analysis algorithms for partial discharge signals, to compose an inspection instrument that can be used in the field by means of a compact and portable software-hardware system and an antenna for the acquisition of radiofrequency interference signals from discharge activity. Thus, the utility's maintenance team will have a decision support tool to assess the structures condition, thus enabling the scheduling of preventive maintenance routines, if necessary, seeking to prevent power supply interruption events. From laboratory tests and field collected data, some results are presented, showing the consistency of the parameters selected to calculate the severity index. The increase of the severity degree is observed with the aggravation of surface pollution and rise of relative humidity.

Keywords: Artificial Intelligence, Machine Learning, Artificial Neural Networks, Partial Discharges, High Voltage Insulators.

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 – Distâncias de interesse do isolador: escoamento (vermelho) e arco (azul)..... | 20 |
| Figura 2 – Formação das bandas secas..... | 24 |
| Figura 3 – Representação de descargas parciais pelo modelo ABC: (a) capacitâncias distribuídas pelo corpo de prova; (b) circuito equivalente do fenômeno..... | 28 |
| Figura 4 – Efeito do número de filtros sobre os dados..... | 33 |
| Figura 5 – Exemplo da ação da camada de <i>pooling</i> pelo valor máximo..... | 34 |
| Figura 6 – Efeito dos parâmetros <i>stride</i> e <i>zero-padding</i> sobre os dados..... | 35 |
| Figura 7 – Modelo das redes adversárias generativas..... | 37 |
| Figura 8 – Gráficos da função logaritmo da probabilidade..... | 38 |
| Figura 9 – Equipamento Radar Engineers Model 242 – AM-UHF RFI Locator..... | 51 |
| Figura 10 – Equipamento Radar Engineers Model 250 – Parabolic Pinpointer..... | 51 |
| Figura 11 – Equipamento HVPD HFCT100: (a) estrutura; (b) resposta em frequência..... | 52 |
| Figura 12 – Alcance de diferentes valores de frequência a partir de uma fonte de interferência..... | 53 |
| Figura 13 – Estrutura sendo inspecionada em campo por meio do equipamento <i>Model 242</i> | 53 |
| Figura 14 – Cadeia de isoladores sendo inspecionada em laboratório por meio do equipamento <i>Model 250</i> | 54 |
| Figura 15 – Equipamento HFCT100 com o condutor de aterramento passando através da sua janela..... | 55 |
| Figura 16 – Exemplo de estrutura de 500 kV inspecionada em campo..... | 55 |
| Figura 17 – Exemplos de estruturas do sistema de 69 kV de São Luís-MA..... | 57 |
| Figura 18 – Utilização do equipamento <i>Model 242</i> à distância do laboratório (em destaque)..... | 58 |
| Figura 19 – Circuito de ensaio padronizado, utilizando o equipamento DDX 9121b..... | 61 |
| Figura 20 – Comparação da hidrofobicidade entre uma amostra recondicionada e uma nova..... | 62 |
| Figura 21 – Interface do programa do equipamento DDX 9121b..... | 63 |
| Figura 22 – Circuito de ensaio utilizado..... | 63 |
| Figura 23 – Método de simulação de descargas por meio de centelhador..... | 65 |
| Figura 24 – Detalhe do <i>gap</i> formado entre o fio e a campânula do isolador..... | 65 |
| Figura 25 – Centelhamento ocorrendo no <i>gap</i> | 65 |
| Figura 26 – Amostra de isolador após ensaio de chuva dentro da câmara de ensaio..... | 69 |
| Figura 27 – Amostra de isolador sob névoa salina dentro da câmara de ensaio..... | 69 |
| Figura 28 – Centelhamento ocorrendo no corpo de prova durante ensaio de névoa salina..... | 70 |
| Figura 29 – Amostra de isolador tipo pilar polimérico classe 69 kV..... | 72 |
| Figura 30 – Método da camada sólida: (a) aplicação da suspensão; (b) amostra contaminada..... | 74 |
| Figura 31 – Comparação entre a amostra sem contaminação (esquerda) e a amostra contaminada (direita)..... | 75 |
| Figura 32 – Câmara de ensaio e antena utilizada com sensor de descargas parciais..... | 75 |
| Figura 33 – Interior da câmara de ensaio, mostrando os nebulizadores e o desumidificador..... | 76 |
| Figura 34 – Configuração final da câmara de ensaio com o tubo de náilon..... | 77 |
| Figura 35 – Antena apontada para a amostra a ser ensaiada..... | 77 |
| Figura 36 – Centelhamento entre as saias do corpo de prova..... | 78 |
| Figura 37 – Arco voltaico sobre o corpo de prova..... | 78 |
| Figura 38 – Consequência do ensaio sobre a camada de contaminação..... | 79 |
| Figura 39 – Consequência do ensaio sobre a camada de contaminação..... | 79 |
| Figura 40 – PicoScope modelo 2206B e sua conexão a um computador pessoal..... | 80 |
| Figura 41 – Exemplo de um sinal contendo descargas parciais e seu respectivo espectrograma..... | 82 |

| | |
|---|-----|
| Figura 42 – Fluxograma dos algoritmos desenvolvidos..... | 84 |
| Figura 43 – Grau de severidade em função da umidade para o caso da camada sólida correspondente à poluição para o mês de outubro..... | 98 |
| Figura 44 – Comparação do valor do grau de severidade para três períodos de poluição. | 100 |
| Figura 45 – Comparação do valor do grau de severidade para dois períodos de poluição. ... | 100 |
| Figura 46 – Forma de onda relativa à atividade mais severa de descargas parciais na Forquilha. | 102 |
| Figura 47 – Funções de pertinência ativadas por cada um dos parâmetros: (a) número de pulsos; (b) taxa de repetição de pulsos; (c) entropia dos pulsos; (d) métrica da severidade. | 103 |
| Figura 48 – Funções de pertinência ativadas pelas regras de inferência. | 103 |
| Figura 49 – Forma de onda relativa à atividade intermediária de descargas parciais na Forquilha. | 104 |
| Figura 50 – Funções de pertinência ativadas por cada um dos parâmetros: (a) número de pulsos; (b) taxa de repetição de pulsos; (c) entropia dos pulsos; (d) métrica da severidade. | 105 |
| Figura 51 – Funções de pertinência ativadas pelas regras de inferência. | 105 |
| Figura 52 – Forma de onda relativa à atividade menos severa de descargas parciais na Forquilha. | 106 |
| Figura 53 – Funções de pertinência ativadas por cada um dos parâmetros: (a) número de pulsos; (b) taxa de repetição de pulsos; (c) entropia dos pulsos; (d) métrica da severidade. | 106 |
| Figura 54 – Funções de pertinência ativadas pelas regras de inferência. | 107 |
| Figura 55 – Forma de onda relativa à atividade de descargas parciais na Subestação Itajubá 3 (janela de 50 ms)..... | 118 |
| Figura 56 – Forma de onda relativa à atividade de descargas parciais na Subestação Itajubá 3 (janela de 1 ms)..... | 118 |
| Figura 57 – Forma de onda relativa ao uso do centelhador com um <i>gap</i> de 1 mm..... | 119 |
| Figura 58 – Forma de onda relativa ao uso do centelhador com um <i>gap</i> de 5 mm..... | 119 |
| Figura 59 – Forma de onda relativa ao ensaio de poluição artificial pelo método da névoa salina. | 120 |
| Figura 60 – Forma de onda relativa ao ensaio de poluição artificial pelo método da névoa salina (detalhe). | 120 |
| Figura 61 – Forma de onda relativa ao ensaio de poluição artificial pelo método da camada sólida (jul.-out.). | 121 |
| Figura 62 – Forma de onda relativa ao ensaio de poluição artificial pelo método da camada sólida (out.). | 122 |
| Figura 63 – Forma de onda relativa ao ensaio de poluição artificial pelo método da camada sólida (50% out.). | 122 |

LISTA DE QUADROS

| | |
|--|----|
| Quadro 1 – Sumário do modelo da rede neural implementada | 88 |
| Quadro 2 – Conjunto de regras de inferência utilizados pelo sistema <i>fuzzy</i> | 97 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 – Dados climáticos para a cidade de São Luís do Maranhão | 68 |
| Tabela 2 – Valores de referência do DDSE por período e da quantidade de sal utilizada | 74 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------|--|
| ABNT | Associação Brasileira de Normas Técnicas |
| AC | Corrente Alternada |
| AM | Amplitude Modulation |
| ANEEL | Agência Nacional de Energia Elétrica |
| ANFIS | Adaptive Neuro-Fuzzy Inference System |
| API | Application Programming Interface |
| ATH | Alumina Trihydrate |
| CNN | Convolutional Neural Network |
| ConvNet | Convolutional Neural Network |
| CPU | Central Processing Unit |
| CSS | Cascading Style Sheets |
| CSV | Comma-Separated Values |
| DC | Corrente Contínua |
| DCGAN | Deep Convolutional Generative Adversarial Network |
| DDS | Densidade do Depósito de Sal |
| DDSE | Densidade do Depósito de Sal Equivalente |
| DP | Descarga Parcial |
| EPDM | Ethylene-Propylene-Diene Monomer |
| EPM | Ethylene-Propylene Monomer |
| FIS | Fuzzy Inference System |
| GAN | Generative Adversarial Networks |
| GIS | Gas-Insulated Switchgear |
| GPU | Graphics Processing Unit |
| HFCT | High Frequency Current Transformer |
| HTML | Hypertext Markup Language |
| IEC | International Electrotechnical Commission |
| IEEE | Institute of Electrical and Electronics Engineers |
| INMET | Instituto Nacional de Meteorologia |
| LAT-EFEI | Laboratório de Alta Tensão Manuel Luís Barreira Martinez |
| MLP | Multilayer Perceptron |
| NBR | Norma Brasileira |
| P&D | Pesquisa e Desenvolvimento |
| PDF | Portable Document Format |
| PNG | Portable Network Graphics |
| PRPD | Phase-Resolved Partial Discharge |
| ReLU | Rectified Linear Unit |
| RIV | Radio Interference Voltage |
| RNA | Rede Neural Artificial |
| RNN | Recurrent Neural Network |
| STFT | Short-Term Fourier Transform |
| SVM | Support Vector Machine |
| TSAD | Time-Sequence-Analysis-Discharge |
| UHF | Ultra High Frequency |
| USB | Universal Serial Bus |

SUMÁRIO

| | |
|--|------------|
| CAPÍTULO 1 – INTRODUÇÃO | 12 |
| 1.1 MOTIVAÇÃO | 12 |
| 1.2 OBJETIVOS | 15 |
| 1.3 MATERIAIS E MÉTODOS | 16 |
| 1.4 ORGANIZAÇÃO DA DISSERTAÇÃO | 17 |
| CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA..... | 19 |
| 2.1 ISOLADORES DE ALTA TENSÃO | 19 |
| 2.1.1 Modos de falha..... | 22 |
| 2.2 DESCARGAS PARCIAIS | 24 |
| 2.2.1 Definições e mecanismos..... | 25 |
| 2.2.2 Métodos de detecção de descargas parciais | 29 |
| 2.3 REDES NEURAIS ARTIFICIAIS | 32 |
| 2.3.1 Redes convolucionais | 32 |
| 2.3.2 Redes adversárias generativas | 35 |
| 2.3.3 Aplicações de cada arquitetura..... | 39 |
| CAPÍTULO 3 – REVISÃO BIBLIOGRÁFICA..... | 41 |
| 3.1 DISCUSSÃO | 47 |
| CAPÍTULO 4 – METODOLOGIA | 49 |
| 4.1 ENSAIOS EM CAMPO | 50 |
| 4.2 ENSAIO PADRONIZADO PARA MEDIÇÃO DA CARGA APARENTE DE DESCARGAS PARCIAIS | 59 |
| 4.3 ENSAIO NÃO PADRONIZADO UTILIZANDO UM CENTELHADOR..... | 64 |
| 4.4 ENSAIOS PADRONIZADOS DE CHUVA E DE POLUIÇÃO ARTIFICIAL..... | 66 |
| 4.5 AQUISIÇÃO E ANÁLISE DE SINAIS DE DESCARGAS PARCIAIS | 80 |
| CAPÍTULO 5 – DESENVOLVIMENTO DOS ALGORITMOS | 83 |
| 5.1 AQUISIÇÃO DE DADOS | 84 |
| 5.2 ANÁLISE DOS DADOS..... | 85 |
| CAPÍTULO 6 – RESULTADOS..... | 98 |
| CAPÍTULO 7 – CONSIDERAÇÃO FINAIS | 108 |
| 7.1 COMENTÁRIOS FINAIS..... | 108 |
| 7.2 CONCLUSÕES | 109 |
| REFERÊNCIAS BIBLIOGRÁFICAS | 112 |
| APÊNDICE A – FORMAS DE ONDA DE SINAIS DE DESCARGAS PARCIAIS | 118 |

CAPÍTULO 1 – INTRODUÇÃO

1.1 MOTIVAÇÃO

Os isoladores em operação estão sujeitos a toda a sorte de poluição atmosférica, desde poeira e sal, até pesticidas e fertilizantes utilizados na zona rural. Sob condições de alta umidade relativa atmosférica, a poluição superficial e a umidade superficial formam juntas uma camada condutiva que provoca um aumento da corrente elétrica ao longo da superfície do isolador. Esta corrente provoca então o aumento da temperatura da umidade superficial, levando à sua evaporação e à formação de bandas secas, que causam a interrupção do fluxo das cargas elétricas ou o estreitamento do seu caminho de condução.

Sobre as bandas secas, passa-se a observar então um gradiente elevado de tensão, formando uma região de concentração de campo elétrico, que intensifica a evaporação, aumentando a largura das bandas. A alta concentração de campo elétrico cria arcos e pode levar a uma descarga disruptiva (*flashover*¹) em casos extremos. Os arcos observados são descargas parciais superficiais², que causam uma série de fenômenos físicos e químicos, como interferências de radiofrequência, emissões de ultrassom e de ruído audível, emissões de radiação ultravioleta e luz visível, aquecimento e reações químicas que podem resultar em subprodutos tóxicos e corrosivos, que levam ao envelhecimento da superfície do isolador e à degradação da ferragem das cadeias de isoladores.

A precipitação de chuva é um dos fatores que auxiliam a lavar naturalmente a superfície dos isoladores, de forma que, ao longo do período da seca, as concessionárias enfrentam uma série de eventos de falta devido ao acúmulo de poluição. Especialmente em regiões litorâneas, onde os isoladores apresentam uma forte deposição de sal devido à maresia, as concessionárias realizam procedimentos de lavagem de estruturas críticas durante os meses de menor precipitação, como forma de prevenir eventos de *flashover*, uma vez que a umidade relativa permanece alta por causa do oceano. Em algumas estruturas, a severidade exige que estas lavagens sejam realizadas em uma frequência semanal.

¹ O termo *flashover* é amplamente utilizado na língua portuguesa para se referir às descargas disruptivas ao longo de um isolador.

² As descargas superficiais são consideradas pela maioria dos estudos como um tipo de descarga parcial (DP), juntamente com descargas do tipo interna e corona. Contudo, alguns estudiosos consideram apenas as descargas internas ao dielétrico como descargas parciais. Por questões de definição de nomenclatura, este trabalho irá considerar as descargas superficiais como descargas parciais.

Em cidades do interior do país, onde a baixa precipitação vem acompanhada de baixa umidade relativa atmosférica, chuvas fracas, garoa ou orvalho, após longos períodos sem chuva, são suficientes para desencadear o processo de descargas parciais superficiais em isoladores poluídos. Alguns isoladores chegam a se romper durante tais eventos, fazendo com que seja observado, por parte das concessionárias, um aumento da aquisição de novas unidades de isoladores e das rotinas de manutenção corretiva. O que ocorre, frequentemente, é que cadeias inteiras de isoladores são simplesmente substituídas sem uma descrição ou um relatório aprofundado sobre os motivos da substituição, e sem o agendamento de manutenções preventivas.

As descargas parciais podem ser medidas por meio de diversos sensores e transdutores, porém, mais comumente, por meio da detecção ruídos de radiofrequência, detecção de ruídos acústicos na faixa de ultrassom ou através de métodos elétricos de ensaio em laboratório. Os ensaios elétricos podem ser conduzidos em laboratório com o isolador fora de operação, seguindo normas específicas.

Os isoladores em operação, por sua vez, podem ser inspecionados, em busca de descargas parciais, por meio de, por exemplo, um transformador de corrente de alta frequência (HFCT, do inglês: *high frequency current transformer*). O uso do HFCT consiste em se passar o condutor de aterramento do isolador através da sua janela de medição. Isto também pode ser realizado diretamente no pé da torre, mas, neste caso, a medição irá compreender sinais oriundos de todos os isoladores da estrutura inspecionada. O sensor irá então permitir a aquisição do conteúdo de descargas parciais presente na corrente de fuga do isolador.

A medição utilizando o HFCT se trata de um método invasivo. Métodos não invasivos amplamente utilizados pelas concessionárias incluem a medição da emissão de radiofrequência por meio de antenas específicas e da emissão de ultrassom por meio do efeito piezoelétrico ou de transdutores capacitivos.

Os sinais de descargas parciais apresentam padrões específicos de acordo com a sua origem, severidade e magnitude. Usualmente, a maneira mais comum de se representar a atividade das descargas parciais é por meio da análise com resolução de fase (PRPD, do inglês: *phase-resolved partial discharge*), que exhibe os pulsos das descargas acompanhados de suas magnitudes e ângulos de fase, referenciados a um ciclo da frequência fundamental da tensão de ensaio, podendo ser exibidos em uma base de tempo linear, senoidal ou elíptica.

Uma vez que os padrões de descargas são bons indicadores da sua origem e severidade, eles podem ser utilizados na avaliação da condição de isoladores de forma a se prevenir eventos de falha que possam levar a faltas no sistema elétrico de potência. Algoritmos de aprendizado

de máquina, ramo da inteligência artificial, são especialistas em reconhecimento de padrões, sendo capazes de realizar tarefas de regressão e de classificação baseados em um conjunto de treinamento composto por dados rotulados. Portanto, um sensor aliado a um sistema dotado de um algoritmo de aprendizado de máquina e algoritmos de análise de dados podem ser utilizados para apresentar um diagnóstico da condição de um isolador, tanto com respeito à poluição quanto à degradação.

Os modelos de redes neurais artificiais (RNAs) são ferramentas de aprendizado de máquina capazes de aprender tarefas, baseadas em um treinamento supervisionado. O *perceptron* de múltiplas camadas (MLP, do inglês: *multilayer perceptron*) é a forma mais básica de uma rede do tipo *feedforward*, isto é, os dados percorrem a rede em apenas um sentido, sempre adiante. Nos últimos anos, contudo, as redes convolucionais (ConvNets, do inglês: *convolutional networks*) têm sido utilizadas para tarefas de visão computacional e reconhecimento de imagens, sendo assim chamadas devido à sua capacidade de realizar a convolução de filtros sobre os dados de entrada.

Uma das mais importantes características das ConvNets é a sua capacidade de compartilhamento de pesos sinápticos, reduzindo o número de parâmetros treináveis em comparação com o modelo MLP, que, por sua vez, possui seus neurônios densamente conectados, através de pesos sinápticos, a todos os neurônios das camadas adjacentes. As ConvNets são também invariantes à posição dos dados, o que significa que seu desempenho não é afetado pela translação dos eixos dos dados de entrada, sendo capazes de reconhecer padrões baseadas na posição relativa destes, ao invés da posição absoluta.

Com o objetivo de desenvolver um sistema de detecção e classificação do grau de severidade de descargas parciais em cadeias de isoladores, foi proposto um projeto do Programa de Pesquisa & Desenvolvimento (P&D) da Agência Nacional de Energia Elétrica (ANEEL), no qual se insere o estudo apresentado nesta dissertação. O projeto foi financiado pelo Grupo Equatorial Energia, tendo, como caso de estudo, o sistema de transmissão de 69 kV da cidade de São Luís, capital do Maranhão³. O projeto foi desenvolvido, em conjunto, pelo Laboratório de Alta Tensão da Universidade Federal de Itajubá (LAT-EFEI) e pela HVEX, empresa do setor elétrico sediada em Itajubá-MG com atuação na fabricação de equipamentos para laboratório de alta tensão e no desenvolvimento de projetos de P&D.

³ O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e é parte do Programa de Pesquisa & Desenvolvimento (P&D) da Agência Nacional de Energia Elétrica (ANEEL), código do projeto PD-00371-0036/2018, financiado pela Equatorial Energia.

O objetivo do projeto de P&D mencionado é um sistema *software-hardware* compacto e portátil e um sensor para a detecção de interferências eletromagnéticas de radiofrequência para serem utilizados em campo, contendo uma interface de usuário e um sistema de aquisição e análise de dados, dotado de ferramentas de inteligência artificial. A função do equipamento é realizar a inspeção de estruturas de transmissão, visando os isoladores de alta tensão e a sua atividade de descargas parciais, que está diretamente ligada ao seu estado de degradação e à condição de poluição superficial. Desta forma, a concessionária irá dispor de uma ferramenta de apoio à decisão e será capaz de inspecionar estruturas e programar as manutenções pertinentes, visando evitar a evolução de defeitos, as falhas e as consequentes interrupções no fornecimento de energia elétrica.

O projeto contou com uma equipe atuando em diversas vertentes nas áreas de elétrica, eletrônica, ciência da computação e mecânica. O presente trabalho relata o desenvolvimento dos algoritmos de inteligência artificial, aquisição de dados, processamento de sinais e cálculo de um parâmetro de diagnóstico, e a realização de parte dos ensaios de isoladores de alta tensão, com o objetivo de se avaliar e selecionar um sensor adequado para a detecção de descargas parciais e de se formar um conjunto de dados de sinais de descargas parciais.

1.2 OBJETIVOS

Esta dissertação apresenta o desenvolvimento e os resultados de um estudo baseado em sinais de descargas parciais coletados em ensaios em campo e em laboratório. O objetivo do estudo é o desenvolvimento de um algoritmo completo, desde a aquisição dos sinais até a obtenção de um grau de severidade da atividade de descargas parciais nos isoladores. Este algoritmo irá compor o equipamento desenvolvido pelo P&D, fornecendo a ele sua principal funcionalidade.

Tendo em vista o equipamento desenvolvido durante o P&D, o algoritmo deve, primeiramente, prever um módulo de aquisição de sinais, contemplando as configurações necessárias para que os sinais de descargas parciais sejam coletados com resoluções de tempo e magnitude adequados para futura análise. Além disso, o algoritmo deve prever um módulo de filtragem dos sinais coletados, contemplando a seleção da faixa desejada de frequências e a eliminação ou redução dos ruídos indesejados.

Uma vez que o sinal tenha sido pré-processado, o algoritmo deve realizar a sua classificação binária por meio de uma rede convolucional. Esta classificação envolve designar sinais contendo ruídos aleatórios, sinais de telecomunicações e demais sinais que não

contenham pulsos de descargas parciais, a uma classe 0. Além disso, também devem ser designados à classe 0, sinais que contenham pulsos de descargas parciais oriundos de ambientes com diversas fontes de ruídos, onde não é possível que estas fontes sejam distinguidas de forma clara, como ocorre em subestações, por exemplo. São designados à classe 1, todos os sinais que apresentem pulsos de descargas parciais que se deseja analisar com o objetivo de se obter o grau de severidade. Apenas os sinais designados à classe 1 devem ser analisados na etapa seguinte.

Em seguida, o algoritmo deve identificar os pulsos de descargas contidos no sinal classificado e, a partir deles, realizar o cálculo de parâmetros representativos da intensidade da atividade de descargas parciais. O grau de severidade propriamente dito deve ser obtido por meio de um sistema de inferência *fuzzy*, que tenha como entradas os parâmetros calculados. O sistema então irá associar os conjuntos *fuzzy* ativados na entrada a conjuntos *fuzzy* de saída por meio de uma base de regras e do método de inferência Mamdani.

Além desses objetivos, que descrevem o que de fato será implementado, este trabalho também visa desenvolver estudos e contribuir para as áreas de descargas parciais e inteligência artificial. Isto é realizado através do estudo e de testes de diversas ferramentas de inteligência artificial e arquiteturas de redes neurais. Além disso, os conjuntos de dados e o estudo da severidade das descargas parciais são obtidos por meio de ensaios no laboratório de alta tensão e em campo.

1.3 MATERIAIS E MÉTODOS

As redes neurais artificiais para identificação e classificação dos sinais de descargas parciais foram implementadas utilizando-se o Keras, uma interface de programação (API) de alto nível para *deep learning*, escrito em linguagem de programação Python (CHOLLET, 2015), tendo o TensorFlow como *backend*⁴, uma biblioteca de código aberto para aprendizado de máquina, “originalmente desenvolvida por pesquisadores e engenheiros trabalhando no time do Google Brain dentro da organização *Machine Intelligence Research* do Google” (ABADI et al., 2015; TENSORFLOW, 2019). A API Keras é o *frontend*⁵ oficial do TensorFlow, com mais

⁴ Camada de acesso aos dados de uma aplicação. Neste caso, o Keras oferece uma interface com abstrações de alto nível, mas é um *backend* que realiza a manipulação dos tensores de dados envolvidos nas operações.

⁵ Camada de abstração, que fornece uma simplificação das funcionalidades disponibilizadas pelo *backend* de uma forma amigável para o usuário.

de 250 mil usuários individuais, segundo aponta uma pesquisa feita em meados de 2018 (KERAS, 2019).

A implementação dos códigos em linguagem Python foi feita por meio do Jupyter Notebook e do *kernel* IPython (KLUYVER et al., 2016; PÉREZ; GRANGER, 2007). O Python e o Jupyter foram instalados por meio da distribuição Anaconda, voltada para o aprendizado de máquina e ciência de dados, e para o gerenciamento de bibliotecas, dependências e ambientes virtuais (ANACONDA, 2016).

Os dados de descargas parciais foram obtidos por meio da realização de ensaios, a maior parte no Laboratório de Alta Tensão da Universidade Federal de Itajubá (LAT-EFEI). Diversos tipos de isoladores de alta tensão foram submetidos a ensaios baseados em diferentes normas e com diferentes objetivos. Os ensaios realizados empregaram, na maioria das vezes, fontes de alta tensão e câmaras de chuva e névoa. Eventualmente, o equipamento Haefely Hipotronics DDX-9121B *Partial Discharge and RIV Detector* foi utilizado para o ensaio normatizado para a medição da carga aparente das descargas. Os sinais foram coletados por meio de diferentes sensores através de osciloscópios de bancada e osciloscópios PicoScope para computador. Alguns isoladores e estruturas também foram inspecionados em ensaios de campo nos municípios de Itajubá e de Piranguinho (MG), Bragança Paulista (SP) e São Luís (MA), com o objetivo de se obter fontes diversificadas de dados para o desenvolvimento dos algoritmos.

1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

O presente capítulo deste trabalho apresenta um preâmbulo das principais ferramentas e metodologias empregadas, bem como as principais motivações e objetivos deste estudo.

O Capítulo 2 apresenta a fundamentação teórica dos principais tópicos abordados ao longo do desenvolvimento do estudo, a saber, redes neurais artificiais, isoladores de alta tensão e descargas parciais em isoladores.

O Capítulo 3 apresenta o estado da arte dos principais temas abordados por este trabalho, a saber, os métodos de detecção de descargas parciais em isoladores e a aplicação de redes neurais artificiais na detecção de falhas em equipamentos elétricos.

O Capítulo 4 apresenta as metodologias de ensaio utilizadas, tanto com relação aos procedimentos recomendados pelas normas pertinentes, quanto com relação aos ensaios realizados de fato, bem como os resultados parciais observados.

O Capítulo 5 apresenta o desenvolvimento dos algoritmos de aquisição e análise de dados, implementados em linguagem de programação Python.

O Capítulo 6 apresenta os resultados da aplicação dos algoritmos de análise aos sinais coletados em campo e em laboratório.

O Capítulo 7 encerra este trabalho apresentando as principais conclusões, contribuições acadêmicas e as possibilidades de trabalhos futuros.

CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA

2.1 ISOLADORES DE ALTA TENSÃO

Os isoladores de alta tensão em linhas aéreas de transmissão e distribuição têm como objetivo fornecer suporte físico, resistência mecânica e resistência elétrica para condutores de alta tensão. Idealmente, isoladores são elementos não condutivos⁶, entretanto, durante a operação, a superfície dos isoladores se torna contaminada pela poluição presente na localidade onde está instalado, levando à formação de uma camada condutiva e ao aparecimento de uma corrente de fuga.

Esta poluição pode tanto ter origem natural quanto ser provocada pelo homem; por exemplo, sal do oceano em cidades costeiras, pesticidas e fertilizantes em áreas rurais, areia e poeira de regiões desérticas, cinzas de origem vulcânica, de incêndios e queimadas, fumaça de veículos e cidades densamente povoadas, fumaça, poeira e substâncias químicas de indústrias e atividades de mineração e, até mesmo, excrementos de aves (HADIPOUR; SHIRAN, 2017; RAMOS HERNANZ et al., 2006). A camada condutiva se comporta como um resistor não linear, causando aquecimento, reações químicas e descargas elétricas.

Além disso, devido aos estilhaços arremessados quando se quebram, os isoladores de vidro, principalmente, costumam ser alvos de vandalismo, sendo frequentemente atingidos, propositalmente, por objetos contundentes e disparos de armas de fogo. Em uma cadeia de isoladores, por exemplo, descargas elétricas podem surgir tanto na unidade alvo de vandalismo, quanto nas demais unidades, devido à sobretensão sobre elas, causada pela ausência da unidade atingida. A evolução destes fenômenos de descargas leva à degradação do isolador na forma de erosão da superfície, podendo evoluir para fenômenos mais graves, como eventos de *flashover* (LOOMS, 1988).

Três grandezas construtivas dos isoladores devem ser definidas aqui: as distâncias de arco, de escoamento e de perfuração. Segundo a norma brasileira ABNT NBR 5472:2012 (ABNT, 2012), a distância de arco (a seco) consiste na menor distância no ar entre as terminações do isolador, ou seja, no comprimento do caminho teórico que um arco elétrico irá percorrer em um evento de *flashover*. A distância de escoamento, por sua vez, consiste na menor distância, ou soma das menores distâncias, ao longo da superfície externa do dielétrico do isolador, entre as suas terminações, ou seja, no comprimento do caminho teórico que uma

⁶ Este é o cenário ideal. Contudo, isoladores reais apresentam uma parcela resistiva que faz com que exista uma corrente de fuga de baixíssima magnitude (da ordem de microampères), mesmo em isoladores novos e limpos.

corrente de fuga irá percorrer ao longo da superfície do isolador entre o potencial de fase e o potencial de terra. Estas duas distâncias são destacadas na Figura 1. Finalmente, a distância de perfuração consiste na distância percorrida por uma descarga disruptiva através do dielétrico.




Figura 1 – Distâncias de interesse do isolador: escoamento (vermelho) e arco (azul).
Fonte: Adaptado de Jahangiri et al. (2020)

A norma brasileira ABNT NBR 5032:2014 (ABNT, 2014), destinada a isoladores de porcelana e vidro para sistemas de corrente alternada para linhas aéreas acima com tensões acima de 1000 V, divide estes isoladores em duas classes:

- Classe A: isolador cuja menor distância de perfuração é igual ou maior que a metade da distância de descarga a seco;
- Classe B: isolador cuja menor distância de perfuração é inferior à metade da distância de descarga a seco.

Além disso, esta norma define quatro tipos de isoladores:

- Isoladores tipo pino;
- Isoladores tipo pilar;
- Isoladores para cadeia, subdivididos em tipo disco e tipo bastão;
- Isoladores para sistemas de tração elétrica⁷.

Segundo Looms (1988), “os três principais materiais que compõem qualquer isolador são o dielétrico, as terminações que acoplam o dielétrico à estrutura mecânica e os intermediários, tais como cimento, lubrificantes e tintas” (LOOMS, 1988, p. 10, tradução nossa). De uma forma ampla, os isoladores podem ser classificados com respeito ao material utilizado na composição do seu dielétrico, podendo ser materiais cerâmicos ou compostos.

Os materiais cerâmicos compreendem as porcelanas e vidros temperados, enquanto os materiais compostos compreendem os compósitos de polímeros. A norma brasileira ABNT NBR 15643:2018 (ABNT, 2018) define as especificações de projeto de isoladores poliméricos

⁷ Isoladores tipo bastão ou tipo disco com ou sem adaptações especiais das ferragens (ABNT, 2014).

como os materiais do núcleo, do revestimento e processo de fabricação; projeto, material e método de fixação das ferragens integrantes; espessura da camada de revestimento sobre o núcleo; e o diâmetro do núcleo, no caso de isoladores compostos.

As ferragens devem ser confeccionadas em ferro fundido maleável ou nodular ou aço, protegidas contra corrosão por meio de zincagem por imersão a quente, quando aplicável. A montagem das ferragens no dielétrico deve possuir cimentação adequada e livre de irregularidades que possam comprometer o desempenho do isolador em operação (ABNT, 2014).

Os isoladores compostos são constituídos basicamente por dois materiais isolantes, sendo um para fornecer resistência elétrica e outro para fornecer resistência mecânica e elétrica, além das ferragens de fixação. O núcleo consiste em um bastão fabricado em um material composto feito de resina e fibra de vidro, cuja função é fornecer isolamento elétrico e suportar os esforços mecânicos exercidos pelos condutores de alta tensão e transferi-los para a estrutura através das ferragens, às quais ele é conectado por meio de diferentes interfaces.

O revestimento (invólucro) do isolador é constituído de uma borracha polimérica, mais comumente silicone, copolímero de etileno e propileno (EPM) ou borracha de etileno propileno terpolímero (EPDM), e é formado por uma camisa (bainha) dotada de saias (ou aletas), com o objetivo de proteger o núcleo da ação do clima, aumentar a distância de escoamento do isolador e fornecer um caminho não contínuo para o escoamento de água.

O silicone tem ampla aplicação devido à sua estabilidade frente a diversas condições climáticas e à sua hidrofobicidade, que faz com que a água não se disperse sobre a superfície do isolador, mas, ao invés disto, forme gotículas concentradas, fazendo com que a corrente de fuga em isoladores poluídos feitos deste material apresentem um valor inferior ao apresentado por isoladores cerâmicos, de vidro ou de outras borrachas (SHARMA, 2020; TAHERIAN, 2019).

Os isoladores compostos são comumente chamados de isoladores poliméricos quando o corpo isolante consiste em pelo menos um material polimérico. Além disso, isoladores compostos com núcleo de porcelana ou vidro, ao invés de fibra de vidro, são denominados isoladores híbridos (ABNT, 2012).

O uso de isoladores compostos aumentou significativamente nas últimas décadas, devido ao seu baixo custo, ao seu menor peso, às características químicas, mecânicas e elétricas descritas, e ao seu bom desempenho em ambientes poluídos. No entanto, a qualidade da fabricação dos isoladores compostos está diretamente relacionada ao seu desempenho em campo, visto que cavidades remanescentes entre o núcleo e o revestimento polimérico são

fontes de defeitos como descargas parciais e exposição do núcleo a umidade e a fatores climáticos.

Além disso, alguns polímeros utilizados na fabricação dos isoladores possuem em sua composição alumina tri-hidratada (ATH), com a função de evitar a degradação carbonácea por trilhamento. Entretanto, com a exposição à radiação ultravioleta ou centelhamento, a ATH sofre uma degradação, resultando em um pó que se acumula sobre a superfície do isolador, afetando o seu nível de *flashover*. As borrachas de silicone, embora também empreguem a ATH, contam com a hidrofobicidade para reduzir a corrente de fuga (SHARMA, 2020; TAHERIAN, 2019).

2.1.1 Modos de falha

Os isoladores em operação estão sujeitos, basicamente, a esforços mecânicos e elétricos que afetam em maior ou menor grau sua integridade e sua vida útil. Capelini (2015) destaca estes esforços e suas causas para isoladores cerâmicos, mas que se aplicam igualmente para os isoladores compostos estudados neste trabalho. Dentre os esforços mecânicos sobre os isoladores, pode-se destacar:

- Esforços verticais: oriundos da sustentação do seu próprio peso e do peso dos condutores, além do acúmulo de neve e gelo em regiões frias;
- Esforços horizontais: oriundos da tração exercida pelos condutores, com direção longitudinal à linha de transmissão;
- Esforços horizontais transversais: oriundos da ação do vento ortogonal aos condutores.

Dentre os esforços elétricos sobre os isoladores, pode-se destacar:

- Tensão nominal de operação;
- Sobretensões em frequência industrial;
- Sobretensões de manobra;
- Sobretensões atmosféricas.

Segundo a norma brasileira ABNT NBR 15643:2018 (ABNT, 2018), as condições ambientais normais a serem levadas em consideração no projeto de um isolador polimérico, são a temperatura máxima do ar ambiente, a temperatura mínima do ar ambiente, vibração, radiação solar, poluição do ar ambiente e umidade. Sobre os demais fatores ambientais que afetam a especificação de isoladores a serem instalados em uma linha de transmissão, Capelini (2015)

cita a precipitação de chuva e de neve, além do acúmulo de gelo, circulação do ar, salinidade do ar e excrementos de aves, além dos atos de vandalismo nas periferias das cidades e áreas rurais.

A qualidade da fabricação dos isoladores e suas condições de operação são fatores que influenciam a tanto a sua suportabilidade em campo quanto a homogeneidade do campo elétrico ao seu redor. A diminuição da sua suportabilidade está ligada a eventos de *flashover* e de aumento da corrente de fuga. A irregularidade do campo elétrico está ligada ao fenômeno de descargas parciais, que também são capazes de evoluir para eventos de *flashover*. As descargas parciais presentes nos isoladores provocam uma série de problemas para os mesmos e para as linhas de transmissão, como:

- Emissão de ondas eletromagnéticas:
 - de radiofrequência;
 - do espectro infravermelho;
 - do espectro visível;
 - do espectro ultravioleta;
- Emissão de ondas mecânicas:
 - na faixa audível;
 - na faixa de ultrassom;
- Reações químicas com subprodutos corrosivos para as ferragens e para a superfície dos isoladores, causando:
 - degradação das superfícies;
 - perda da hidrofobicidade em materiais poliméricos;
 - erosão das ferragens e do isolador;
- Perdas nas linhas de transmissão da ordem de centenas de kW/km.

Tomando como exemplo a rede elétrica da cidade de São Luís (MA), a partir da qual foram obtidos dados para o desenvolvimento deste trabalho, o principal fator que afeta os isoladores é a poluição depositada na sua superfície, com destaque para o sal proveniente das correntes de ar do oceano e o pó de minério da região do Porto do Itaqui. A deposição destes poluentes por si só não afeta o desempenho do isolador. Esta camada se torna crítica apenas quando estes poluentes se associam à umidade relativa do ar, que, no caso de São Luís, costuma ser elevada ao longo de todo o ano.

A associação da umidade com sais solúveis ou ácidos forma uma camada condutiva, aumentando a parcela resistiva do isolador e, conseqüentemente, a corrente de fuga. Esta relação entre contaminação superficial, umidade relativa do ar, umidade absorvida e corrente de fuga afeta diretamente a suportabilidade do isolador, diminuindo a tensão de *flashover* com o aumento destes fatores.

O aumento da corrente de fuga provoca o aquecimento da umidade absorvida pela camada superficial do isolador, fazendo com que esta umidade evapore, formando regiões úmidas intercaladas com regiões secas, denominadas bandas secas. O campo elétrico sobre uma banda seca possui valor elevado devido ao valor da tensão aplicada sobre uma distância reduzida, e a distorção do campo desencadeia o processo de descargas parciais.

Uma representação da camada de contaminação e das descargas sobre uma banda seca é mostrada na Figura 2. Uma sucessão de descargas sustentadas sobre a superfície do isolador pode facilmente evoluir para um *flashover*. Além do caso da poluição superficial, a simples deposição de água sobre uma superfície com hidrofobicidade consideravelmente alta, como superfícies poliméricas novas, forma gotículas capazes de gerar descargas do tipo corona, dependendo do seu formato, através da deformação do campo elétrico ao seu redor.




Figura 2 – Formação das bandas secas.
Fonte: Adaptado de NGK Insulators (2020)

2.2 DESCARGAS PARCIAIS

As descargas parciais são um fenômeno que ocorre em aparatos e equipamentos de alta tensão, possuindo diferentes causas e origens, e provocando diferentes níveis de defeitos. A norma IEC 60270:2000 (IEC, 2015) se aplica a técnicas de ensaios de alta tensão para a medição de descargas parciais e define descarga parcial como:

Descarga elétrica localizada que apenas une parcialmente o isolante entre os condutores e que pode ou não ocorrer adjacente a um condutor. Descargas parciais são, em geral, uma consequência de concentrações de estresse elétrico locais no isolante ou na superfície do isolante (IEC, 2015, p. 8, tradução nossa).

De um modo geral, as descargas parciais podem ser classificadas em três tipos, com respeito à sua origem: internas, superficiais e externas, este último tipo também sendo conhecido como “corona” ou “efeito corona”. As descargas parciais do tipo internas ocorrem no interior do material dielétrico, originando-se a partir de bolhas e cavidades oriundas do processo de fabricação do mesmo, ou a partir de esforços de tração e vibração durante o transporte, instalação, manutenção e operação, podendo evoluir para cavidades maiores, arborescência e podendo levar à erosão do material dielétrico.

As descargas do tipo superficiais ocorrem ao longo da superfície do material devido à formação de bandas secas, poluição depositada e degradação da superfície, podendo causar trilhamento e carbonização do material da superfície. Com isto, elas podem intensificar a sua degradação, podendo causar sua erosão e levar a eventos de *flashover*.

As descargas do tipo corona são originárias da concentração do campo elétrico em extremidades agudas, ângulos agudos e superfícies afiadas de condutores de alta tensão, causando avalanches eletrônicas no meio gasoso circundante e exibindo luminescência, visível principalmente durante a noite, sendo o tipo menos severo de descarga parcial para o aparato de alta tensão.

2.2.1 Definições e mecanismos

Nos anos de 1990, o IEEE publicou, através da *Electrical Insulation Magazine*, uma série de artigos destinados a explorar os diversos aspectos da natureza das descargas parciais. Estes artigos discutem as definições que envolvem o fenômeno das descargas parciais e os mecanismos envolvidos na sua ocorrência. No primeiro artigo da série, Boggs (1990a) aborda os aspectos fundamentais das descargas parciais, enquanto os subsequentes passam a abordar casos mais específicos de ocorrência, juntamente com os métodos de detecção e medição.

As descargas parciais podem ocorrer em meios sólidos, líquidos e gasosos, e são originárias de uma alteração abrupta na configuração do campo elétrico, causando um fluxo de cargas no condutor ao qual o aparato com descargas parciais está conectado. Para ser considerada uma descarga parcial, esta corrente deve possuir amplitude e taxa de repetição suficientes para ser distinguida de ruído aleatório.

Entretanto, a carga envolvida no fenômeno no interior do aparato não é a mesma que se pode medir externamente, de forma que a grandeza medida externamente é dado o nome de magnitude efetiva de descarga parcial, ou, no caso da norma pertinente (IEC, 2015), carga

aparente. As fontes mais comuns de descargas parciais são componentes em flutuação, corona e cavidades.

O caso do componente em flutuação é um bom exemplo para ilustrar o mecanismo do fenômeno. Havendo uma peça metálica condutora em flutuação, isto é, sem conexão a um potencial definido, e estando esta peça metálica próxima a um condutor de alta tensão, se a diferença de potencial entre a peça e o condutor de alta tensão for suficientemente alta, ocorrerá uma descarga parcial de forma a equalizar o potencial entre eles.

O que ocorre é que a presença da peça provoca uma deformação no campo elétrico, a qual é maior do que em outros pontos do meio gasoso. Dada a natureza alternada da corrente na grande maioria dos sistemas de transmissão de energia elétrica, essa transferência de carga se torna recorrente em cada semiciclo da forma de onda da fundamental, apresentando diversas descargas por semiciclo a cada equalização de potencial.

A magnitude mensurável externamente varia de forma inversamente proporcional ao tamanho do sistema, sendo que um mesmo fenômeno interno ocorrendo em uma classe mais baixa de tensão irá produzir uma carga aparente mensurável muito maior do que aquela medida em uma classe mais alta de tensão (BOGGS, 1990a).

O efeito corona, por sua vez, é um tipo de descarga parcial que ocorre em meios gasosos a partir da ionização do ar causada por uma região de concentração do campo elétrico, como pontas e curvaturas de condutores em ângulos agudos, onde o campo não é homogêneo. Um processo de ruptura do meio gasoso é iniciado, entretanto, este não completa o canal de ruptura devido ao tamanho pequeno da região de estresse do campo elétrico ou devido à diminuição do valor do campo elétrico com a distância a partir do condutor de alta tensão.

De uma forma leiga, o efeito corona poderia ser definido como uma extensão do condutor, uma vez que consiste em uma região ionizada adjacente a este. O processo se inicia a partir de um elétron livre inserido em um campo elétrico não homogêneo, o qual é submetido a uma aceleração que faz com que se inicie uma avalanche eletrônica através da ionização de moléculas pelo impacto de elétrons livres.

Este fenômeno provoca uma variação da capacitância entre o condutor e o solo, e é observada uma queda na tensão do condutor, fazendo com que ocorra um fluxo de cargas entre a fonte de tensão e o condutor. Os íons positivos e negativos gerados por este processo se deslocam em direção aos eletrodos negativos e positivos, respetivamente, agindo como uma corrente elétrica real.

O efeito corona, portanto, consiste na geração de um sinal de descarga parcial externo ao sistema através de três passos: a ionização do canal (extensão do condutor), que aumenta a

capacitância entre o condutor e o solo; o deslocamento dos elétrons em direção ao eletrodo positivo; e o deslocamento dos íons positivos, que tende a ser mais lento e, portanto, não detectável pelos sistemas de medição. O fenômeno é repetitivo, uma vez que, depois de cessado o deslocamento das cargas, as condições necessárias para o início do fenômeno são reestabelecidas (BOGGS, 1990a; TRINH, 1995).

As descargas em cavidades, por sua vez, são, na maioria das vezes, o objetivo de análises mais detalhadas de aparatos e equipamentos de alta tensão, uma vez que, diferentemente do efeito corona, a detecção pelo método acústico pode ser mais difícil e a detecção pelo método óptico não é possível. Havendo uma cavidade inserida em um dielétrico posicionado entre dois eletrodos energizados em corrente alternada, haverá um campo elétrico presente no interior da cavidade.

Se a tensão for suficientemente alta, o campo elétrico gerado no seu interior irá provocar um processo de ionização, que pode fazer com que um elétron livre no interior da cavidade desencadeie um processo de ruptura do gás confinado dentro dela, fazendo com que a carga elétrica se distribua de forma a cancelar o campo elétrico no seu interior. O mecanismo deste tipo de descarga é muito semelhante ao caso do componente em flutuação, até mesmo do ponto de vista do padrão de pulsos obtido a partir de cada caso. Entretanto, descargas em cavidades possuem uma amplitude muito inferior e são muito menos previsíveis, uma vez que diversos aspectos da cavidade influenciam no comportamento das descargas (BOGGS, 1990a).

As descargas em cavidades evoluem gradualmente, provocando a formação de túbulos pelo impacto dos elétrons no material dielétrico. Estes túbulos podem ainda evoluir para ramificações distribuídas pelo interior do material dielétrico, assumindo uma aparência arbórea, caracterizando o fenômeno da arborescência em dielétricos sólidos, que pode ser desencadeado por uma série de fatores além das cavidades internas, como estresse mecânico.

A arborescência consiste no crescimento de túbulos dendríticos que evoluem em um período de algumas horas até alguns anos, formando um padrão semelhante às ramificações de uma árvore, que podem atravessar o dielétrico, causando sua falha. A análise do comportamento das descargas parciais no interior destes túbulos e a forma como pulsos externos de corrente ocorrem nos condutores segue o mesmo princípio das descargas em cavidades.

Este fenômeno pode ser observado também em dielétricos líquidos, porém com uma taxa muito superior de crescimento dos dendritos, sendo considerado um tipo de corona, dada a natureza fluida do líquido, a qual proporciona a autorrecuperação deste, impedindo danos permanentes ou estacionários (BOGGS, 1990a).

No caso de isoladores poliméricos, as descargas parciais no ar produzem substâncias, a partir do oxigênio e do nitrogênio, que são oxidantes (O_3 e NO_2) capazes de danificar cadeias poliméricas. Neste processo, as cadeias de carbono são quebradas, produzindo ácidos corrosivos para a fibra de vidro, danificando assim o núcleo do isolador (CHERNEY, 1991).

O mecanismo de formação das descargas parciais superficiais por bandas secas, devido à deposição de poluição, foi discutido na Seção 2.1.1 e se trata do principal interesse deste estudo, visto que se trata do tipo mais frequente e mais prejudicial de descarga no caso de estudo de São Luís.

Tomando-se como exemplo uma descarga parcial do tipo interna, ocorrendo em uma cavidade no dielétrico, pode-se representar este fenômeno através do modelo ABC (BOGGS, 1990b) das capacitâncias envolvidas, sendo estas definidas ao longo das linhas paralelas longitudinais ao eixo formado pelos eletrodos do corpo de prova, conforme mostra a Figura 3(a).

Considerando-se a capacitância da cavidade, representada como C_C , posicionada em série com a capacitância entre a cavidade e os eletrodos, representada como C_B , tem-se este ramo em paralelo com a capacitância do restante do corpo de prova, representada como C_A . Desta forma, pode-se simplificar o modelo do corpo de prova através de um circuito composto pelas três capacitâncias ABC e um centelhador em série com um resistor e em paralelo com a capacitância da cavidade, conforme mostra a Figura 3(b).




Figura 3 – Representação de descargas parciais pelo modelo ABC: (a) capacitâncias distribuídas pelo corpo de prova; (b) circuito equivalente do fenômeno.

Fonte: Adaptado de Haefely (2014)

O problema deste modelo envolve a impossibilidade de se calcular a capacitância da cavidade, a qual é considerada como sendo esférica para estudos teóricos, mas que pode assumir diversos formatos não uniformes. A magnitude da descarga parcial quando o centelhador é disparado poderia ser calculada conhecendo-se os valores das capacitâncias envolvidas, entretanto, as capacitâncias da geometria do corpo de prova não podem ser calculadas, de forma que o valor da magnitude da descarga parcial não pode ser obtido.

Considerando-se ainda a cavidade esférica, o campo elétrico no seu interior é praticamente uniforme. Quando a tensão aplicada sobre a cavidade excede a tensão de ruptura do gás no seu interior, uma descarga pode ocorrer. Contudo, isto não necessariamente ocorre imediatamente após a tensão atingir o valor de ruptura, uma vez que a ocorrência da descarga depende da presença de um elétron livre no interior da cavidade.

No entanto, a partir do momento que um elétron livre estiver presente no interior da cavidade, este elétron será acelerado pelo campo elétrico e produzirá mais elétrons livres através de colisões com as moléculas do gás a uma taxa exponencial. Forma-se então um canal resistivo ao longo da cavidade através do qual ocorre a descarga, reduzindo o campo elétrico no interior da cavidade.

A queda no campo elétrico provoca a extinção do canal, fazendo com que as cargas elétricas remanescentes se desloquem para as paredes da cavidade, reduzindo ainda mais o valor do campo elétrico. Este comportamento do campo elétrico nulo é o mesmo para o caso de uma cavidade preenchida com um material condutor, o que, por sua vez, aumentaria a capacitância entre os eletrodos e provocaria uma queda na tensão entre os eletrodos da amostra (BOGGS, 1990b). A variação da tensão em função da variação da capacitância pode ser entendida pela equação (1):

$$\Delta V = \frac{Q}{\Delta C} \quad (1)$$

O fluxo de carga da fonte para os eletrodos de forma a manter a tensão sobre os eletrodos constante é a chamada carga aparente, que pode ser medida externamente e é utilizada como análise quantitativa da atividade de descargas parciais no interior de um corpo de prova. A carga aparente é influenciada por diversos fatores da geometria do corpo de prova e da cavidade (BOGGS, 1990b). Esta variação de carga pode ser entendida pela equação (2):

$$\Delta Q = V \Delta C \quad (2)$$

2.2.2 Métodos de detecção de descargas parciais

Segundo Stone (1991), as descargas parciais são tanto um sintoma quanto uma causa da deterioração dos dielétricos sólidos. A detecção de descargas parciais tornou-se, portanto, uma importante ferramenta de diagnóstico para o controle de qualidade, não apenas do ponto de vista da qualidade de fabricação, mas também da taxa de deterioração do equipamento em operação.

A maior parte dos ensaios de descargas parciais é realizada com o equipamento *offline* (fora de operação), em laboratório, com o auxílio de uma fonte de alta tensão. Os custos de se remover um equipamento de operação, entretanto, podem ser extremamente elevados, de forma que são muitos os incentivos para testes de diagnóstico em equipamentos *online* (em operação).

O grande problema das inspeções *online* são as falsas indicações de descargas parciais causadas por ruído, tornando-as, muitas vezes, ineficientes. Os ruídos podem possuir origem térmica ou externa. Contudo, ruídos externos tendem a ser muito mais prejudiciais à inspeção do que os ruídos térmicos. Dentre as fontes de ruído externo, estão descargas parciais de outros equipamentos, centelhamentos, chaveamentos e sinais de telecomunicações. De forma a se diferenciar os sinais de descargas parciais de outras fontes de ruído, é importante que se conheça o ângulo de fase de ocorrência das descargas em relação ao ciclo da fundamental, o seu espectro de frequências, magnitude e distribuição dos pulsos, polaridade, taxa de repetição e localização física (STONE, 1991).

Os pulsos de corrente causados pelas descargas parciais tendem a ocorrer nas faixas de 0° a 90° e de 180° a 270° da forma de onda da tensão, possuindo diferentes taxas de repetição. A curta duração dos pulsos resulta em componentes da ordem de centenas de mega-hertz no espectro de frequências. As componentes de altas frequências dos sinais de descargas parciais oriundos de fontes externas sofrem uma atenuação ao longo do percurso até o corpo de prova, permitindo que seja feita uma distinção entre os sinais com origem no corpo de prova e aqueles com origem externa.

Um dos métodos de distinção entre os pulsos de descargas parciais e o ruído é o uso de ferramentas de reconhecimento de padrões, como sistemas especialistas ou análises estatísticas dos padrões. Segundo Stone (1991), diversos métodos de diagnóstico em máquinas rotativas envolviam uma análise realizada por pessoal especializado e experiente em reconhecer os padrões exibidos pelos sistemas de medição.

O método de detecção por meio de radiofrequência originou-se da inspeção de turbinas de geradores por meio de transformadores de corrente de alta frequência conectados ao neutro do gerador, cujos sinais medidos são analisados por meio de um analisador de espectro. Outro método citado por Stone (1991) envolve o monitoramento constante da atividade de descargas parciais oriundas de equipamentos operando em atmosferas poluídas, onde, na presença de umidade, se observa o fenômeno de trilhamento da superfície do dielétrico.

O método utiliza uma antena de 500 kHz e um microfone ultrassônico de 40 kHz posicionados próximos ao isolamento. Os falsos positivos são minimizados através desta

redundância dos sensores, da proximidade dos sensores com o corpo de prova e do método de reconhecimento de padrões utilizado (STONE, 1991).

Entretanto, o que se observa é a grande preocupação com equipamentos de valor elevado, como máquinas elétricas, cabos e equipamentos de subestações. Os equipamentos de menor custo se apresentam distribuídos em uma grande área, tornando inviável a sua inspeção (STONE, 1991). Embora o caso de estudo de São Luís trate de isoladores de alta tensão, com custo relativamente baixo, ele envolve uma série de problemas ocasionados pela falha destes isoladores, os quais acarretam despesas e penalidades elevadas por interrupção do fornecimento de energia.

O principal método de detecção *offline* de descargas parciais é o elétrico, através do ensaio em laboratório normatizado pela IEC 60270:2000 (IEC, 2015). Além do método elétrico, a norma também prevê, através de um anexo informativo, os métodos acústico, óptico e químico, além da observação dos efeitos das descargas no corpo de prova, quando aplicável. Estes últimos métodos não são adequados para a medição quantitativa das descargas parciais, devendo ser utilizado, para este fim, o método elétrico. Contudo, estes métodos alternativos são úteis para inspeções *online*, possibilitando a detecção da presença de descargas parciais em uma estrutura ou dispositivo e até mesmo a coleta dos sinais das descargas, dependendo do método empregado, através de osciloscópios e placas de aquisição de dados.

O método acústico envolve o uso de microfones ou outros transdutores para a detecção de ruídos audíveis e/ou de ultrassom causados pelas descargas. Este método, quando utilizado de forma direcional por meio de refletores parabólicos, permite uma detecção altamente seletiva da fonte de emissão do ruído e, portanto, das descargas em si.

O método visual ou óptico pode ser feito em um ambiente escuro a olho nu ou com o auxílio de binóculos; alternativamente câmeras de longa exposição podem ser empregadas. Além da radiação emitida no espectro visível, as descargas parciais também emitem radiação na faixa ultravioleta, além de provocar aquecimento do dielétrico, de forma que as câmeras ultravioleta e infravermelho também possam ser empregadas.

As descargas parciais ainda provocam a decomposição de substâncias utilizadas no sistema de isolamento, tais como em equipamentos com isolamento a óleo ou a gás, de forma que a análise química destes subprodutos pode ser utilizada na avaliação da degradação causada pelas descargas parciais (IEC, 2015).

Além destes métodos, a norma ainda dedica um anexo ao uso de medidores de radiointerferência para a detecção das descargas. Para este fim, podem ser empregadas antenas e circuitos receptores adequados para a detecção destes tipos de sinais irradiados pelo

fenômeno; ou, quando possível, transformadores de corrente envolvendo os próprios cabos de alimentação ou condutores de aterramento, fazendo a leitura da corrente e todo o seu conteúdo, incluindo os pulsos de descargas parciais.

O método de medição por radiofrequência utilizando antenas não permite uma análise quantitativa do fenômeno, mas permite a coleta dos sinais, utilizando instrumentos adequados. O método de medição envolvendo o transformador de corrente, por sua vez, pode ser empregado para a análise quantitativa do fenômeno, permitindo inclusive o cálculo da carga aparente, quando respeitado o controle das condições de ensaio.

2.3 REDES NEURAIAS ARTIFICIAIS

2.3.1 Redes convolucionais

As redes neurais convolucionais (CNN, do inglês: *convolutional neural networks*), também conhecidas apenas como redes convolucionais (ConvNets), são um tipo de redes neurais do tipo *feedforward* cujas camadas implementam a convolução de filtros sobre os dados de entrada. A convolução consiste em se deslizar um filtro (ou *kernel*) sobre os dados, criando um mapa das características contidas nos dados.

Quando comparadas com o modelo MLP, as vantagens das ConvNets incluem os campos receptivos locais, o compartilhamento de pesos, as camadas de *pooling* (agrupamento), a invariância à translação dos dados, além de manterem a organização espacial dos dados de entrada. Isto frequentemente resulta em menos parâmetros treináveis, o que auxilia na prevenção do *overfitting*⁸ e diminui a complexidade do treinamento (FUKUSHIMA, 1980; LECUN et al., 1989; LECUN et al., 1999).

As ConvNets podem ter uma, duas ou três dimensões, dependendo do formato dos dados de entrada. Embora as palavras filtro e *kernel* sejam usadas de forma intercambiável no contexto das ConvNets, o termo *kernel* é mais utilizado para se referir à estrutura de pesos que realiza a convolução sobre os dados. Ou seja, dados unidimensionais serão filtrados por *kernels* unidimensionais, analogamente, dados bi- e tridimensionais serão filtrados, respectivamente, por *kernels* bi- e tridimensionais.

No entanto, quando múltiplos filtros são utilizados na mesma camada convolucional, o que é comum, os dados obtidos após a convolução possuem uma dimensão adicional. Por

⁸ Em português, sobreajuste, fenômeno em que o modelo memoriza o conjunto de dados, apresentando ótimo desempenho durante o treinamento, mas apresenta baixa capacidade de generalização sobre novos dados.

exemplo, se o dado de entrada é bidimensional, o *kernel* do filtro também será bidimensional, porém, se n filtros forem utilizados na convolução, então os mapas de características bidimensionais gerados por cada filtro serão empilhados, resultando em um dado contendo uma terceira dimensão de tamanho n , isto é, um volume de dados.

Na Figura 4(a), tem-se um dado de entrada com dimensões $32 \times 32 \times 3$, que poderia ser, por exemplo, uma imagem com resolução 32×32 e três canais de cores. Neste caso, deseja-se inspecionar, por meio de um filtro, seções do dado de entrada de dimensões 5×5 e, portanto, o filtro deve respeitar o número de canais, isto é, deve possuir dimensões $5 \times 5 \times 3$, como indicado, em vermelho, sobreposto sobre o dado de entrada.

A cada posição do filtro sobre o dado de entrada, é gerado um único elemento, sendo que a varredura total produz um mapa de características de dimensões $32 \times 32 \times 1$, como indicado em vermelho. Além disso, neste exemplo, são empregados dez filtros no total, isto é, são produzidos dez mapas de características, que são empilhados, resultando no volume de dados de $32 \times 32 \times 10$, como indicado em azul. A Figura 4(b) mostra dois filtros diferentes, um representado em vermelho e outro em verde, e a forma como o mapa de característica gerado por cada um deles compõe o dado de saída.




Figura 4 – Efeito do número de filtros sobre os dados

Fonte: Dertat (2017)

A subárea do dado de entrada sobre a qual o *kernel* realiza a convolução é chamada de campo receptivo, em comparação ao córtex visual biológico (FUKUSHIMA, 1980; HUBEL; WIESEL, 1962). Os valores do *kernel* são os pesos propriamente ditos, os quais são atualizados durante o processo de treinamento, sendo que o mesmo conjunto de pesos em um dado *kernel* é utilizado para realizar a convolução sobre todos os campos receptivos de um dado de entrada. Por esta razão, é dito que as ConvNets implementam o compartilhamento de pesos. Os *kernels* dos filtros são mais eficientes quando possuem dimensões de tamanho ímpar, de forma a realizarem a convolução centrados sobre cada elemento do dado de entrada.

Finalmente, as ConvNets implementam as camadas de *pooling* (agrupamento) após uma ou algumas camadas convolucionais. Em geral, é implementado o *maximum pooling* (*max pooling*), ou agrupamento pelo máximo valor, isto é, os dados são subamostrados através da seleção do máximo valor de cada campo receptivo (STANFORD, 2020). A Figura 5 mostra um conjunto de dados de dimensões 4×4 , que é subdividido em janelas de dimensões 2×2 , resultando em quatro subdivisões, indicadas pelas diferentes cores. A operação implementada pela camada de *pooling* pelo máximo valor consiste em simplesmente se selecionar o máximo valor presente dentro de cada uma das subdivisões, reduzindo, assim, o tamanho das dimensões do dado de entrada pela metade.




Figura 5 – Exemplo da ação da camada de *pooling* pelo valor máximo.
Fonte: Adaptado de Dertat (2017)

Além da camada de *pooling* e do número de filtros utilizados em cada camada convolucional, existem dois hiperparâmetros que afetam o formato dos dados através da rede convolucional. O tamanho do passo (número de elementos) com que um filtro se desloca ao longo do dado de entrada é definido pelo primeiro hiperparâmetro, chamado de *stride*, e afeta o tamanho das dimensões dos dados de saída, isto é, um *stride* igual a 1 irá resultar em um dado de saída com dimensões de mesmo tamanho das do dado de entrada, enquanto um *stride* igual a 2 irá resultar em uma redução pela metade do tamanho das dimensões nas quais ele for utilizado.

Quando é desejável se manter o tamanho das dimensões de saída igual ao das dimensões de entrada, pode-se também empregar um preenchimento com zeros nas bordas dos dados, chamado de *zero-padding*, o segundo hiperparâmetro, o qual permite que o filtro realize a convolução centrado sobre as extremidades dos dados, resultando em um processo de convolução aplicado a todos os elementos do dado de entrada (STANFORD, 2020).

A Figura 6 mostra três exemplos do efeito dos parâmetros *stride* e *zero-padding* sobre o tamanho das dimensões dos dados de entrada. A estrutura bidimensional de dados em azul representa a entrada, sendo que a área sombreada representa o campo receptivo sobre o qual o *kernel* do filtro está posicionado. Isto é, o filtro possui dimensões 3×3 . A estrutura bidimensional de dados em verde representa a saída após a convolução.

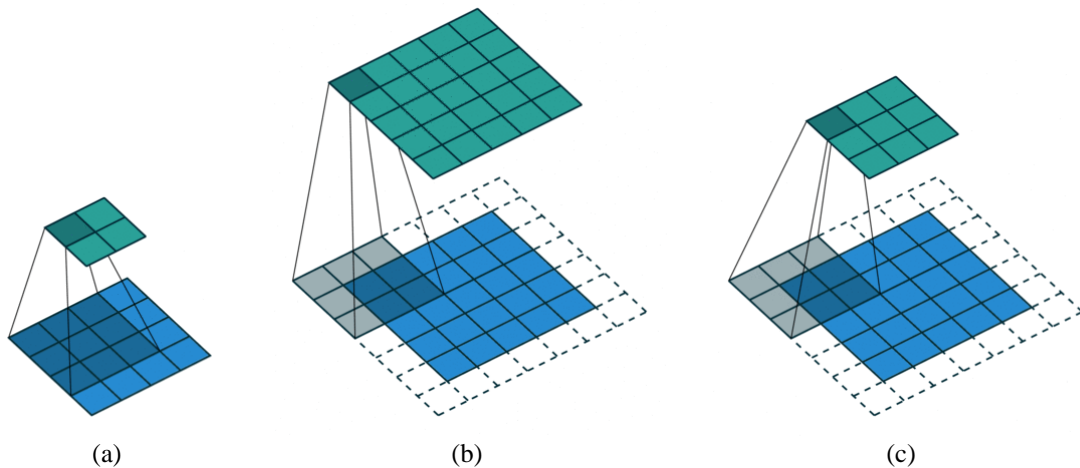


Figura 6 – Efeito dos parâmetros *stride* e *zero-padding* sobre os dados.
Fonte: Dumoulin, Visin (2016)

Na Figura 6(a), é exemplificado o caso da ausência de *zero-padding* e o uso de *stride* igual a 1. Observa-se que, para o dado de entrada com dimensões 4×4 , o filtro é capaz de assumir apenas quatro posições sobre este, resultando, portanto, em uma redução nas dimensões do dado para 2×2 .

Na Figura 6(b), é utilizado *stride* igual a 1, e o dado de entrada possui dimensões 5×5 e faz uso do parâmetro *zero-padding*, indicado pelas linhas tracejadas. Observa-se, neste caso, que o filtro passa a ser capaz de realizar a convolução centrado sobre os elementos das bordas do dado de entrada, permitindo que o dado de saída mantenha as dimensões do dado de entrada.

Finalmente, na Figura 6(c), o parâmetro *zero-padding* é mantido, porém o parâmetro *stride* é alterado para 2, isto é, o filtro passa a se deslocar dois elementos a cada passo, provocando, assim, uma redução nas dimensões do dado para 3×3 .

A convolução propriamente dita consiste no produto escalar realizado entre os elementos do *kernel* e do campo receptivo, resultando em um único valor que corresponde a um elemento do mapa de características gerado. Em seguida, conforme definido acima, o *stride* e o *padding* irão definir o deslocamento do *kernel* ao longo dos elementos do dado de entrada, impactando diretamente no tamanho das dimensões do mapa de características. Este processo é realizado pelo *kernel* de cada filtro, cada um dos quais irá produzir um mapa de características (STANFORD, 2020).

2.3.2 Redes adversárias generativas

As redes adversárias generativas (GAN, do inglês: *generative adversarial networks*) foram introduzidas pela primeira vez em 2014 como um novo *framework* para a avaliação de

modelos generativos (GOODFELLOW et al., 2014). O *framework* consiste em dois modelos: o modelo generativo (gerador) e o modelo discriminativo (discriminador), que competem em um jogo contraditório (*adversarial*).

O objetivo do discriminador é determinar se uma amostra advém da distribuição do modelo gerador ou da distribuição de dados (GOODFELLOW et al., 2014). O gerador produz amostras a partir de um espaço latente, representado por um vetor de valores aleatórios amostrados de uma distribuição normal, com o objetivo de enganar o discriminador. O jogo consiste em treinar ambos os modelos iterativamente, alternando passos de otimização entre eles, de forma que as amostras provenientes do gerador se tornem indistinguíveis das amostras provenientes do conjunto de dados.

Quando isso ocorre, a probabilidade fornecida pelo discriminador converge para 0,5 e o gerador se torna capaz de gerar novas amostras com a mesma distribuição dos dados de treinamento. Em outras palavras, o gerador aprende a gerar dados falsos, mas realísticos, e se torna capaz de enganar o discriminador. O algoritmo implementado pelo *framework* é descrito pela equação (3).

$$\min_G \max_D V(D, G) = \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} \left[\log \left(1 - D(G(\mathbf{z})) \right) \right] \quad (3)$$

O artigo original implementa as GAN utilizando um modelo MLP. No entanto, Radford, Metz e Chintala (2016) implementaram as chamadas redes adversárias generativas convolucionais profundas (DCGAN, do inglês: *deep convolutional generative adversarial network*), que são implementadas utilizando ConvNets bidimensionais, tornando possível a geração de imagens e dados bidimensionais com o auxílio das ConvNets.

O discriminador é atualizado pelo gradiente ascendente, enquanto o gerador é atualizado pelo gradiente descendente. Ambos os modelos competem, como dois jogadores, em um jogo de soma zero⁹ através do algoritmo *minimax*, que tem como objetivo reduzir o erro do gerador e aumentar o erro do discriminador.

A partir do momento em que o discriminador for enganado em metade dos casos, o gerador passará a gerar dados convincentes. O modelo desta arquitetura é mostrado na Figura 7, onde G representa o gerador, D representa o discriminador, \mathbf{x}_{real} representa uma amostra do conjunto de dados, \mathbf{x}_{gen} representa uma amostra produzida pelo gerador, e \mathbf{z} representa o espaço latente.

⁹ Em teoria dos jogos, um jogo em que a perda de um jogador representa o ganho exato para outro jogador é chamado de jogo de soma zero, onde a quantidade total envolvida permanece constante (WEISSTEIN, 2020b).




Figura 7 – Modelo das redes adversárias generativas.
Fonte: Próprio autor

A saída do discriminador, $D(\cdot)$, representa a probabilidade de que a amostra seja proveniente do conjunto de dados. O algoritmo propõe o uso do logaritmo da probabilidade, que resulta em 0 para uma probabilidade igual a 100% ou em valores negativos para os demais valores de probabilidade. Por este motivo, do ponto de vista do discriminador, o algoritmo visa maximizar o valor esperado do logaritmo da probabilidade, uma vez que o logaritmo é uma função monótona, de forma a maximizar o valor esperado de probabilidade para amostras provenientes do conjunto de dados e minimizar o valor esperado de probabilidade para amostras provenientes do gerador. Portanto, para amostras provenientes do conjunto de dados, cuja probabilidade esperada é 1, o algoritmo maximiza o $\log D(\mathbf{x})$, enquanto, para amostras provenientes do gerador, cuja probabilidade esperada é 0, o algoritmo maximiza $\log(1 - D(G(\mathbf{z})))$.

Por outro lado, do ponto de vista do gerador, o algoritmo visa minimizar o valor esperado do logaritmo da probabilidade como forma de maximizar o valor esperado de probabilidade para amostras provenientes do gerador. Portanto, para amostras provenientes do gerador, o algoritmo minimiza $\log(1 - D(G(\mathbf{z})))$. Contudo, o próprio artigo afirma que esta implementação pode provocar a saturação do algoritmo, uma vez que, inicialmente, as amostras provenientes do gerador são claramente diferentes daquelas provenientes do conjunto de dados. Portanto, o algoritmo do gerador pode ser modificado para maximizar $\log D(G(\mathbf{z}))$.

O intervalo de valores de probabilidade $[0,1]$ é o domínio da função logaritmo de probabilidade, ou seja, a imagem desta função corresponde ao intervalo de valores de $(-\infty, 0]$. A Figura 8 mostra os gráficos das funções $\log D$ e $\log(1 - D)$, dado intervalo de probabilidades D de $[0,1]$.




Figura 8 – Gráficos da função logaritmo da probabilidade.
Fonte: Próprio autor

Quando se maximiza $\log D(\mathbf{x})$, a probabilidade $D(\mathbf{x})$ tende a 1, isto é, o discriminador atribui a máxima probabilidade para amostras provenientes do conjunto de dados, vide equação (4).

$$\arg \max_{D \in [0,1]} \log D(\mathbf{x}) = \{1\} \quad (4)$$

Quando se maximiza $\log(1 - D(G(\mathbf{z})))$, a probabilidade $D(G(\mathbf{z}))$ tende a 0, isto é, o discriminador atribui a mínima probabilidade para amostras provenientes do gerador, vide equação (5).

$$\arg \max_{D \in [0,1]} \log(1 - D(G(\mathbf{z}))) = \{0\} \quad (5)$$

Quando se minimiza $\log(1 - D(G(\mathbf{z})))$ ou se maximiza $\log D(G(\mathbf{z}))$, a probabilidade $D(G(\mathbf{z}))$ tende a 1, isto é, o discriminador atribui a máxima probabilidade para amostras provenientes do gerador, vide equação (6).

$$\arg \min_{D \in [0,1]} \log(1 - D(G(\mathbf{z}))) = \arg \max_{D \in [0,1]} \log D(G(\mathbf{z})) = \{1\} \quad (6)$$

Os algoritmos de otimização de redes neurais implementam a minimização do erro como método de aprendizagem. Em tarefas de regressão logística e de classificação binária, recomenda-se o uso da entropia cruzada binária como função custo, a qual é implementada pelo negativo da função logaritmo da probabilidade, como mostra a equação (7). Isto significa que, através da minimização desta função, o logaritmo da probabilidade é maximizado.

$$H = -\frac{1}{n} \sum_{i=1}^n (y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i)) \quad (7)$$

onde y_i representa o rótulo da amostra, \hat{y}_i é a saída da rede neural e representa a probabilidade de que a amostra pertença à classe, n representa o número total de amostras, e H representa o valor calculado para a entropia.

Portanto, o algoritmo de maximização proposto para a implementação das GAN pode ser implementado através da minimização do erro entropia cruzada, que se trata, justamente, do algoritmo de aprendizagem utilizado pelas redes neurais de regressão logística e de classificação. Considerando-se a função sigmoide logística como função de ativação do neurônio de saída, sua imagem corresponde ao intervalo aberto $(0,1)$. Portanto, a função custo definida pelo negativo do logaritmo assume valores no intervalo aberto $(0, \infty)$ para o domínio $(0,1)$, ou seja, através da sua minimização, é possível se obter um valor de erro tendendo a 0.

2.3.3 Aplicações de cada arquitetura

A arquitetura MLP é amplamente empregada em aplicações que já possuem um conjunto de características ou parâmetros definidos, a partir dos quais é possível se implementar tarefas de regressão logística e classificação. Aplicações comuns estão presentes em áreas da medicina, auxiliando, por exemplo, no diagnóstico de câncer, tomando como entrada o conjunto de características de um nódulo e classificando-o como benigno ou maligno (JANGHEL et al., 2010); também na área de controle de sistemas, por exemplo, onde uma rede neural pode aprender a implementar um modelo de controle preditivo baseado no erro da saída do sistema (NISHA et al., 2009).

Ou seja, de uma forma geral, esta arquitetura permite a implementação da aproximação de funções, permitindo, além das tarefas de regressão logística, também tarefas de regressão linear. Além disso, esta arquitetura também permite tarefas de reconhecimento de imagens, processamento da linguagem natural, entre outras aplicações comuns à área de aprendizado de máquina. Contudo, para determinadas tarefas, a complexidade da rede pode tornar a implementação pouco prática, havendo, neste caso, alternativas mais eficientes.

Como alternativa à arquitetura MLP para o reconhecimento de imagens, por exemplo, pode-se destacar as redes convolucionais bidimensionais. Estas redes são capazes de extrair características de dados brutos e implementar tarefas de classificação com maior eficiência que a arquitetura MLP, considerando os seus principais benefícios, com destaque para o compartilhamento de pesos, que fornece maior eficiência à arquitetura convolucional.

De forma análoga, tarefas de reconhecimento de voz podem ser implementadas com redes convolucionais bidimensionais sobre espectrogramas de gravações de áudio (LECUN;

BENGIO, 1995). Na área de medicina, esta arquitetura também encontra aplicações na análise de radiografias e ultrassonografias para o diagnóstico de fraturas ósseas e tumores (LOTFY et al., 2019).

O método implementado pelas redes convolucionais pode também ser aplicado a dados unidimensionais, isto é, sinais e séries temporais, identificando padrões e características e, a partir destes, realizando tarefas de previsão e de classificação. Além dos exemplos de aplicações aqui descritos, existem inúmeros outros estudos nesta área, que se desenvolve a cada dia.

No caso das descargas parciais, considerando as suas altas frequências e a necessidade de uma janela de tempo de alguns milissegundos, a quantidade de amostras em um único sinal é bastante elevada – da ordem de milhões de amostras – e, portanto, o uso de uma arquitetura de rede neural para o processamento desta quantidade de informação deve possuir uma eficiência suficiente para manter a praticidade da implementação.

Portanto, as arquiteturas convolucionais podem ser vistas como as melhores alternativas para processar o sinal bruto, embora a arquitetura MLP seja também amplamente utilizada a partir de um conjunto reduzido de características extraídas previamente.

CAPÍTULO 3 – REVISÃO BIBLIOGRÁFICA

O uso de ferramentas de inteligência artificial para o reconhecimento de padrões de descargas parciais é amplamente descrito na literatura científica, como será discutido neste capítulo. O termo inteligência artificial representa a capacidade das máquinas de simular percepções e comportamentos humanos, e engloba diversas metodologias. Dentre estas metodologias, as ferramentas de aprendizado de máquina vem sendo amplamente utilizadas na aprendizagem de tarefas realizada por computadores a partir de bancos de dados.

O aprendizado de máquina consiste em se treinar um modelo a partir de um conjunto de dados de treinamento com o objetivo de se implementar uma tarefa de regressão linear ou logística. Desta forma o modelo se torna capaz de realizar previsões, diagnósticos e classificações. Dentre as ferramentas de aprendizado de máquina, destacam-se principalmente as diversas arquiteturas de redes neurais artificiais, além da máquina de vetores de suporte (SVM, do inglês: *support vector machine*), árvore de decisão, sistema de inferência *fuzzy* e sistema neuro-*fuzzy* adaptativo (ANFIS, do inglês: *adaptive neuro-fuzzy inference system*).

Ainda dentro do tópico aprendizado de máquina, pode-se citar o aprendizado profundo (em inglês: *deep learning*) e das redes neurais profundas (em inglês: *deep neural networks*). O termo “profundo” refere-se não apenas à arquitetura (quanto mais camadas, mais profunda é a rede), mas também à capacidade de aprendizagem do modelo.

O aprendizado profundo e as redes neurais profundas são bastante conhecidas entre os pesquisadores da área de inteligência artificial. Em uma época anterior, pesquisadores costumavam realizar tarefas de extração de características manualmente, isto é, eles analisavam os dados de forma cognitiva e selecionavam suas características mais representativas com relação a uma determinada classificação desejada. Estas características eram então apresentadas à rede neural para seu treinamento visando implementar a tarefa desejada.

Hoje, dados brutos são apresentados diretamente aos modelos de redes profundas e são as camadas mais rasas do modelo que realizam a tarefa de extração de características durante o próprio processo de treinamento. Com o avanço dos métodos computacionais e do próprio sistema elétrico, é cada vez maior o volume de dados coletados, permitindo a implementação de ferramentas de aprendizado de máquina para a realização das mais variadas tarefas de análise de sistemas elétricos.

Do ponto de vista das descargas parciais, os padrões de seus pulsos são fortes indicativos da sua origem, do seu tipo e da sua severidade. Contudo, a análise cognitiva dos padrões, tanto

no domínio no tempo, quanto levando em conta seu conteúdo de frequências, ainda depende fortemente de expertise na área.

O uso de ferramentas de aprendizado profundo na classificação de descargas parciais é discutido por Barrios et al. (2019) em uma revisão do estado da arte, especialmente com respeito à sua capacidade de realizar a extração de características de forma automática, em comparação com a extração manual exigida pelas ferramentas de aprendizado de máquina tradicionais. Os autores abordam as principais arquiteturas utilizadas na tarefa de classificação de descargas parciais, dentre elas:

- Redes neurais recorrentes (RNN), arquitetura na qual os neurônios apresentam uma memória do estado anterior;
- *Autoencoders*, um modelo de aprendizagem não supervisionada que visa reconstruir o dado de entrada na camada de saída e produzir uma codificação, ou um conjunto de características, nas camadas escondidas;
- Redes adversárias generativas (GAN), utilizadas para gerar dados artificiais mantendo as características dos dados reais;
- Redes convolucionais (CNN), inspiradas pelo córtex visual biológico e, portanto, especialistas, mas não restritas, em reconhecimento de imagens, apresentando um ótimo desempenho na extração de características.

Os tipos de classificação de descargas parciais usualmente implementados por modelos de aprendizado profundo envolvem identificar diferentes tipos ou fontes de defeitos. Na maioria dos casos, utiliza-se o gráfico PRPD ou a série temporal de amostras do sinal de descargas parciais. No caso do uso de ferramentas de aprendizado profundo, não é interessante que se realize uma seleção manual de características, dada a capacidade dos modelos em realizar isto de forma automática.

Do ponto de vista de classificação de sinais de descargas parciais, Barrios et al. (2019) aponta que grande parte dos estudos nesta área que utilizam modelos de redes neurais profundas apresentam melhor desempenho quando comparados com outras ferramentas, como lógica *fuzzy*, máquina de vetores de suporte (SVM) e modelos de redes MLP. Contudo, os autores também destacam que a maior parte destes estudos se utilizam de simulações de defeitos em laboratório ou gerados por computador, o que poderia comprometer a implementação prática destas metodologias, caso estas simulações não sejam boas representações das condições de campo.

Estes autores ainda destacam que o modelo mais aplicável do ponto de vista prático seriam as redes convolucionais, justamente pela sua capacidade de manter a informação estrutural dos dados, como um espectrograma. Esta abordagem foi realizada por Li et al. (2018) em um artigo que apresenta a evolução de um estudo anterior (LI et al., 2016). Os autores aplicam as redes convolucionais a sinais de descargas parciais oriundos de subestações isoladas a gás (GIS, do inglês: *gas-insulated switchgear*).

Diversos artigos na literatura citam o uso de espectrogramas para a visualização da variação do espectro de frequência de um dado sinal ao longo do tempo (LI et al., 2016; LU et al., 2016). O resultado é uma representação bidimensional, cujo eixo horizontal, usualmente, representa o tempo e cujo eixo vertical, usualmente, representa a frequência. Podem ser utilizadas cores para indicar a intensidade da grandeza envolvida. Alternativamente, a intensidade pode ser representada por uma terceira dimensão, formando uma superfície tridimensional.

Os espectrogramas são amplamente aplicados em trechos de gravações de voz com o objetivo de implementar aplicações de inteligência artificial para tarefas de reconhecimento de voz. Além disso, diversos trabalhos aplicam os espectrogramas a sinais de descargas parciais, o que permite o seu uso com redes convolucionais bidimensionais (LI et al., 2016; LU et al., 2016). O pilar dos algoritmos a serem desenvolvidos no presente trabalho é uma rede convolucional para a classificação de espectrogramas de descargas parciais, sendo esta a solução mais viável para a tarefa almejada da forma como se deseja que ela seja executada.

Os autores (LI et al., 2018) abordam os métodos de monitoramento de descargas parciais mais comuns: o químico, o elétrico e o acústico. Contudo, eles destacam que o método de medição de sinais de UHF (*ultra high frequency*, do inglês: frequência ultra-alta) vem se tornando o mais significativo, devido à sua sensibilidade e ao fato de permitir o monitoramento em tempo real. No seu estudo mais recente (2018), os autores implementam uma rede convolucional visando uma análise multirresolução dos espectrogramas de descargas através da análise por meio de filtros temporais, filtros de frequência e filtros de textura.

A análise multirresolução é obtida por meio da variação do tamanho da janela da transformada de Fourier de curto termo (STFT, do inglês: *short-term Fourier transform*) durante a geração dos espectrogramas. Os autores afirmam que as redes convolucionais são consideradas o estado da arte para tarefas de visão computacional e, portanto, as empregam juntamente com redes recorrentes para uso com múltiplos sensores.

Contudo, os múltiplos sensores UHF empregados pelos autores na GIS simulada em laboratório são intrusivos, sendo instalados internamente ao equipamento, permitindo, assim,

maior controle das condições de medição. De fato, grande parte das aplicações empregam sensores fixos e/ou intrusivos, havendo poucos relatos de sensores portáteis para uso não intrusivo em campo.

Tang et al. (2017) utilizam uma antena de microfita (*microstrip*) para a detecção dos sinais, e simulações de defeitos em laboratório para a geração de descargas parciais. Os autores descrevem alguns parâmetros estatísticos, que foram extraídos dos dados obtidos, para o cálculo de um grau de severidade utilizando SVM. Alternativamente, os autores empregam um *autoencoder* a título de comparação, o qual resulta em um melhor desempenho. Contudo os diferentes graus de severidade selecionados são baseados na tensão aplicada no ensaio de laboratório, inviabilizando sua aplicação em campo.

Fontana et al. (2012) descrevem uma rede de sensores para o monitoramento do estado de poluição de isoladores de alta tensão. Os autores afirmam que a amplitude, taxa de repetição e duração dos pulsos de descargas são bons indicadores do grau de poluição de cadeias de isoladores. O sistema de sensores empregado se utiliza da detecção dos pulsos de descargas parciais presentes na corrente de fuga, e compreende um sensor óptico, fibras ópticas e um módulo eletrônico de processamento. Contudo, mais uma vez, trata-se de um método intrusivo de detecção de descargas.

Em um artigo, Milioudis, Andreou e Labridis (2019) abordam o monitoramento *online* para a detecção e localização de descargas parciais em cabos subterrâneos de média tensão. Os autores destacam os principais desafios envolvidos na aquisição de sinais de campo, dentre eles, o excesso de ruídos presente nesta condição de monitoramento. Os autores então apresentam dois algoritmos: um para a redução do ruído e um para a detecção de picos de descargas, sendo o primeiro implementado por meio da transformada *wavelet* discreta.

Tenbohlen et al. (2008) abordaram os principais aspectos e desafios da utilização da faixa de UHF na detecção de descargas parciais em campo. Os autores destacam a vantagem de se realizar a detecção por este método, dada a não necessidade de conexão elétrica com o circuito de alta tensão. Por outro lado, os autores também comentam sobre a impossibilidade de se obter um valor confiável da carga aparente, argumentando, assim, que esta não se trata de uma grandeza de grande importância quando se trata de sistemas complexos de isolamento, uma vez que o comportamento da atividade de descargas parciais possui maior importância.

Em estudos mais recentes, Park e Jung (2020) propõem uma antena UHF de polarização circular no formato de uma espiral de Arquimedes para a detecção de descargas parciais. Qi et al. (2019), por sua vez, propõem uma antena de banda ultralarga para atender à faixa de frequências de ocorrência das descargas. Os autores avaliaram a antena proposta em laboratório

para a detecção de descargas parciais em um isolador contaminado pelo método da camada sólida em um ensaio de poluição artificial.

Rocha et al. (2019) desenvolveram um estudo sobre a detecção de radiofrequência por antenas com o objetivo de se avaliar a poluição superficial acumulada em isoladores de alta tensão. A metodologia dos autores consistiu na instalação de uma cadeia de isoladores desenergizada em paralelo com cadeias energizadas nas estruturas do estudo por um período de doze meses. Foram então realizadas medições dos sinais de radiofrequência a partir das cadeias energizadas a cada três meses, as quais foram então comparadas com a poluição medida nas cadeias desenergizadas.

Para isto, os autores utilizaram uma antena log periódico e um amplificador. Os sinais são analisados com respeito ao seu conteúdo de frequências e são decompostos utilizando a transformada *wavelet*. Uma rede neural foi então treinada com o objetivo de atribuir aos sinais coletados um dos três níveis de poluição definidos.

Além de tais classificações, alguns estudos também visam propor um grau de severidade da atividade de descargas parciais. A avaliação da severidade das descargas é abordado por Ahmed e Srinivas (2001), Miao et al. (2018), Stewart et al. (2006), Dong et al. (2015), Montanari, Seri e Contin (2018), Abu-Elanien, Salama e Ibrahim (2012) e Lumba et al. (2019).

Ahmed e Srinivas (2001) definem cinco níveis de severidade para um sistema de cabos. Os sinais de descargas são atribuídos a cada um destes níveis baseados na observação dos padrões, tendo como grandezas medidas, a magnitude e a taxa de repetição dos pulsos. A tendência de evolução da atividade de descargas também é considerada, e o objetivo do estudo é estimar a expectativa de vida útil do sistema de isolamento.

Miao et al. (2018) e Dong et al. (2015) apresentam uma seleção de parâmetros estatísticos extraídos a partir dos sinais de descargas. A simulação das descargas é feita em laboratório e a coleta dos dados é a mesma descrita por Tang et al. (2017). Os parâmetros são inseridos em um sistema *fuzzy*, a partir do qual os sinais são classificados em quatro classes representando o estado do isolamento estudado.

Stewart et al. (2006) definem uma equação para o cálculo direto de um grau de severidade baseado na carga aparente medida e na correlação temporal entre os pulsos de descargas. Os estudos são baseados em um gráfico tridimensional que implementa a análise da sequência temporal de descargas (TSAD, do inglês: *time-sequence-analysis-discharge*).

Montanari, Seri e Contin (2018) analisam o impacto de cada fonte de descargas no isolante. Neste caso, as descargas parciais são estudadas em máquinas rotativas. Os autores afirmam que a estimativa da condição das máquinas deve considerar, primeiramente, a natureza

das descargas e, em segundo lugar, a sua magnitude. Os autores propõem um cálculo de um índice para indicar o quão saudável é a condição das máquinas rotativas, e sugerem que este índice pode ser representado por meio de uma escala de 0 a 10 ou por meio das cores de um semáforo, por exemplo.

Abu-Elanien, Salama e Ibrahim (2012) propõem um índice para indicar a condição de operação de transformadores imersos em óleo. A metodologia proposta considera aspectos químicos obtidos a partir da análise do óleo isolante. Os autores propõem o uso da lógica *fuzzy* com o objetivo de reduzir as discrepâncias de opinião entre especialistas na definição de categorias de condições de operação, e reduzir a incerteza quanto ao limiar entre estas categorias.

Lumba et al. (2019) selecionam quatro parâmetros de descargas parciais, considerando o número de pulsos e a magnitude de carga. Contudo, a metodologia proposta pelos autores envolve a análise da evolução do fenômeno, e considera esta comparação na definição de um diagnóstico quanto à condição da atividade de descargas.

Considerando-se a necessidade de um conjunto de dados numeroso para o treinamento de uma rede neural e de um sistema de inferência *fuzzy*, frequentemente são empregados algoritmos de ampliação artificial do conjunto de dados, quando não é possível a obtenção de novos dados reais. Considerando-se os recentes avanços no ramo de redes neurais, as GANs, apresentadas pela primeira vez em 2014, demonstraram uma capacidade surpreendente de geração de dados sintéticos, principalmente de imagens.

Embora o artigo original cite a utilização da arquitetura MLP clássica, diversos artigos na literatura vêm utilizando as GANs com outras arquiteturas com o objetivo de gerar imagens sintéticas, de paisagens ou rostos totalmente artificiais, além de, por exemplo, colorir fotos em preto e branco ou aumentar a resolução e a nitidez de imagens de baixa qualidade (RADFORD; METZ; CHINTALA, 2016).

Em um breve estudo realizado durante este projeto, que resultou na publicação de um artigo em congresso (PETRI et al., 2019), as GANs foram aplicadas na geração de espectrogramas de descargas parciais com o objetivo de se avaliar a sua capacidade de geração de novos dados. Alguns padrões de descargas parciais foram selecionados dentre os sinais do conjunto de dados deste projeto, a partir dos quais foi treinada uma GAN para cada padrão, resultando, assim, em um modelo gerador para cada padrão.

A partir destes modelos geradores foram gerados espectrogramas sintéticos com as mesmas características dos espectrogramas reais. Uma rede neural de multiclassificação foi então treinada exclusivamente sobre os dados sintéticos e, após o treinamento, avaliou-se seu

desempenho com os dados reais. O resultado demonstrou que esta rede de classificação foi capaz de aprender as características e os padrões contidos nos dados sintéticos e identificá-los nos dados reais, classificando-os corretamente.

Além disso, utilizando-se a mesma rede treinada, foram apresentados novos dados reais, com dois padrões distintos dos presentes nos dados anteriores, de forma a se avaliar o seu comportamento diante de novos dados. A rede classificou os dois novos padrões em duas classes distintas, sendo todos os dados de um mesmo padrão atribuídos a uma mesma classe. O que se observa é que a rede buscou a classe que possuía mais características em comum com o novo padrão, realizando a classificação baseada no aprendizado obtido durante seu treinamento. Isto reafirma a capacidade de aprendizagem das redes neurais sobre dados sintéticos, confirmando a possibilidade de utilizá-los para ampliação do conjunto de treinamento.

Contudo, as GANs não foram utilizadas diretamente no conjunto de treinamento final da rede neural que compõe os algoritmos desenvolvidos neste estudo. Primeiramente, a arquitetura ainda é foco de muitos estudos e, ocasionalmente, apresenta resultados inesperados. Em segundo lugar, dada a ocorrência destes resultados inesperados, muito tempo precisa ser empregado na análise cognitiva dos dados artificiais gerados. Por estes motivos, a aplicação das GANs foi restrita a este breve estudo experimental realizado durante o projeto.

3.1 DISCUSSÃO

Dado o exposto até aqui, considerando-se a fundamentação teórica apresentada no Capítulo 2 e a revisão bibliográfica apresentada neste capítulo, é possível observar que grande parte dos estudos foca em ensaios em laboratório, com sensores adequados para esta condição, para a aquisição de sinais de descargas parciais. Além disso, as descargas parciais propriamente ditas são obtidas por meio de simulações de defeitos. O presente trabalho irá apresentar, nos próximos capítulos, uma metodologia para a aquisição de um conjunto de dados baseado em sinais coletados em campo e por meio de ensaios de laboratório que reproduzem as condições de operação em campo.

Além disso, este trabalho irá apresentar a proposta e a avaliação do uso de uma antena de UHF para aquisição dos sinais em campo, a partir dos quais são obtidos parâmetros independentes da amplitude absoluta dos pulsos de descargas para a estimativa de um grau de severidade. Alguns dos parâmetros selecionados são amparados pelas normas pertinentes e outros são adaptados a partir dos estudos citados neste capítulo.

Dadas as características dos parâmetros propostos e a incerteza a eles relacionada, e tendo em vista a utilização de sistemas de inferência *fuzzy* pelos estudos descritos neste capítulo, nos capítulos seguintes será apresentada a proposta de um sistema *fuzzy* para a obtenção de um grau de severidade numérico a partir do conjunto de parâmetros selecionados. Neste caso, o sistema *fuzzy* foi utilizado apenas como uma ferramenta para auxiliar o desenvolvimento dos algoritmos, não tendo sido realizados estudos extensos a seu respeito. A sua principal vantagem repousa na sua capacidade de lidar com as incertezas associadas aos parâmetros de entrada, ideal, neste caso, dada a utilização de grandezas de magnitude relativa.

Além disso, dadas as vantagens e os resultados levantados com respeito ao uso de redes convolucionais na classificação de sinais de descargas parciais, uma rede neural nesta arquitetura é proposta, para que os algoritmos desenvolvidos neste estudo realizem a seleção dos sinais que se deseja analisar de forma mais detalhada. Os estudos citados neste capítulo apontam a capacidade das redes convolucionais de manter a informação estrutural dos dados como sua principal vantagem na aplicação a dados de descargas parciais.

CAPÍTULO 4 – METODOLOGIA

Tendo em vista os objetivos deste trabalho, o algoritmo proposto para identificação e classificação das descargas parciais deve ser capaz de analisar os sinais classificados pela rede neural, e apresentar parâmetros correlacionados à intensidade da atividade de descargas parciais, incluindo um grau de severidade, com valores na faixa de 0 a 10. Considerando-se os sinais coletados como o objeto de estudo deste trabalho, uma série de ensaios foi realizada com o objetivo de se encontrar um sensor adequado para a detecção dos sinais de descargas parciais em campo, e de se formar um conjunto de dados para o desenvolvimento e avaliação dos algoritmos.

A proposta inicial do P&D para a medição dos sinais de descargas parciais seria por meio de um transformador de corrente de núcleo dividido instalado no condutor de aterramento da estrutura a ser inspecionada. A literatura mostra que o conteúdo de descargas parciais está presente na corrente de fuga dos isoladores, portanto o transformador de corrente seria capaz de detectá-las (AGUIAR DO NASCIMENTO et al., 2018; CAPELINI, 2015; SUWARNO, 2001).

Trata-se do método mais confiável para as medições em campo, considerando-se que, embora ainda haja a possibilidade de detectar sinais de estruturas adjacentes trafegando pelos condutores, o transformador de corrente, na maioria das vezes, faria a leitura apenas dos sinais provenientes da estrutura sob inspeção.

Entretanto, ao se realizar ensaios em laboratório, constatou-se que a maioria dos transformadores de corrente ensaiados possuía baixa blindagem eletromagnética a sinais externos. Em alternativa aos transformadores de corrente inicialmente testados, um transformador de corrente de alta frequência (HFCT), específico para a detecção de descargas parciais, foi avaliado. Este sensor, por sua vez, atendeu aos requisitos deste estudo, realizando apenas a leitura dos componentes de altas frequências e possuindo uma ótima blindagem a sinais de radiointerferência.

Contudo, ao serem realizadas inspeções na linha de transmissão em São Luís, observou-se que a maioria das estruturas desta não dispunha do condutor de aterramento acessível. Grande parte das estruturas são postes de concreto tipo duplo T, com isoladores tipo pilar polimérico ou tipo bastão polimérico, classe 69 kV, porém com o condutor cimentado no pé da estrutura.

Desta forma, metodologias alternativas, porém amparadas cientificamente, foram testadas para uso em campo, levando à conclusão de que um sensor de radiofrequência baseado

em uma antena para a detecção da radiointerferência seria a solução mais adequada e prática para a questão da detecção dos sinais.

Paralelamente, também foram testados equipamentos baseados em ultrassom, porém a escolha final foi a antena de radiofrequência, dada a sua flexibilidade quanto à estrutura com a qual pode ser utilizada, seu baixo custo, simplicidade de fabricação, robustez e facilidade de manutenção em caso de defeito. Comparativamente, o custo para o desenvolvimento da antena de radiofrequência, descontada a mão-de-obra, é de R\$ 50, enquanto o sensor HFCT disponível comercialmente chega a US\$ 1.500. Além disso, a inspeção com a antena se trata de um método não invasivo, quando comparado à inspeção utilizando o HFCT.

A seguir são apresentados os principais ensaios realizados, seus resultados parciais, suas possíveis contribuições para o desenvolvimento dos algoritmos e suas conclusões parciais.

4.1 ENSAIOS EM CAMPO

Levando em conta os métodos de inspeção *online* e considerando-se o que cita a norma IEC 60270:2000 (IEC, 2015) e os sensores disponíveis comercialmente, foram utilizados, neste estudo, três sensores, sendo um baseado em radiointerferência e um baseado em ultrassom, ambos fabricados pela Radar Engineers, e um terceiro sensor, um transformador de corrente de alta frequência (HFCT, do inglês: *high frequency current transformer*) fabricado pela HVPD.

O primeiro equipamento é o *Model 242 – AM-UHF RFI Locator*, que tem como objetivo localizar fontes de radiointerferência na faixa de 500 kHz a 3,5 MHz. O equipamento consiste em um circuito de sintonia e um amplificador para a faixa de 500 kHz a 1.000 MHz, e em um osciloscópio embutido, além de ser capaz de reproduzir a radiointerferência na forma de ruído audível.

O circuito é otimizado para a detecção de ruídos oriundos de centelhamento, distinguindo-os de sinais de telecomunicações nas frequências de rádio e televisão. O transdutor utilizado é uma antena log-periódico, cuja diretividade é garantida para a faixa de 270 MHz a 1.000 MHz, com um ângulo de abertura de aproximadamente 60° e com uma ótima relação frente-costas (RADAR ENGINEERS, 2012). A Figura 9 mostra um operador utilizando o equipamento e o painel do equipamento.



Figura 9 – Equipamento Radar Engineers Model 242 – AM-UHF RFI Locator.
Fonte: Radar Engineers (2020a); Radar Engineers (2020b)

O segundo equipamento é o *Model 250 – Parabolic Pinpointer*, que tem como objetivo localizar fontes de ultrassom como forma de auxiliar os operadores das concessionárias a identificar fontes de radiointerferência, tendo em vista a energia ultrassônica emitida pelo centelhamento. A localização por ultrassom tende a ser extremamente precisa, permitindo a identificação da posição da fonte de ruído dentro de uma estrutura.

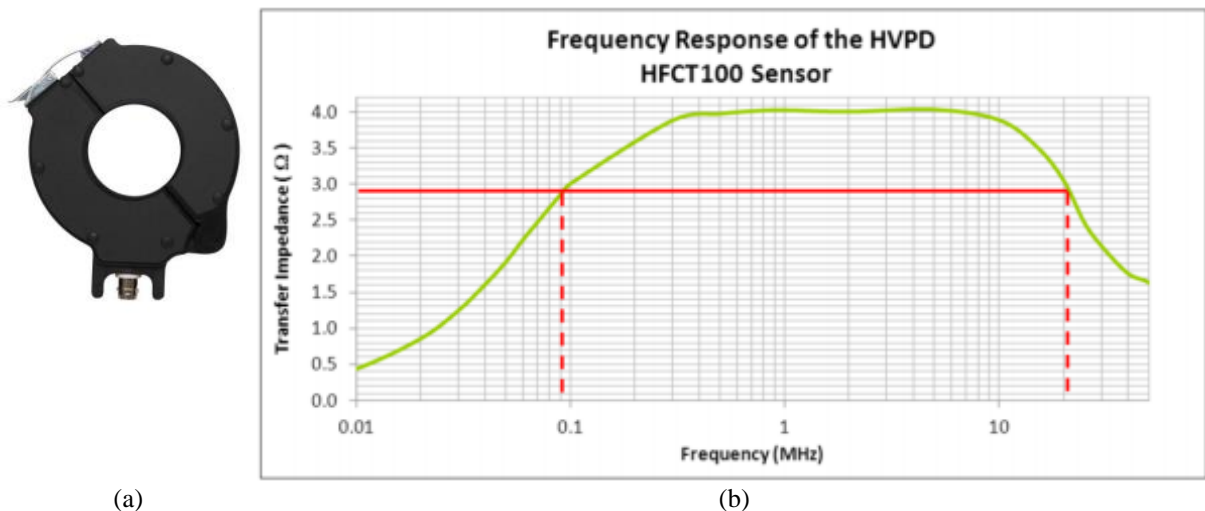
O equipamento consiste em um transdutor de ultrassom montado em um refletor parabólico, juntamente com um receptor, amplificadores, alto-falante e medidor. O equipamento possui também um detector de corona que, embora não seja sempre definitivo, pode auxiliar na distinção deste tipo de descarga em sistemas de transmissão de pelo menos 115 kV. A identificação inicial da estrutura que contém a fonte de interferência deve ser conduzida utilizando-se um detector de radiofrequência com uma antena direcional (RADAR ENGINEERS, 1998). A Figura 10 mostra um operador utilizando o equipamento.



Figura 10 – Equipamento Radar Engineers Model 250 – Parabolic Pinpointer.
Fonte: Adaptado de Radar Engineers (2020a)

O terceiro sensor é o HFCT100 fabricado pela HVPD, que tem como objetivo realizar medições de descargas parciais na faixa de radiofrequência em sistemas de potência através do condutor de aterramento, sem necessidade de conexão direta. Este HFCT possui uma largura de banda larga e deve ser conectado ao redor do condutor de aterramento do equipamento que se deseja inspecionar, uma vez que é portátil e possui núcleo dividido permitindo seu uso para a realização de inspeções *online*.

O sensor apresenta boa blindagem a radiointerferências externas e atenuação suficiente para componentes de baixa frequência. Sua faixa de resposta de -3 dB varia de 100 kHz até 20 MHz, com uma impedância de transferência de $3,9 \text{ mV/mA} \pm 5\%$ (HVPD, 2018). A Figura 11(a) mostra o equipamento propriamente dito e a Figura 11(b) mostra sua resposta em frequência.



(a) (b)
 Figura 11 – Equipamento HVPD HFCT100: (a) estrutura; (b) resposta em frequência.
 Fonte: HVPD (2018)

Desta forma, estes três sensores foram selecionados para serem testados em campo, visando a seleção do mais adequado para a versão final do equipamento desenvolvido pelo projeto de P&D.

Uma fonte de centelhamento usualmente emite sinais de radiointerferência na faixa de 100 kHz até mais de 1 GHz. As frequências mais baixas se propagam a distâncias maiores da fonte do que as frequências mais altas, como mostra o diagrama da Figura 12, extraída do manual do equipamento. Por este motivo, quanto mais alta a frequência de sintonia utilizada no equipamento, maior a certeza da proximidade da fonte de radiointerferência.

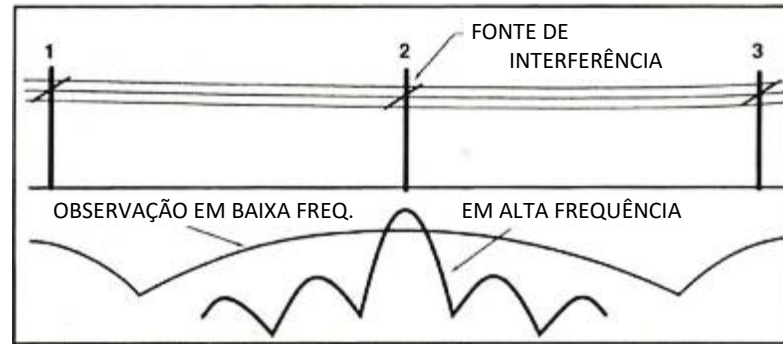


Figura 12 – Alcance de diferentes valores de frequência a partir de uma fonte de interferência.
Fonte: Adaptado de Radar Engineers (2012)

A operação do equipamento *Model 242* consiste em, inicialmente, se realizar uma varredura da região, sintonizando-se a maior frequência que a antena é capaz de detectar, ou em um valor de aproximadamente 150 MHz. Um operador experiente é capaz de realizar a distinção dos ruídos de centelhamento dos demais ruídos. O ganho deve então ser variado de forma a se determinar a localização aproximada da fonte de interferência. Conforme se aproxima da fonte, o equipamento deve ter sua frequência de sintonia aumentada gradualmente, até o valor de 300 MHz.

Com o auxílio da antena log periódica, sempre movendo-se em direção à fonte de interferência, é possível realizar a detecção até a faixa de 600 a 700 MHz. Rotacionando-se a antena ao redor do seu eixo, é possível aproveitar-se da sua diretividade para identificar corretamente a estrutura fonte de interferência. A operação do equipamento é exibida na Figura 13.




Figura 13 – Estrutura sendo inspecionada em campo por meio do equipamento *Model 242*.
Fonte: Próprio autor

Uma vez localizada a estrutura fonte de radiointerferência com o uso do equipamento de radiofrequência, a inspeção fina pode ser realizada com o equipamento de ultrassom. A detecção da fonte de descargas com o equipamento de ultrassom é altamente confiável, dadas as características físicas do fenômeno. A Figura 14 mostra a operação do equipamento em laboratório.

A inspeção deve ser metódica, dada a alta diretividade do equipamento. O apontamento do refletor parabólico cobre apenas uma pequena área da estrutura, de aproximadamente 20 cm de diâmetro. Portanto, a inspeção deve compreender uma varredura completa de todos os pontos de cada dispositivo que possa ser uma fonte de descargas.



Figura 14 – Cadeia de isoladores sendo inspecionada em laboratório por meio do equipamento *Model 250*.
Fonte: Próprio autor

O HFCT100, por sua vez, se trata de um transdutor que converte os sinais da corrente em um condutor em sinais de tensão, os quais precisam então ser lidos por meio de um sistema de medição adequado, como, por exemplo, um osciloscópio. Este HFCT possui um núcleo dividido, permitindo sua abertura para envolver o condutor que se deseja inspecionar, como mostrado na Figura 15.

Inicialmente, utilizando-se apenas os dois equipamentos fabricados pela *Radar Engineers*, alguns postes de distribuição de 13,8 kV foram inspecionados no município de Itajubá para a familiarização com a operação dos equipamentos. Em seguida, na zona rural do município, foram inspecionadas estruturas de transmissão da linha de 500 kV que faz a ligação entre Cachoeira Paulista - SP a Poços de Caldas - MG, nas imediações da subestação Itajubá 3, como a mostrada na Figura 16.



Figura 15 – Equipamento HFCT100 com o condutor de aterramento passando através da sua janela.
Fonte: Próprio autor



Figura 16 – Exemplo de estrutura de 500 kV inspecionada em campo.
Fonte: Próprio autor

Em outra ocasião, utilizando-se também o HFCT100 fabricado pela HVPD, foram realizadas inspeções em estruturas de transmissão de linhas de 138 kV, tanto no município de Itajubá, quanto no município vizinho de Piranguinho. De forma comparativa, utilizando-se apenas a antena do *Model 242* juntamente com o HFCT100, constatou-se que ambos têm a capacidade de realizar a detecção dos pulsos de descargas parciais da forma desejada.

Para o uso do HFCT, foi necessária a conexão de um segmento de fio condutor (*jumper*) em paralelo com o pé da torre. O HFCT foi então instalado envolvendo este *jumper*, possibilitando a leitura da parcela da corrente de fuga da estrutura nele presente. Este procedimento considera uma torre metálica aterrada. Estruturas de concreto exigem acesso ao condutor de aterramento.

Outros membros da equipe deste P&D também realizaram ensaios na cidade de Bragança Paulista - SP, em uma linha de 69 kV com estruturas de concreto e isoladores poliméricos, semelhante ao sistema elétrico de São Luís. Na época do ensaio, a linha era nova e os isoladores se encontravam visualmente limpos. As medições foram realizadas com uma antena de UHF comum (utilizada para recepção de sinais de televisão) e com o HFCT.

Após esta sequência de ensaios, que teve como objetivo avaliar o desempenho e a sensibilidade dos sensores candidatos à seleção para o protótipo do equipamento, um conjunto de ensaios foi agendado para ser realizado em São Luís, visando se obter uma análise do estudo de caso real. Durante esses ensaios, foi possível inspecionar e realizar as medições pertinentes nas estruturas que são o foco deste estudo, apresentando as condições de degradação e poluição que deveriam ser consideradas para o desenvolvimento dos algoritmos.

Os ensaios foram realizados em duas etapas, nos meses de agosto e setembro, no começo da estação seca. Primeiramente, em agosto, foi possível notar o início do acúmulo de poluição, que poderia facilmente ser removido através de procedimentos de lavagem, e algumas marcas de centelhamento em ambas extremidades de alguns isoladores, mas principalmente próximas ao condutor de alta tensão.

Durante estes ensaios, constatou-se que a maioria das estruturas não dispunha de acesso ao seu condutor de aterramento, desta forma, inviabilizando o uso do HFCT. Assim, o foco do P&D, com respeito ao sensor a ser utilizado, passou a ser a avaliação de antenas direcionais para a detecção dos sinais de descargas parciais por meio da interferência eletromagnética de radiofrequência.

De um modo geral, durante os ensaios no mês de agosto, pulsos de descargas parciais foram detectados com diferentes padrões em diversas estruturas. Além disso, em algumas ocasiões, alguns sinais de telecomunicações também foram detectados. A Figura 17 mostra exemplos de estruturas do sistema de São Luís. Como é possível se observar através desta figura, em sua maioria, as estruturas são de concreto, com perfil duplo T, havendo também estrutura com perfil circular. Os isoladores são, em sua maioria, poliméricos, do tipo suspensão ou pilar.

Nos dias em que foi realizada a primeira etapa dos ensaios, no mês de agosto, foram observadas algumas chuvas breves. No mês de setembro, quando foi realizada a segunda etapa, os membros da equipe presentes nos ensaios não presenciaram precipitação de chuva nos dias de ensaio. Considerando também a média histórica de precipitação para o mês de setembro, pode-se afirmar que a poluição acumulada já era maior do que a observada no mês de agosto. Embora, visivelmente, a condição de poluição fosse a mesma, para a maior parte dos isoladores

inspecionados no mês de setembro, a atividade de descargas parciais detectada foi muito maior comparando-se o mesmo conjunto de isoladores inspecionados no mês anterior.




Figura 17 – Exemplos de estruturas do sistema de 69 kV de São Luís-MA.

Fonte: Próprio autor

Além disso, outro conjunto de isoladores foi inspecionado em uma linha de transmissão a vazio, havendo, portanto, uma sobretensão de valor desconhecido. Esta linha – localizada na região da Forquilha, em São Luís – foi indicada pela equipe de manutenção da concessionária, dado o seu histórico de interrupções no fornecimento de energia, centelhamento visível e ruído audível, relatados, inclusive, por moradores do local.

Dentre as três estruturas que foram selecionadas para inspeção, nesta que é considerada uma das linhas mais críticas do sistema de São Luís, a primeira delas foi inspecionada apenas durante o dia, a segunda foi inspecionada durante o final do dia e início da noite e a terceira apenas à noite. O intuito da inspeção incluía também a avaliação da mudança da atividade das descargas em diferentes horas do dia, considerando-se diferenças climáticas, como temperatura, umidade e direção do vento, a qual pode carregar mais ou menos sal em suspensão vindo do oceano.

As inspeções mostraram que a primeira estrutura apresentava um padrão de pulsos individuais distribuídos ao longo dos semiciclos da forma de onda da tensão fundamental. São pulsos bem definidos, de baixa densidade, repetindo-se a cada semiciclo da tensão em uma faixa específica de ângulos de fase.

A segunda estrutura, por sua vez, apresentou uma densidade muito maior de pulsos (maior taxa de repetição) durante o período da noite, em comparação com as inspeções realizadas

durante o dia. A umidade relativa do ar aumenta durante o período noturno, o que explica a mudança no comportamento da atividade das descargas. As amplitudes dos pulsos, contudo, não se alteraram em relação às medições realizadas durante o dia. A taxa de repetição aumenta com o aumento da poluição salina superficial e da umidade relativa.

Finalmente, a terceira estrutura apresentou a maior e mais severa atividade de descargas parciais dentre todas as inspeções realizadas durante os meses de agosto e setembro. Além desta localidade, foram também realizadas inspeções na região do Porto do Itaqui, onde existe uma forte movimentação de cargas de minérios. Os isoladores desta região, no entanto, embora fiquem constantemente cobertos de pó de minério, não apresentam uma atividade tão intensa quanto a observada anteriormente na linha a vazio.

Retornando-se ao laboratório a antena foi extensamente testada, de forma a se avaliar o seu desempenho, tendo em vista a detecção adequada dos pulsos de descargas, a sua distância de operação e a sua diretividade. Assim, mantendo-se um circuito de ensaio energizado com uma simulação de defeito, o equipamento de radiofrequência *Model 242* foi levado para fora do prédio do laboratório, a uma distância de cerca de 280 metros, mantendo, porém, a visada direta para o local de ensaio, como mostrado, em destaque, na Figura 18. Ao se variar o ângulo de apontamento da antena em relação à direção da visada, tanto no plano horizontal, quanto no vertical, constatou-se a boa capacidade de diretividade da antena. Já o equipamento de ultrassom, por sua vez, teve seu uso restrito ao interior do laboratório



Figura 18 – Utilização do equipamento *Model 242* à distância do laboratório (em destaque).

Fonte: Próprio autor

De uma forma geral, todos estes ensaios foram conclusivos com relação ao uso de sensores de radiofrequência (radiointerferência e HFCT) e de ultrassom, seu desempenho em campo e sua capacidade de detectar, com fidelidade, descargas parciais em estruturas de alta tensão. A metodologia de inspeção a ser utilizada para detecção dos sinais de descargas parciais pôde ser avaliada e validada. Além disso, foi possível se observar e conhecer o comportamento dos fenômenos de radiofrequência e de ultrassom oriundos das descargas parciais, com relação à sua distância de propagação e ao seu comportamento diante de obstáculos.

Dentre as observações sobre o fenômeno, pode-se destacar que a taxa de repetição dos pulsos de descargas parciais é um bom indicador da condição de poluição do isolador, independentemente da amplitude dos pulsos, do sistema de calibração e do posicionamento do sensor em campo. Além disso, constatou-se que o HFCT não seria adequado para o sistema de São Luís, dada a inacessibilidade do condutor de aterramento na maior parte das estruturas inspecionadas. Considerando-se também a altíssima diretividade do sensor de ultrassom, conclui-se que a antena para a detecção da radiointerferência é o sensor mais adequado para ser utilizado pela equipe de manutenção da concessionária ao se utilizar o equipamento desenvolvido pelo P&D.

4.2 ENSAIO PADRONIZADO PARA MEDIÇÃO DA CARGA APARENTE DE DESCARGAS PARCIAIS

Para a determinação do grau de severidade em isoladores e futura validação do algoritmo de classificação desenvolvido neste trabalho, foram realizados ensaios padronizados de medição da carga aparente de descargas parciais em diversas amostras de isoladores.

A carga aparente é a grandeza recomendada a ser aferida durante o ensaio de descargas parciais padronizado pela norma IEC 60270:2000 (IEC, 2015), sendo usualmente expressa em picocoulombs (pC). Existem alguns circuitos básicos sugeridos para o ensaio pelo método elétrico proposto por esta norma, porém, de uma forma geral, podem-se destacar os componentes principais deste circuito como sendo:

- Corpo de prova, podendo ser representado por um capacitor C_a ;
- Capacitor de acoplamento C_k , que deve possuir um baixo nível de descargas parciais para a tensão de ensaio;
- Sistema de medição, com sua impedância de entrada;

- Fonte de alta tensão, com baixo nível de ruído de fundo;
- Conexões de alta tensão, com baixo nível de ruído de fundo;
- Impedância ou filtro, introduzido no terminal de alta tensão da fonte para reduzir o ruído de fundo oriundo da fonte.

O sistema de medição consiste no dispositivo de acoplamento, no sistema de transmissão e no instrumento de medição. O dispositivo de acoplamento mais comumente utilizado é um quadripolo (rede ativa ou passiva de quatro terminais), o qual converte os sinais de corrente para sinais de tensão. O sistema de transmissão consiste em um cabo ou em uma conexão óptica (IEC, 2015).

Um dos circuitos para o ensaio de descargas parciais de um corpo de prova por meio do método elétrico padronizado pela norma IEC 60270:2000 (IEC, 2015) consiste na sua conexão, em paralelo com o capacitor de acoplamento, à fonte de alta tensão por meio do filtro, que impede a entrada de sinais externos de alta frequência no circuito de ensaio. Esta configuração de circuito é mostrada na Figura 19.

Quando ocorre um pulso de descarga parcial no corpo de prova, há uma diminuição abrupta na tensão sobre ele, que é compensada por uma corrente mensurável $i(t)$, fornecida pelo capacitor de acoplamento. A magnitude desta corrente depende da relação entre as capacitâncias C_a e C_k , idealmente $C_k \gg C_a$. Assim, a carga aparente q pode ser calculada como a integral do pulso de corrente (HAEFELY, 2014), conforme a equação (8).

$$q = \int i(t) dt \quad (8)$$

A carga aparente, no entanto, não representa a verdadeira quantidade envolvida no processo da descarga parcial, a qual não pode ser medida diretamente (IEC, 2015), uma vez que isso exigiria o conhecimento de todas as capacitâncias envolvidas no processo, inclusive da própria cavidade, quando se fala em uma descarga do tipo interna, por exemplo. Quanto maior a capacitância do corpo de prova, menor a carga aparente mensurável, considerando a equação (8), de forma que, neste caso, torna-se necessário o uso de instrumentos de maior sensibilidade. A carga medida externamente se trata apenas da corrente fornecida ao objeto com descargas parciais para suprir a queda de tensão provocada sobre ele devido às descargas.

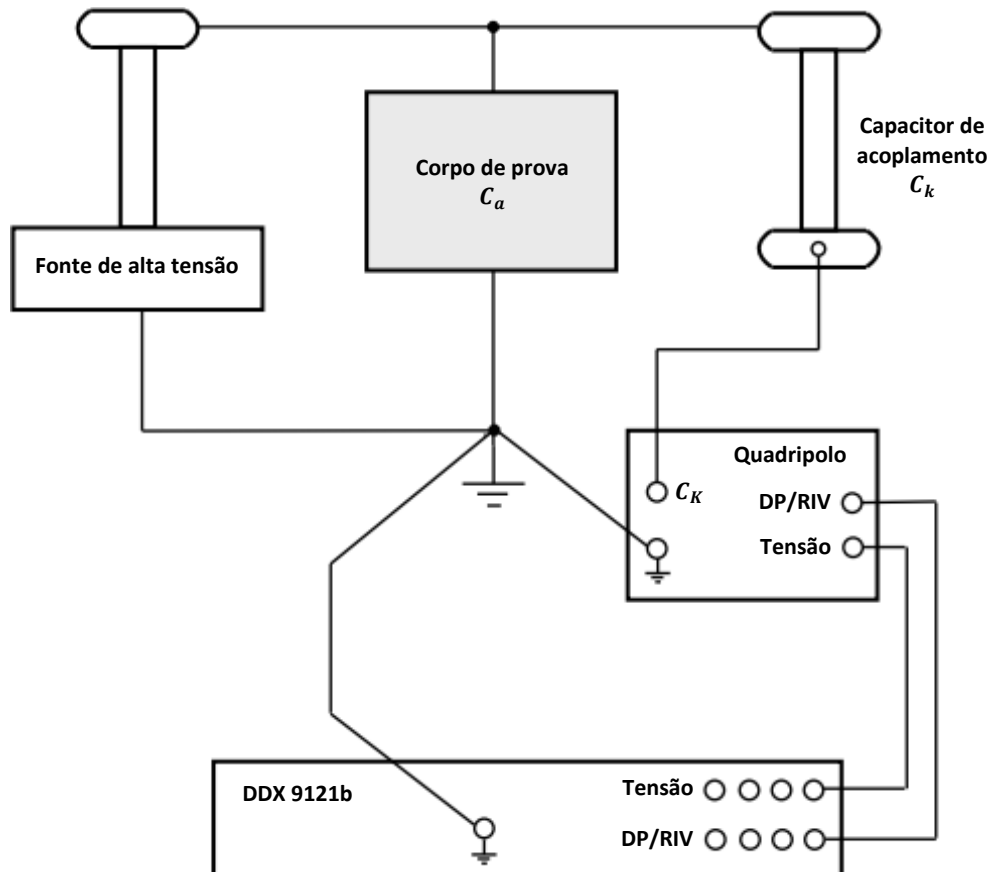


Figura 19 – Circuito de ensaio padronizado, utilizando o equipamento DDX 9121b.
Fonte: Adaptado de Haefely (2014)

Para os ensaios realizados neste estudo, foi utilizado o equipamento padronizado Tettex DDX 9121b, o qual possui uma opção de medição baseada na máxima magnitude de ocorrência de descarga parcial e a opção de indicação da magnitude de descarga parcial segundo a resposta do detector de quase pico do padrão da IEC.

Este instrumento realiza a medição e a gravação dos pulsos de descarga parcial e da tensão de ensaio, exibindo através de seu *software* a atividade de descargas parciais com resolução de fase (PRPD, do inglês: *phase-resolved partial discharge*), os valores da carga aparente medida segundo a opção selecionada, da tensão de ensaio e da frequência do sistema. A atividade pode ser exibida em uma base de tempo linear, senoidal (sincronizada com a frequência da tensão de ensaio), ou elíptica, que rotaciona de forma sincronizada com a frequência da tensão de ensaio (HAEFELY, 2014; IEC, 2015).

Para o ensaio propriamente dito, foram selecionadas, amostras de isoladores tipo bastão polimérico de ancoragem classe 15 kV. Este conjunto de amostras compreende três amostras novas e três amostras que passaram por um processo de recondicionamento. A Figura 20 mostra uma amostra recondicionada à esquerda e uma amostra nova à direita, a partir das quais é

possível se observar a perda de hidrofobicidade da amostra recondicionada em relação à amostra nova.

Além deste primeiro conjunto de amostras, foram adicionadas ao conjunto, amostras de isoladores tipo bastão polimérico de ancoragem classe 15 kV provenientes de um outro projeto desenvolvido anteriormente no laboratório. Estas últimas amostras haviam passado por um processo de envelhecimento artificial em laboratório, contemplando períodos de envelhecimento de 7.500 horas, 2.500 horas e 1.500 horas.

Os isoladores de alta tensão, geralmente, apresentam em seu catálogo a máxima tensão de radiointerferência (RIV, do inglês: *radio interference voltage*), mas não fornecem uma correlação entre este e o valor da carga aparente, obtida pelo ensaio de descargas parciais. As normas pertinentes também não indicam valores limites de carga aparente para ensaios de isoladores.



Figura 20 – Comparação da hidrofobicidade entre uma amostra recondicionada e uma nova.
Fonte: Próprio autor

Desta forma, considerando-se o procedimento apresentado pela norma IEC 60270:2000 (IEC, 2015) e tendo como base a experiência da equipe do LAT-EFEI com ensaios de descargas parciais em outros equipamentos de alta tensão, foi definida uma metodologia de ensaio que permitisse a avaliação da correlação entre o valor da carga aparente e a condição do isolador. A interface do *software* utilizado é mostrada na Figura 21.

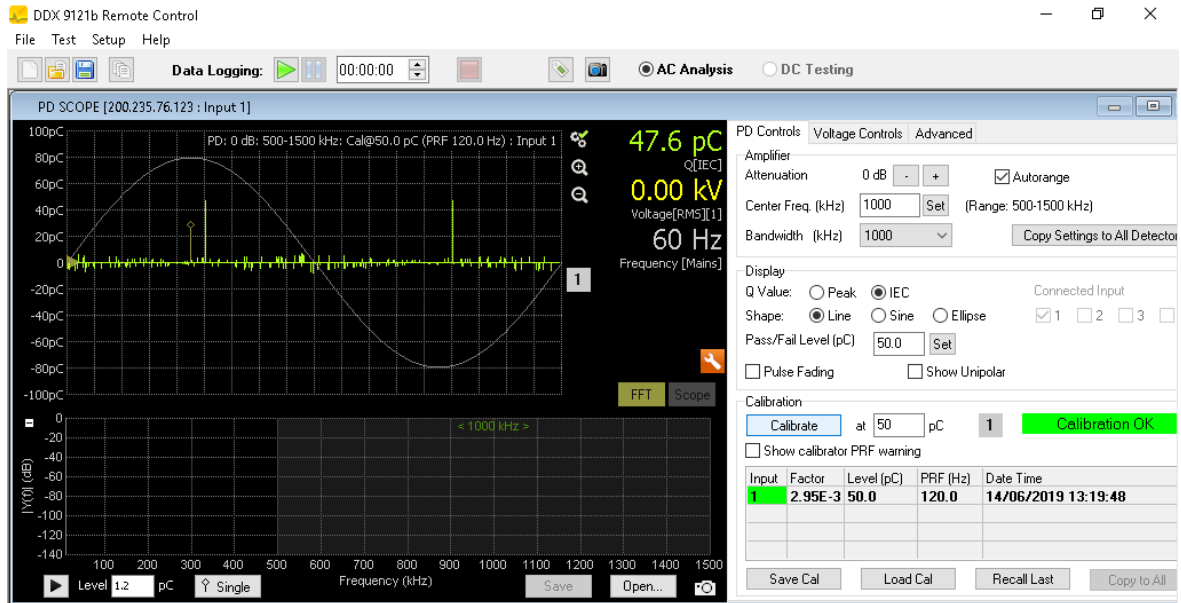


Figura 21 – Interface do programa do equipamento DDX 9121b.

Fonte: Próprio autor

O procedimento de ensaio empregado consiste, primeiramente, em submeter o isolador a uma tensão aplicada de 8 kV (tensão de fase de 1 pu) por um período de 5 minutos. Em seguida, a tensão é retirada e o corpo de prova é deixado em repouso por um período de 5 minutos. Finalmente, o corpo de prova é submetido a uma tensão aplicada de 16 kV (2 pu) por um período de 5 minutos, totalizando, assim, 15 minutos de ensaio. A Figura 22 mostra a bucha da fonte de alta tensão (esquerda), o capacitor de acoplamento, o filtro e o quadripolo (atrás), e o corpo de prova.



Figura 22 – Circuito de ensaio utilizado.

Fonte: Próprio autor

O conjunto ensaiado inicialmente totaliza dez amostras, sendo que algumas foram ensaiadas mais de uma vez, totalizando, assim, dezesseis ensaios. Sob tensão nominal aplicada, constatou-se a ocorrência de descargas parciais em 25% dos ensaios, nenhum dos casos envolvendo isoladores novos. Sob tensão aplicada de 2 pu, constatou-se a ocorrência de descargas parciais em 75% dos ensaios. A ocorrência de descargas parciais foi verificada através do valor da carga aparente e através dos pulsos exibidos no gráfico PRPD, ambos fornecidos pelo *software* do equipamento de ensaio.

Embora a partir deste ensaio não sejam coletados sinais, que são o objeto de estudo deste trabalho, este ensaio representa um passo importante no entendimento do fenômeno, visto que oferece um procedimento padronizado para a obtenção de uma grandeza representativa da condição dos isoladores. A partir deste procedimento, é possível se correlacionar o envelhecimento e a degradação das amostras à carga aparente medida. A partir disto, concluiu-se que o envelhecimento e a degradação são uma causa da intensificação da atividade de descargas parciais.

4.3 ENSAIO NÃO PADRONIZADO UTILIZANDO UM CENTELHADOR

Com o objetivo de enriquecer o banco de dados a ser utilizado para o treinamento das RNA utilizadas neste trabalho, em complemento aos ensaios realizados nos isoladores, foram feitos ensaios não padronizados simulando a descarga parcial por meio de um centelhador.

A literatura cita diversos recursos para a simulação de diferentes tipos de descarga parcial. A norma IEC 60507:2013 (IEC, 2013), por exemplo, apresenta as recomendações para o ensaio de poluição artificial de isoladores com o objetivo de se determinar a sua suportabilidade, entretanto os procedimentos descritos propiciam a ocorrência de descargas parciais, permitindo se observar descargas causadas pela poluição superficial.

Além desta norma, um dos ensaios mais simples, embora não padronizado, para a simulação de descargas parciais envolve o uso de um centelhador formado por uma seção de fio rígido em paralelo com o corpo de prova (CAPELINI, 2015), como mostra a Figura 23, conectado fisicamente a um de seus terminais, porém com um espaçamento (*gap*) de alguns milímetros para o outro, como mostra a Figura 24.

No caso do ensaio aqui descrito, foi utilizada uma cadeia de isoladores de disco cerâmico de suspensão, com o fio conectado ao pino de uma das unidades, contornando seu dielétrico, e formando o *gap* com a campânula. Ao se aplicar tensão sobre o corpo de prova, haverá centelhamento no *gap*, reproduzindo o comportamento de descargas parciais, permitindo a

avaliação de sensores. A captura de um vídeo gravado durante o ensaio é exibida na Figura 25, mostrando a ocorrência do centelhamento.



Figura 23 – Método de simulação de descargas por meio de centelhador.
Fonte: Próprio autor



Figura 24 – Detalhe do *gap* formado entre o fio e a campânula do isolador.
Fonte: Próprio autor



Figura 25 – Centelhamento ocorrendo no *gap*.
Fonte: Próprio autor

Considerando-se o desempenho negativo da blindagem de diferentes unidades de bobinas Rogowski testadas neste ensaio, foi selecionada para teste, uma unidade do transformador de corrente de alta frequência (HFCT) modelo HFCT100, fabricado pela HVPD. Considerando-se ainda o uso do centelhador, o HFCT foi testado juntamente com um sensor *shunt* resistivo de 10 k Ω conectado ao condutor de aterramento, cujo sinal de tensão seria medido por meio de um osciloscópio. Além disso, foi utilizada paralelamente, a antena log periódico do equipamento de radiofrequência *Model 242* fabricado pela *Radar Engineers*, conectada diretamente ao osciloscópio.

As respostas dos três sensores foram semelhantes, guardadas as diferenças intrínsecas de cada um deles, demonstrando o comportamento esperado para cada um deles. O resistor *shunt* detecta a totalidade de componentes do sinal da corrente de fuga, desde a forma de onda da tensão fundamental, harmônicos, ruídos de alta frequência e pulsos de descargas parciais. Com a antena de radiofrequência, a resposta foi semelhante à do resistor *shunt* com respeito ao conteúdo, porém apresentando uma amplitude tensão aproximadamente dez vezes menor.

O HFCT por sua vez, é projetado para apresentar uma resposta à faixa de 100 kHz a 20 MHz, onde se localizam as descargas parciais, de forma que os sinais da tensão fundamental e dos harmônicos não são exibidos na leitura do osciloscópio. Ao se retirar o condutor de aterramento da janela de medição do HFCT, deixando o sensor em flutuação, a resposta aos pulsos de descargas parciais foi atenuada em aproximadamente dez vezes, considerando a amplitude de tensão. Este teste leva à conclusão de que o sensor HFCT possui boa blindagem para a aplicação, uma vez que atenua suficientemente os sinais detectados por radiointerferência externa, e é adequado à faixa de frequências com a qual se deseja trabalhar.

Com relação aos sinais de descargas parciais propriamente ditos, observou-se que quanto maior a tensão aplicada, maior a taxa de repetição dos pulsos. Além disso, a variação da distância do *gap* revelou que quanto maior a distância deste, maior a tensão necessária para o início da atividade de descargas parciais e menor a taxa de repetição. Não foram observadas variações de amplitude dos pulsos medidos com a variação da tensão aplicada ao corpo de prova.

4.4 ENSAIOS PADRONIZADOS DE CHUVA E DE POLUIÇÃO ARTIFICIAL

A norma IEC 60060-1:2010 (IEC, 2010) estabelece os parâmetros para a padronização do ensaio sob chuva. O corpo de prova deve receber as gotículas de água na resistividade recomendada em igual intensidade, tanto na vertical quanto na horizontal. A norma IEC

60168:1994 (IEC, 2001), por sua vez, apresenta um procedimento de ensaio aplicável apenas a isoladores tipo pilar para uso externo e visa a determinação da tensão de suportabilidade do isolador nesta condição.

Estas normas visam a determinação da tensão de suportabilidade do corpo de prova sob chuva, o que é realizado através da observação da ocorrência de descargas disruptivas (*flashovers*). Entretanto, no caso deste trabalho, o procedimento foi seguido para a observação da ocorrência de descargas parciais nestas condições e para a aquisição de sinais para compor o conjunto de dados.

Além do ensaio do isolador sob chuva, a norma IEC 60507:2013 (IEC, 2013) especifica os parâmetros e os procedimentos de ensaio para isoladores sob condição de poluição artificial, simulando as condições de operação ao ar livre. Assim, esta norma recomenda dois métodos para o ensaio de isoladores de cerâmica e vidro a serem utilizados ao ar livre em atmosferas poluídas. O objetivo desta norma é o levantamento da suportabilidade do isolador na tensão industrial sob condição de poluição artificial. Os métodos recomendados são divididos nas seguintes categorias:

- Método da névoa salina, no qual o isolador é submetido a uma poluição ambiente;
- Método da camada sólida, no qual uma camada de poluição sólida é uniformemente depositada na superfície do isolador.

Estes procedimentos de ensaio são pertinentes para este estudo, pois o caso do município de São Luís do Maranhão envolve justamente a atividade de descargas parciais em decorrência da poluição superficial dos isoladores. Tomando-se então este estudo de caso, a posição geográfica do município, junto à linha do equador e localizado em uma ilha, faz com que haja duas estações bem definidas: seca e chuvosa. A estação da chuva se inicia em janeiro e vai até o mês de julho, enquanto de agosto a dezembro ocorre o período da seca. Entretanto, embora haja uma diferença significativa na precipitação entre estes dois períodos, conforme mostra a Tabela 1, a umidade relativa do ar permanece elevada ao longo de todo ano, variando pouco, para mais ou para menos, da média anual de 82,8% (INMET, 2020).

Este comportamento climático faz com que os isoladores do município de São Luís acumulem mais poluição no período de estiagem, uma vez que a precipitação é baixa demais – sendo a chuva o auxílio natural na lavagem da superfície dos isoladores. Contudo, devido à umidade relativa constantemente elevada¹⁰ mesmo no período de estiagem, a sua combinação

¹⁰ Outros fatores que também contribuem são chuvas breves e/ou leves, orvalho, hora do dia, direção do vento, entre outros. A queda de temperatura no período da noite leva à condensação da umidade da superfície do isolador. A direção do vento muda de acordo com a hora do dia, podendo trazer mais ou menos umidade e sal do oceano.

com a poluição depositada na superfície do isolador leva à formação da camada condutiva que intensifica a corrente de fuga e desencadeia o surgimento das bandas secas e da atividade de descargas parciais.

A intensificação destes fenômenos aliada à condição de degradação da superfície do isolador pode acarretar eventos de *flashover*, podendo ainda causar faltas e interrupções no fornecimento de energia elétrica.

Tabela 1 – Dados climáticos para a cidade de São Luís do Maranhão

| | Período | |
|--------------------------------------|---------|---------|
| | Jan-Jul | Ago-Dez |
| Média da precipitação acumulada (mm) | 296,5 | 24,8 |
| Média da umidade relativa do ar (%) | 85,9 | 78,3 |

Fonte: INMET, 2020

Desta forma, do ponto de vista de representação em laboratório do comportamento dos isoladores em operação em campo, os ensaios mais significativos são os de poluição artificial, e, portanto, a norma a ser empregada para uma parte significativa dos ensaios em laboratório seria a IEC 60507:2013 (IEC, 2013). No caso deste estudo, contudo, a norma foi utilizada apenas como base para os procedimentos de ensaio e para se obter os valores padrão da concentração de cloreto de sódio (NaCl) da solução empregada na névoa salina, da concentração de caulim (silicato de alumínio) utilizada no método da camada sólida e os valores normalizados de vazão de névoa no interior da câmara de ensaio.

Para o método da névoa salina, a solução a ser utilizada na névoa deve ser obtida a partir de água e cloreto de sódio (NaCl) nas concentrações recomendadas pela norma, as quais podem ser medidas por meio de um condutivímetro. O isolador deve ser submetido à névoa no interior de uma câmara de ensaio e a tensão deve ser aplicada, respeitando-se as recomendações e procedimentos da norma. Para os ensaios realizados neste estudo foram selecionadas as seguintes concentrações para a solução:

- 2,5 kg/m³;
- 40 kg/m³;
- 80 kg/m³.

Os ensaios envolvem o uso de uma câmara de chuva e névoa, dentro da qual o isolador é submetido às condições padronizadas representativas da sua condição de operação em atmosferas poluídas, como mostra a Figura 26. Embora os isoladores do sistema elétrico de São Luís sejam em sua maioria poliméricos, do tipo pilar ou suspensão, por questão de disponibilidade no laboratório, uma única unidade de isolador de disco cerâmico com pino e campânula foi inicialmente ensaiada. O procedimento completo de ensaio descrito pela norma

foi seguido, visando a determinação da tensão de suportabilidade do isolador, tanto sob chuva, quanto sob poluição pelo método da névoa salina, como mostra a Figura 27.

Em seguida, focando-se no objetivo do estudo em desenvolvimento, foi inserido um sensor *shunt* resistivo conectado ao condutor de aterramento do isolador para a aquisição dos sinais da corrente de fuga por meio de um osciloscópio de bancada. O procedimento completo de ensaio permitiu a criação de um conjunto de dados amplo, contendo diversos sinais da corrente de fuga com a presença de descargas parciais do tipo superficial devido à poluição por névoa salina. A Figura 28 mostra o centelhamento ocorrendo no corpo de prova sob ensaio.



Figura 26 – Amostra de isolador após ensaio de chuva dentro da câmara de ensaio.
Fonte: Próprio autor



Figura 27 – Amostra de isolador sob névoa salina dentro da câmara de ensaio.
Fonte: Próprio autor




Figura 28 – Centelhamento ocorrendo no corpo de prova durante ensaio de névoa salina.
Fonte: Próprio autor

Este método de ensaio foi mais significativo com respeito à atividade de descargas parciais quando comparado ao ensaio de chuva. A partir dos resultados deste ensaio e dos sinais nele coletados, foram dados os primeiros passos no desenvolvimento do algoritmo. As primeiras arquiteturas de redes neurais foram testadas, visando a comparação entre o modelo MLP e o modelo convolucional, e a seleção do conjunto de hiperparâmetros que otimizariam seu desempenho.

Para o método da camada sólida descrito pela norma, o ensaio deve empregar uma suspensão que deve ser preparada à base de diatomito ou caulim. Para este estudo, foi utilizado o caulim, seguindo a seguinte proporção:

- 40 g de caulim;
- 1.000 g de água;
- Uma quantidade adequada de cloreto de sódio (NaCl).

O caulim é uma argila inerte, formada por dióxido de silício (SiO_2), óxido de alumínio (Al_2O_3), óxido de ferro (Fe_2O_3) e água (H_2O), e sua granulometria varia de 0,1 a 10 μm . Por ser um material inerte, ele permite a distribuição do cloreto de sódio sobre a superfície do isolador e impede a interação deste com a água durante a aplicação da névoa, mantendo a uniformidade da distribuição da poluição e impedindo que ela se dissolva e escorra.

A norma fornece uma tabela com valores de referência de poluição baseados na densidade do depósito de sal (DDS), medido em miligramas por centímetro quadrado (mg/cm^2), e na condutividade da camada, medida em micro-siemens (μS), e apresenta a condutividade volumétrica equivalente para a suspensão, medida em Siemens por metro (S/m). Para atingir o

grau de poluição, a condutividade da suspensão a ser aplicada sobre a superfície do isolador deve ser medida, ajustando-se a quantidade de cloreto de sódio conforme a necessidade.

A suspensão deve ser aplicada por meio de um pulverizador ou derramando-a sobre a superfície previamente limpa do isolador. Quando a camada de contaminação estiver seca, o grau de poluição do isolador deve ser determinado por meio de uma das duas grandezas descritas pela norma: a condutividade da camada ou a densidade do depósito de sal (DDS). Para este estudo foi utilizada a segunda grandeza.

A determinação consiste em remover e coletar a contaminação depositada sobre a superfície de uma segunda amostra contaminada da mesma maneira que a amostra a ser ensaiada. Alternativamente, tendo-se apenas uma única amostra, pode-se realizar a coleta do depósito de contaminação a partir de algumas saias para o cálculo da densidade do depósito de sal e, em seguida, reaplicar a camada de contaminação sobre a superfície limpa.

O corpo de prova contendo a camada sólida de poluição sobre a sua superfície deve então ser colocado no interior de uma câmara e submetido a uma névoa uniforme que o envolva totalmente. A aplicação da névoa deve ser mantida constante durante todo o período do ensaio, de tal forma que, a partir de um certo momento, haja uma condensação da névoa sobre a camada de contaminação.

Da mesma forma que o ensaio anterior, o procedimento do método da camada sólida tem como objetivo o levantamento da suportabilidade e/ou da tensão de *flashover* dos isoladores mediante diferentes condições de operação (chuva, poluição e umidade). Entretanto, este procedimento foi modificado e, a partir dele, uma metodologia é proposta a seguir, tendo como objetivos a reprodução da condição de poluição específica do município de São Luís e a aquisição de sinais para o desenvolvimento e validação dos algoritmos.

Assim, foram realizados ensaios no LAT-EFEI consistindo na submissão de algumas amostras de isoladores degradados provenientes de São Luís a um ensaio de tensão aplicada sob névoa, seguindo o método da camada sólida. As amostras são isoladores do tipo pilar polimérico classe 69 kV, removidos de campo, com forte contaminação do silicone e perda da hidrofobicidade, além de marcas de centelhamento e oxidação nas ferragens. Uma das amostras ensaiadas é mostrada na Figura 29.



Figura 29 – Amostra de isolador tipo pilar polimérico classe 69 kV.
Fonte: Próprio autor

O caulim foi utilizado no ensaio em uma proporção diferente da recomendada pela norma, resultando em uma suspensão mais densa. Esta medida foi tomada, considerando-se a dificuldade da aplicação da camada de poluição, devido à hidrofobicidade da superfície polimérica, ainda que já degradada, problema este que é investigado por Engelbrecht et al. (2013).

Além disso, o cenário ideal seria a utilização de parâmetros reais de contaminação da cidade de São Luís. Esta contaminação deve ser medida pela densidade do depósito de sal equivalente (DDSE). Esta grandeza representa a razão da quantidade de NaCl pela área da superfície do isolador que, quando dissolvida em água, produziria uma solução com a mesma condutividade da solução contendo os contaminantes coletados em uma superfície de mesma área.

Em sua tese de doutorado, Monteiro Porfírio (2018) conduziu um estudo a respeito dos efeitos do clima sobre isoladores de alta tensão, sendo seu caso de estudo, justamente, a cidade de São Luís, juntamente com os municípios de Belém e Barcarena, no Pará. Como já apresentado na Tabela 1, São Luís possui duas estações bem definidas, caracterizadas por um inverno chuvoso e verão seco, com temperaturas médias praticamente constantes ao longo de todo o ano. Dentro da estação seca, de julho a dezembro, o mês de outubro destaca-se como o mais seco, segundo a média histórica do INMET (2020), apresentando também a maior deposição acumulada de contaminação sobre os isoladores.

A metodologia utilizada por Monteiro Porfírio (2018) emprega coletores na forma de tubos com fendas longitudinais, posicionados a 5 metros do solo. Em cada ponto de afiação,

são utilizados quatro tubos direcionados para os quatro pontos cardeais. O material das amostras de poluição coletado no interior dos tubos é então dividido entre solúvel e não solúvel por um processo de filtragem. A partir do material solúvel, a condutividade em $\mu\text{S}\cdot\text{cm}^{-1}$ é medida e então convertida para o valor de DDSE em $\text{mg}\cdot\text{m}^{-2}\cdot\text{dia}^{-1}$, considerando-se a área da fenda dos coletores, o volume de água utilizado e o período de coleta. A norma apresenta os cálculos para esta conversão a partir do valor da condutividade da solução, de onde se obtém os valores da salinidade e do DDSE.

Quando o DDSE é calculado para um material resultante de coleta em campo, ele representa a quantidade de sais solúveis de ocorrência natural que se depositaram sobre a superfície analisada. Em laboratório o sal utilizado para o ensaio é o cloreto de sódio (NaCl) e, portanto, o DDSE representa a quantidade desta substância distribuída sobre a superfície do isolador. Portanto, o valor do DDSE pode ser utilizado tanto para a obtenção de uma medida quantitativa da poluição depositada sobre o isolador, quanto para se realizar o caminho inverso, isto é, para se determinar a quantidade de NaCl a ser utilizada no ensaio, baseada em um nível de poluição apresentado em campo.

Desta forma, tomando-se os valores de DDSE obtidos no estudo de Monteiro Porfírio (2018) como referência e considerando-se a área da superfície das amostras de isoladores poliméricos tipo pilar utilizados neste estudo, é possível se obter algumas quantidades de NaCl para serem utilizadas no ensaio de poluição artificial pelo método da camada sólida recomendado pela IEC 60507:2013 (IEC, 2013).

Os valores de DDSE selecionados são relativos ao período de julho a outubro (cumulativo) e ao mês de outubro apenas, a partir dos quais as respectivas quantidades de NaCl são calculadas¹¹. A partir destas quantidades de NaCl, por sua vez, foram calculadas, quantidades parciais, correspondendo a períodos parciais dentro da estação seca, sendo estes: metade do período de julho a outubro, metade do mês de outubro (aproximadamente duas semanas) e um quarto do mês de outubro (aproximadamente uma semana), conforme mostra a Tabela 2.

Considerando-se a área calculada da superfície das amostras de isoladores deste estudo igual a $12.865,55\text{ cm}^2$, foi preparada uma suspensão composta pela respectiva quantidade de sal descrita na Tabela 2, 61,1 g de água e 67,2 g de caulim, formando uma pasta fluida. Todas as massas foram aferidas por meio de uma balança.

¹¹ Os valores de NaCl foram calculados com uma margem de 20% para mais, considerando-se possíveis perdas na aplicação da camada sobre a amostra, com base em medições do DDSE realizadas a partir de raspagem da camada aplicada sobre as amostras.

Tabela 2 – Valores de referência do DDSE por período e da quantidade de sal utilizada

| Período | DDSE (mg/cm ²) | Massa de NaCl (g) |
|-------------|----------------------------|-------------------|
| Jul-Out | 0,614 | 9,48 |
| 50% Jul-Out | - | 4,74 |
| Out | 0,197 | 3,05 |
| 50% Out | - | 1,52 |
| 25% Out | - | 0,76 |

Fonte: Monteiro Porfírio (2018)

A respectiva quantidade de sal foi inicialmente dissolvida apenas no volume de água, para garantir a sua total dissolução, e o caulim foi então adicionado à solução em seguida. A aplicação da pasta sobre a amostra de isolador foi feita utilizando-se um pincel e um soprador térmico, como mostra a Figura 30(a), apenas para fixar a pasta e evitar que ela escorresse – a secagem da camada foi feita de forma natural, uma vez que, com o uso do soprador, a camada forma lâminas que se desprendem da superfície polimérica do isolador.

A suspensão preparada foi suficiente para cobrir totalmente a superfície de uma amostra de isolador, incluindo suas ferragens, a camisa polimérica e os lados superior e inferior das saias poliméricas, resultando na cobertura mostrada na Figura 30(b). Uma comparação entre uma amostra sem contaminação (esquerda) e uma amostra contaminada (direita) é mostrada na Figura 31.




Figura 30 – Método da camada sólida: (a) aplicação da suspensão; (b) amostra contaminada.
Fonte: Próprio autor



Figura 31 – Comparação entre a amostra sem contaminação (esquerda) e a amostra contaminada (direita).
Fonte: Próprio autor

A câmara de ensaio utilizada é a mostrada na Figura 32. Trata-se de uma câmara metálica não hermética, dentro da qual foram ligados dois nebulizadores domésticos a ultrassom na metade da sua intensidade máxima, como mostrado na Figura 33. Para o ensaio, as portas da câmara foram deixadas abertas, porém a abertura foi coberta com uma lona plástica transparente com o objetivo de manter a névoa confinada no interior da câmara, manter a visibilidade do corpo de prova e do higrômetro para a medição da umidade relativa, e para evitar a atenuação que os sinais poderiam sofrer através da porta metálica aterrada.




Figura 32 – Câmara de ensaio e antena utilizada com sensor de descargas parciais.
Fonte: Próprio autor



Figura 33 – Interior da câmara de ensaio, mostrando os nebulizadores e o desumidificador.

Fonte: Próprio autor

Entretanto, a bucha utilizada para se aplicar tensão ao corpo de prova apresentou ruídos ao ser energizada. Desta forma, o que se fez foi posicionar um tubo de náilon através da lona plástica, passando-se o condutor de alta tensão através do seu furo, permitindo, assim, a conexão direta entre a fonte de alta tensão e o corpo de prova, como mostrado na Figura 34 e na Figura 35.

O tubo foi suspenso por meio de um fio de náilon, de forma a evitar descargas parciais no próprio tubo. Esta alternativa solucionou o problema causado pela introdução de descargas parciais pelo próprio circuito de ensaio. Desta forma, ao se energizar o isolador seco, sem névoa no interior da câmara, os únicos sinais coletados foram ruídos externos, incapazes de interferir significativamente no ensaio.

Uma vez seca, a amostra contaminada foi então colocada no interior da câmara e os nebulizadores foram ligados até que a umidade relativa no interior da câmara atingisse um valor superior a 85% e um leve acúmulo de umidade na camada de poluição fosse observado. Em seguida, os nebulizadores foram desligados e a tensão nominal foi aplicada sobre o corpo de prova.

Ao se iniciar o monitoramento da atividade de descargas parciais por meio da antena desenvolvida, o fenômeno foi finalmente observado com padrão muito semelhante ao da ocorrência em isoladores contaminados em campo. Além disso, centelhamento visível foi observado entre as saias do isolador sob ensaio, como mostra a Figura 36, chegando a evoluir para arcos mais extensos, próximos de um *flashover*, como o mostrado na Figura 37. Após estes ensaios, como consequência do acúmulo de umidade sobre a superfície do isolador aliado ao

centelhamento, a camada de contaminação chegou a ser removida, como mostra a Figura 38 e a Figura 39.



Figura 34 – Configuração final da câmara de ensaio com o tubo de náilon.
Fonte: Próprio autor



Figura 35 – Antena apontada para a amostra a ser ensaiada.
Fonte: Próprio autor




Figura 36 – Centelhamento entre as saias do corpo de prova.
Fonte: Capelini (2020)¹²



Figura 37 – Arco voltaico sobre o corpo de prova.
Fonte: Capelini (2020)¹²

¹² Captura de vídeo do ensaio, cedida por Renato Massoni Capelini, 19 maio 2020.



Figura 38 – Consequência do ensaio sobre a camada de contaminação.
Fonte: Próprio autor



Figura 39 – Consequência do ensaio sobre a camada de contaminação.
Fonte: Próprio autor

Este ensaio, portanto, produziu os resultados mais significativos do ponto de vista da reprodução em laboratório do fenômeno observado em campo. Tanto o método de ensaio pela camada sólida, quanto os valores de DDSE de São Luís, contribuíram para a formação de um conjunto de dados variado, com padrões muito semelhantes aos dos sinais coletados em campo, permitindo assim a avaliação, calibração e validação do algoritmo desenvolvido.

4.5 AQUISIÇÃO E ANÁLISE DE SINAIS DE DESCARGAS PARCIAIS

Além da avaliação dos sensores, os ensaios realizados também tiveram como objetivo a aquisição de sinais para a criação de um conjunto de dados. Este conjunto é a base para o treinamento da rede neural e o desenvolvimento do algoritmo, e é a partir dele que foram calculados os parâmetros para se obter o grau de severidade de descargas parciais.

Para a aquisição, foi utilizada a placa de aquisição de dados (osciloscópio USB para computador) PicoScope modelo 2206B, mostrada na Figura 40, dotada de dois canais, com uma largura de banda de 50 MHz, memória *buffer* de 32 MS e taxa máxima de amostragem de 500 MS/s. A PicoScope, através de seu *software*, permite sua utilização como osciloscópio com os mesmos recursos de um equipamento de bancada. Contudo, através do pacote Python “pico-python”, foi implementada, através de linguagem de programação, a aquisição instantânea do sinal a ser avaliado pelos algoritmos de análise desenvolvidos.

Durante os ensaios, as amostras de cada sinal foram salvas no formato CSV (*comma-separated values*, ou valores separados por vírgulas) e as formas de onda dos sinais foram salvas como imagens no formato PNG (*portable network graphics*). Durante a execução dos algoritmos, um módulo de aquisição realiza a configuração da placa e do canal a ser utilizado e coleta as amostras do sinal.

A aquisição em ambos os casos é realizada com uma janela de 50 ms com um intervalo de amostragem de 8 ns, a qual resulta em um sinal de 6,25 MS comportando três ciclos da tensão fundamental de 60 Hz. Segundo o teorema da amostragem de Nyquist, estes parâmetros possibilitam a aquisição de sinais de até 62,5 MHz.



Figura 40 – PicoScope modelo 2206B e sua conexão a um computador pessoal.
Fonte: Newark (2020); Elektor Magazine (2016)

Embora a análise destes sinais, do ponto de vista dos parâmetros para o cálculo do grau de severidade, seja realizada a partir dos dados no domínio do tempo, a rede neural convolucional bidimensional, utilizada para a classificação dos sinais, utiliza os dados no domínio tempo-frequência, denominado espectrograma do sinal. Estes espectrogramas foram obtidos por meio do pacote de processamento de sinais SciPy, o qual disponibiliza uma função que realiza a transformada de Fourier de curto termo (STFT), a qual resulta nos espectrogramas desejados. Cada sinal é dividido em três, de forma a se obter três sinais respectivos a um único ciclo da tensão fundamental de 60 Hz, e a partir de cada um destes é obtido um espectrograma.

A STFT possui como desvantagem o tamanho fixo da janela utilizada na decomposição das diferentes componentes de frequências, de forma que o tamanho desta janela está diretamente relacionado à resolução do espectrograma. Uma janela mais larga resulta em uma boa resolução de frequência, mas baixa resolução de tempo; uma janela mais estreita resulta em uma boa resolução de tempo, mas baixa resolução de frequência.

Entretanto, a STFT é amplamente utilizada para análise de gravações de voz com o objetivo de reconhecimento de voz e processamento da linguagem natural por algoritmos de inteligência artificial. Além disso, a STFT também já foi aplicada para a análise de sinais de descargas parciais em algoritmos de aprendizado de máquina. Portanto, este estudo buscou encontrar a melhor resolução, tanto de tempo quanto de frequência, que permitisse à rede neural identificar os padrões contidos nos espectrogramas para assim classificar os dados conforme o desejado.

Os espectrogramas gerados possuem as dimensões 151×857 , isto é, são matrizes com 151 linhas contendo informações a respeito do conteúdo de frequências do sinal, e 857 colunas contendo informações a respeito do conteúdo temporal do sinal. Em outras palavras, a matriz pode ser representada como um gráfico bidimensional cujo eixo vertical representa a frequência, o eixo horizontal representa o tempo e as intensidades são representadas por uma escala de cores, conforme mostra o exemplo da Figura 41, onde os tons de violeta representam as magnitudes mais baixas e o amarelo representa as magnitudes mais elevadas.

Alternativamente, a matriz pode ser representada como um gráfico tridimensional, mas, ao invés da representação da magnitude por meio de cores, estas são representadas na terceira dimensão, formando então uma superfície.

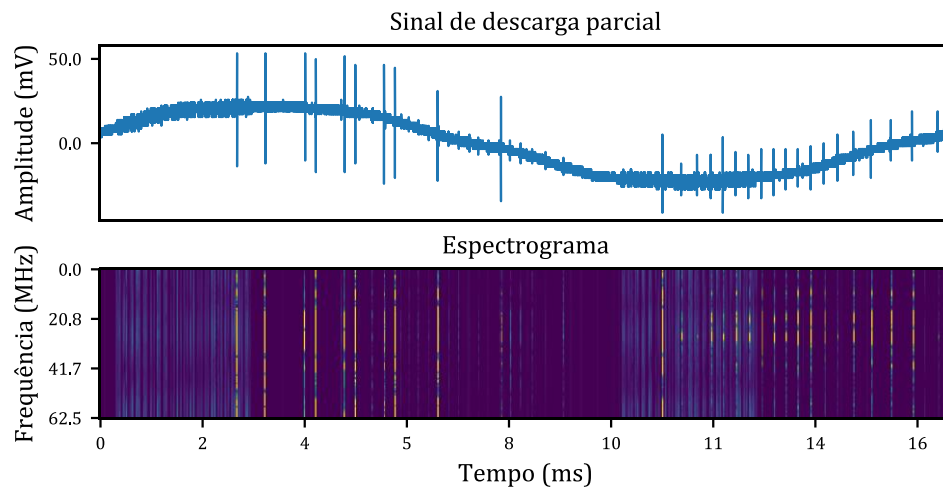


Figura 41 – Exemplo de um sinal contendo descargas parciais e seu respectivo espectrograma.
Fonte: Próprio autor

CAPÍTULO 5 – DESENVOLVIMENTO DOS ALGORITMOS

Os algoritmos desenvolvidos para este estudo podem ser divididos, de forma macro, em dois passos: aquisição e análise dos dados. Todo o código foi escrito na linguagem de programação Python 3, que é, atualmente, uma das linguagens mais utilizadas para ciência de dados e aprendizado de máquina. O motivo para isto está no alto nível da linguagem, oferecendo grande legibilidade, na sua estabilidade e flexibilidade e na vasta gama de pacotes, bibliotecas e *frameworks*, gratuitos e de código aberto, para o desenvolvimento de diversas aplicações.

O ambiente de desenvolvimento utilizado para a implementação do código Python foi o Jupyter Notebook, uma interface *web* interativa, disponibilizada através da distribuição Anaconda. Neste caso, o Jupyter foi utilizado, tendo como *backend (kernel)*, o IPython, um interpretador para a linguagem Python.

Uma das bibliotecas mais utilizadas no desenvolvimento deste estudo foi o denominado “ecossistema” SciPy, o qual dispõe de uma série de pacotes de código aberto voltados a matemática, ciência e engenharia, dos quais, foram utilizados os seguintes:

- NumPy – pacote para manipulação de *arrays* de dados multidimensionais;
- SciPy – pacote para computação científica e processamento de sinais;
- Matplotlib – pacote para geração de gráficos;
- Pandas – pacote para manipulação de estruturas de dados;
- IPython – um *shell* interativo para Python e um *kernel* para o Jupyter Notebook.

Adicionalmente, foram também utilizados o pacote “pico-python”, para comunicação com a placa de aquisição de dados PicoScope, o pacote PyWavelets, para implementação de transformadas *wavelet*, e o *toolbox* SciKit-Fuzzy para implementação do sistema de inferência *fuzzy*.

O desenvolvimento das redes neurais artificiais foi realizado com o auxílio da biblioteca Keras, um *framework* que fornece código Python legível de alto nível para a implementação de modelos de redes neurais artificiais. O Keras proporciona a criação de modelos de aprendizado profundo com camadas organizadas em modo sequencial, a configuração do seu processo de aprendizagem, o seu treinamento e avaliação, e a geração de previsões a partir de novos dados.

O Keras se integra com bibliotecas de menor nível e permite o treinamento tanto na CPU quanto na GPU. Os *backends* disponíveis para esta integração são: o TensorFlow do Google, o CNTK da Microsoft e o Theano. Neste estudo, foi utilizado o TensorFlow, uma biblioteca de código aberto para manipulação de tensores e aprendizado de máquina desenvolvida pela

equipe de engenheiros e pesquisadores do grupo de pesquisa em aprendizado de máquina do Google, com alta adoção pela indústria. Além disso, o TensorFlow permite o uso de GPUs da NVIDIA para a aceleração do processo de treinamento. Hoje, o Keras é disponibilizado juntamente com o TensorFlow e tornou-se seu *frontend* oficial.

O fluxograma geral dos algoritmos é mostrado na Figura 42. Nas seções seguintes deste capítulo, os módulos são descritos de forma mais detalhada.

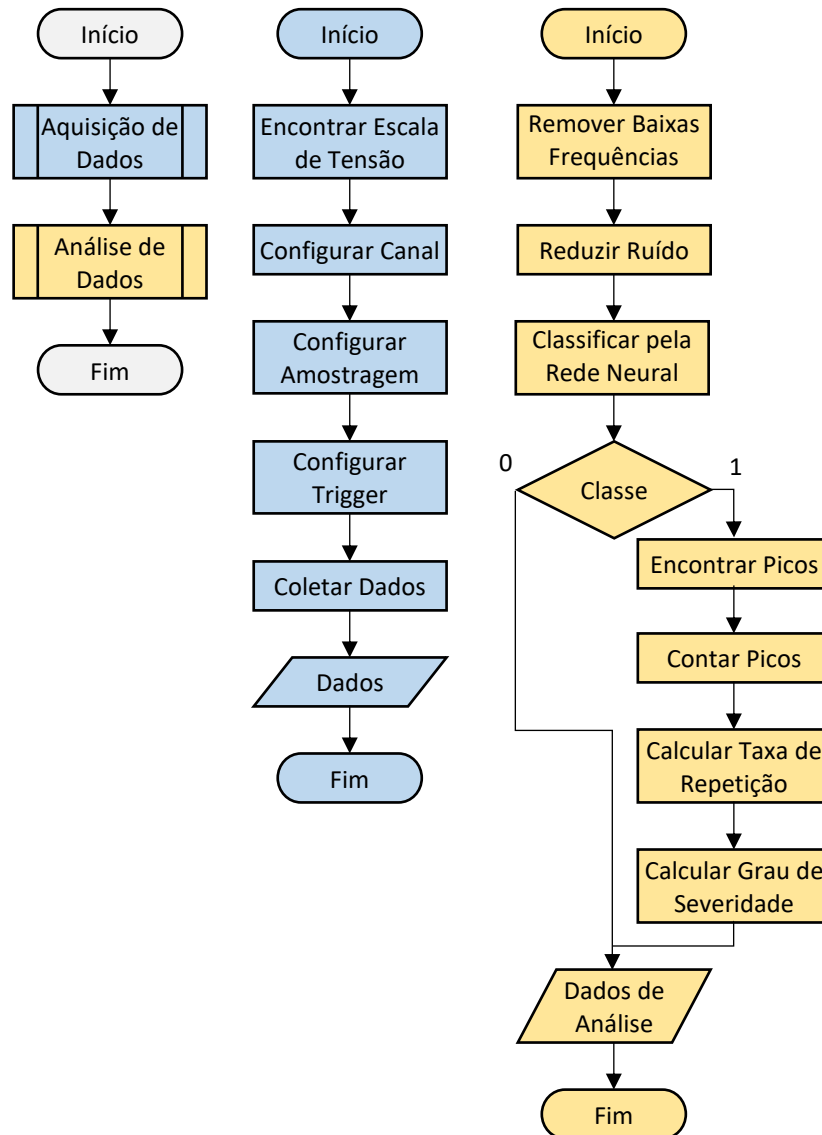


Figura 42 – Fluxograma dos algoritmos desenvolvidos.
Fonte: Próprio autor

5.1 AQUISIÇÃO DE DADOS

O primeiro passo na execução dos algoritmos consiste na configuração dos parâmetros de aquisição de dados e na aquisição propriamente dita. O pacote “pico-python” foi desenvolvido por O’Flynn e Harfouche (2013), e permite a configuração dos parâmetros da

PicoScope com o auxílio dos *drivers* disponibilizados pelo fabricante, permitindo acessar as funcionalidades de baixo nível da placa.

Inicialmente, o respectivo canal da placa deve ser habilitado ou desabilitado, conforme a necessidade. Da mesma forma como um osciloscópio de bancada é configurado, a placa deve ser configurada com relação ao seu tipo de acoplamento (AC ou DC), escala vertical e valor de *offset*. Em seguida, são configurados os parâmetros da escala horizontal, como taxa de amostragem e janela de aquisição.

Além disso, o trigger também é configurado, com relação ao seu canal de origem, valor e borda de detecção. A biblioteca utilizada, no entanto, não possibilita o uso de uma escala vertical automática, de forma que foi necessária a implementação de uma função para possibilitar o ajuste da escala para melhor exibição do sinal coletado.

A maior escala disponível para o modelo da PicoScope utilizada é a de 20 V. Desta forma, a função realiza uma amostragem com janela de 1 segundo, buscando o maior valor medido dentro desta janela. Caso o valor seja inferior a 2 V, é realizada uma nova amostragem com janela de 1 segundo, utilizando agora a escala de 2 V, buscando novamente o maior valor. Caso este valor seja inferior a 200 mV, é realizada uma nova amostragem com janela de 1 segundo, utilizando agora a escala de 200 mV.

O maior valor medido obtido após este procedimento é selecionado com uma margem de 5% para mais como o valor a ser utilizado na aquisição do sinal. Este valor é enviado como argumento para a função de configuração do canal do osciloscópio, a qual irá determinar a menor escala capaz de comportar este valor, não sendo, necessariamente, uma das três utilizadas na função anterior, uma vez que existem outros valores de escalas intermediárias.

A aquisição do sinal é então realizada a uma taxa de amostragem de 125 MS/s, coletando 6,25 MS em uma janela de 50 ms. Este sinal é então retornado pelo módulo de aquisição na forma de um *array* para posterior classificação e análise.

5.2 ANÁLISE DOS DADOS

Uma vez obtido o *array* contendo as amostras do sinal coletado, este é enviado para a função de análise de dados, que, por sua vez, faz uso de três módulos, descritos a seguir. A preparação dos dados se inicia utilizando-se a transformada *wavelet* discreta através do pacote PyWavelets (LEE et al., 2019), o primeiro módulo realiza uma decomposição multinível do sinal, de forma a se obter seus diversos coeficientes *wavelet*.

Através desta decomposição, são eliminados os coeficientes respectivos aos componentes de baixas frequências, como a forma de onda fundamental da tensão e seus harmônicos de baixa ordem. Além disso, também é realizada uma diminuição do ruído e é aplicado um limiar (*threshold*) sobre o sinal, de forma a eliminar o ruído de fundo e manter apenas os pulsos de descargas parciais. O sinal é então reconstruído e o que se obtém é o sinal novamente no domínio do tempo, porém sem as componentes de baixas frequências e com o nível de ruído reduzido.

O sinal é então enviado para o segundo módulo, a etapa de classificação pela rede neural, que irá dividir o *array* original do sinal em três sub-*arrays*. Isto é, o sinal no domínio do tempo, originalmente contendo o equivalente a três ciclos da tensão fundamental, é subdividido em três sinais, cada um dos quais equivalente a um ciclo da tensão fundamental. A partir destes sinais, são então gerados os respectivos espectrogramas através da função STFT do pacote SciPy. Foram selecionados os parâmetros da janela da STFT de forma a se obter uma matriz com dimensões 151×857 , isto é, 151 subdivisões de frequência e 857 subdivisões de tempo.

Desta forma, os dados coletados originalmente no domínio do tempo estão preparados, na forma de espectrogramas, para serem classificados pela rede convolucional. Estes espectrogramas são apresentados à rede neural, que, por sua vez, apresenta em sua saída o grau de pertinência (probabilidade com valor variando de 0 a 1) com o qual o sinal pertence a uma das duas classes.

A primeira classe definida (indicada por 0) representa ausência de pulsos de descargas parciais ou padrões de pulsos que não se deseja analisar; a segunda classe (indicada por 1) representa a presença de pulsos de descargas parciais e permite a sua análise detalhada. A maior probabilidade é selecionada e um limiar é aplicado, realizando, assim, a classificação do sinal.

O motivo para se selecionar a maior probabilidade leva em conta a possibilidade de um ou dois dos sinais não estar apresentando ocorrência de pulsos naquele instante, dada a natureza aleatória das descargas parciais. Portanto, considerando o princípio de classificação do sinal, basta uma de suas subdivisões apresentar ocorrência de descargas parciais para que ele seja classificado como 1.

As redes neurais são amplamente utilizadas para tarefas de regressão, variando em seu objetivo segundo a função de ativação da camada de saída. Redes neurais com o objetivo de obter modelos estimadores para realizar previsões, por exemplo, frequentemente empregam uma função de ativação linear, aproximando o comportamento das variáveis de entrada a uma reta e fornecendo um valor numérico quantitativo.

Alternativamente à regressão linear, existem as tarefas de regressão logística, que, por sua vez, empregam a função sigmoide logística no neurônio de saída, que é o caso da rede neural deste estudo. O valor numérico fornecido pela saída do modelo, neste caso, está associado à probabilidade de que o dado de entrada pertença a uma determinada classe.

Os modelos de regressão logística são ferramentas para se implementar tarefas de classificação, mas não são, *per se*, modelos de classificação. A tarefa de classificação é implementada ao se aplicar um limiar de decisão sobre a curva sigmoide, sobre as probabilidades fornecidas pelo modelo de regressão logística.

A função sigmoide logística é utilizada em alternativa à função de Heaviside por ser suave, isto é, diferenciável em todo o seu domínio. A função de Heaviside, além de possuir uma descontinuidade em $x = 0$, possui derivada igual a 0 para todos os outros valores do domínio, dificultando a implementação de algoritmos de aprendizagem baseados no gradiente descendente.

O modelo de rede neural implementado neste trabalho é baseado na arquitetura das redes convolucionais bidimensionais, que são utilizadas amplamente para tarefas de reconhecimento de imagens e visão computacional. Uma rede convolucional típica compreende uma sequência de camadas convolucionais intercaladas com camadas de *pooling*.

Os aspectos mais importantes de uma camada convolucional são *stride*, *padding* e as dimensões do *kernel* do filtro. No modelo implementado, é utilizado *zero-padding* para permitir a convolução do filtro sobre todo o dado de entrada. Além disso, foram utilizados filtros com *kernel* de dimensões 3×3 em todas as camadas convolucionais, porém em diferentes quantidades em cada camada, iniciando-se com dezesseis filtros nas camadas mais rasas e dobrando-se este valor ao longo da sequência de camadas até se atingir 128 filtros nas camadas mais profundas.

As dimensões do *kernel*, o uso de *padding* e o tamanho do *stride* impactam diretamente nas dimensões do dado de entrada ao longo das camadas. Contudo, quando se considera uma camada convolucional imediatamente seguida por uma camada de *pooling*, pode-se, alternativamente, utilizar apenas a camada convolucional configurada com um valor de *stride* maior do que 1, eliminando-se a camada de *pooling*. Desta forma, o modelo foi implementado com *stride* igual a 1 em todas as camadas convolucionais seguidas por outra camada convolucional, e com *stride* igual a 2 em todas as camadas convolucionais que seriam seguidas por uma camada de *pooling*.

Em suma, o modelo implementado utiliza quatro camadas convolucionais com *stride* igual a 1 intercaladas com outras quatro camadas convolucionais com *stride* igual a 2,

resultando em oito camadas. Todas estas camadas empregam a função de ativação unidade linear retificada (ReLU, do inglês: *rectified linear unit*) e são intercaladas com camadas de *dropout* configuradas com uma taxa de 40% como método de regularização durante o treinamento, auxiliando na prevenção do *overfitting*, totalizando, assim, dezesseis camadas.

Finalmente, ao final desta sequência de camadas, as unidades são achatadas, isto é, a estrutura dos dados, que, a este ponto é tridimensional, é desfeita, e as unidades são organizadas em uma única dimensão. Em seguida, esta nova organização é densamente conectada a um único neurônio de saída. O neurônio de saída emprega a função de ativação sigmoide (logística), responsável por realizar a regressão logística dos dados e, posteriormente, classificá-los em duas classes, 0 ou 1.

O modelo foi treinado através da retropropagação do erro tipo entropia cruzada binária (*binary cross-entropy*), utilizando-se o otimizador Adam. O sumário do modelo é mostrado no Quadro 1, onde as camadas são nomeadas como “Conv 2D” (camada convolucional bidimensional), “Dropout” ou “Densa” (neurônios densamente/totalmente conectados). Quando aplicável, a função de ativação utilizada é exibida entre parênteses. A segunda coluna mostra os hiperparâmetros de cada camada (todas as camadas convolucionais empregam *zero-padding*).

Quadro 1 – Sumário do modelo da rede neural implementada

| Camada (função de ativação) | Hiperparâmetros |
|-----------------------------|---|
| Conv 2D (ReLU) | 16 filtros, kernel de 3×3, stride de 1 |
| Dropout | 40% |
| Conv 2D (ReLU) | 16 filtros, kernel de 3×3, stride de 2 |
| Dropout | 40% |
| Conv 2D (ReLU) | 32 filtros, kernel de 3×3, stride de 1 |
| Dropout | 40% |
| Conv 2D (ReLU) | 32 filtros, kernel de 3×3, stride de 2 |
| Dropout | 40% |
| Conv 2D (ReLU) | 64 filtros, kernel de 3×3, stride de 1 |
| Dropout | 40% |
| Conv 2D (ReLU) | 64 filtros, kernel de 3×3, stride de 2 |
| Dropout | 40% |
| Conv 2D (ReLU) | 128 filtros, kernel de 3×3, stride de 1 |
| Dropout | 40% |
| Conv 2D (ReLU) | 128 filtros, kernel de 3×3, stride de 2 |
| Dropout | 40% |
| Densa (Sigmoide) | 1 unidade |

Fonte: Próprio autor

O modelo foi implementado utilizando-se o modo sequencial do Keras, com uma entrada de dimensões 151×857×1, correspondente ao espectrograma, cujo eixo vertical (frequência) possui tamanho 151 e cujo eixo horizontal (tempo) possui tamanho 857. A saída consiste em um único neurônio, cuja saída é um *float* (número real) variando de 0 a 1. Um limiar de 0,5 é

utilizado, de forma que valores abaixo deste limiar representem a classe 0 enquanto valores acima deste limiar representam a classe 1.

Sabe-se que algumas tarefas de aprendizado de máquina apresentam melhor desempenho quando os modelos são configurados com determinados parâmetros. As tarefas de regressão linear para estimativas de quantidades numéricas são melhor realizadas por modelos com função de ativação linear em sua camada de saída e função custo do tipo erro quadrático médio. As tarefas de classificação binária, por sua vez, apresentam melhor desempenho quando o modelo emprega uma função sigmoide em sua camada de saída e função custo do tipo entropia cruzada.

Quando o modelo apresenta mais de duas classes, no entanto, a função de ativação recomendada a ser empregada na saída é a chamada *softmax*, que produz uma distribuição de probabilidades entre os neurônios de saída. Todos estes são parâmetros de referência que são mais adequados para determinadas tarefas. Contudo, além disso, existem outros que podem ser selecionados para se obter o melhor desempenho da rede, e.g., número de neurônios por camada, número de camadas, funções de ativação das camadas ocultas, algoritmo de aprendizagem, arquitetura da rede, entre outros.

Todos estes parâmetros que definem a arquitetura do modelo e que irão impactar no seu treinamento são chamados de hiperparâmetros e são definidos e configurados antes do treinamento. Em geral, o que a literatura apresenta é o teste extensivo de diversos modelos configurados com diferentes hiperparâmetros de forma a se obter o modelo mais adequado para desempenhar a tarefa desejada (BERGSTRA; BENGIO, 2012). Estes são chamados testes de busca ou testes de refinamento. Diferentemente dos hiperparâmetros, os parâmetros de um modelo são os coeficientes que são atualizados (modificados) pelo algoritmo de aprendizagem, os quais são otimizados, durante o treinamento, para minimizar o erro de saída.

Desta forma, considerando-se a tarefa de classificação a ser implementada neste estudo, foram testados diversos hiperparâmetros e arquiteturas de redes neurais para se obter o modelo mais adequado para desempenhar esta tarefa. De uma forma geral, foram testadas as arquiteturas MLP, convolucional de uma dimensão e convolucional de duas dimensões. Além disso, os hiperparâmetros pertinentes a cada arquitetura foram modificados e testados, tais como o número de neurônios por camada e o número de camadas na arquitetura MLP, e o número de filtros, as dimensões do *kernel* e o número de camadas nas arquiteturas convolucionais.

Os resultados demonstraram que as redes convolucionais bidimensionais tiveram um desempenho superior nas tarefas de classificação envolvendo este conjunto de treinamento de sinais de descargas parciais quando comparadas com redes convolucionais unidimensionais e

redes MLP. Os testes também revelaram um melhor desempenho para a função de ativação ReLU, quando comparada a outras funções de ativação disponíveis no Keras. O resultado dos estudos e dos testes acerca dos modelos mais adequados para esta pesquisa conduziu ao modelo descrito pelo Quadro 1, o qual se baseia, em parte, em hiperparâmetros de referência para a tarefa e, em parte, em hiperparâmetros resultantes de testes de busca.

Após a classificação, o sinal é então enviado para o terceiro e último módulo, que irá realizar a detecção dos pulsos e o cálculo do grau de severidade da atividade de descargas parciais. Segundo a norma IEC 60270:2000 (IEC, 2015), o formato do pulso de resposta do sistema de medição ao sinal de descarga parcial determina como o pico do pulso deve ser detectado. Baseando-se na norma, observou-se que a maior parte dos sinais coletados apresenta uma resposta oscilatória ao pulso de descarga, o qual deve ser definido, portanto, pelo maior pico observado dentro deste sinal, sendo a polaridade, porém, indeterminada.

A norma também recomenda que, para este tipo de resposta, este pico seja utilizado no cálculo da carga aparente. Entretanto, a magnitude do pico e a carga aparente são idealmente medidos em um ambiente controlado, isto é, um laboratório onde é possível se garantir a calibração de todos os instrumentos utilizados, bem como os níveis de tensão aplicada sobre o corpo de prova e a ausência de interferências externas.

O equipamento no qual será implementado o algoritmo desenvolvido neste trabalho, entretanto, tem como objetivo ser utilizado em campo, onde a amplitude medida deixa de ser uma grandeza confiável para a determinação da carga aparente, uma vez que a calibração não pode ser realizada e a forma de onda a tensão aplicada, muitas vezes, não é conhecida¹³. Além disso, o sensor utilizado é uma antena de radiofrequência, cuja posição em relação à estrutura sob inspeção pode provocar a variação da amplitude de tensão medida, além de também ser capaz de detectar outras fontes de radiointerferência e ser suscetível a interferências externas.

Portanto, a detecção de picos implementada nesta pesquisa tem como objetivo apenas a determinação da posição relativa dos pulsos¹⁴, sua quantidade e sua taxa de repetição. As amplitudes dos picos só serão consideradas neste estudo quando se estiverem considerando os valores de amplitudes relativas, isto é, a relação entre as amplitudes dos diversos picos de um sinal.

¹³ Embora a classe de tensão do sistema seja conhecida, existem outros fatores que influenciam na forma de onda da tensão, e.g., harmônicos, interferências, subtensões e sobretensões desconhecidas em linhas a vazão, por exemplo.

¹⁴ Considerando-se a inspeção de sistemas trifásicos, embora se observe uma forma de onda senoidal de 60 Hz nos sinais medidos, esta não pode ser utilizada como referência para o ângulo de fase dos pulsos.

Considerando-se que o sinal é alternado, isto é, apresenta valores negativos e positivos, os valores absolutos são obtidos, uma vez que a polaridade não é considerada. Este sinal, contendo apenas valores positivos é então filtrado com relação aos seus valores máximos, resultando em uma espécie de envelope dos valores de pico, o qual é utilizado para se estimar o valor de proeminência e altura para a detecção dos picos. A detecção é, por sua vez, realizada por meio de uma função do pacote SciPy para esta finalidade.

São considerados como parâmetros de seleção (passados como argumentos para a função): altura, proeminência e distância (em número de amostras) entre picos consecutivos. A altura diz respeito à magnitude propriamente dita do pico, em termos absolutos; a proeminência mede o quanto o pico se destaca da linha base da vizinhança; e a distância diz respeito ao número mínimo de amostras que deve haver entre dois picos consecutivos.

Desta forma, mesmo que um pico possua a magnitude necessária para a detecção, este também deve ser proeminente em relação aos valores da sua vizinhança e deve estar a uma distância mínima de outros picos vizinhos; apenas ao obedecer a estes três parâmetros, o pico é considerado. Com estes parâmetros, são desconsiderados picos de baixas amplitudes e ruídos de fundo.

Dado o comportamento oscilatório da resposta ao pulso, deseja-se que apenas o maior pico seja detectado, por este motivo, uma distância de 200 amostras é considerada, de forma que os demais picos da oscilação de um mesmo pulso não sejam detectados. A função retorna os índices dos picos detectados.

A partir dos índices dos picos, é possível determinar o número de pulsos contidos em um sinal, bem como a taxa de repetição dos pulsos. A taxa de repetição das descargas parciais, conforme é definido pela norma IEC 60270:2000 (IEC, 2015), é o número de pulsos presentes em um dado intervalo de tempo dividido pela duração deste intervalo.

Considerando-se os sinais coletados ao longo desta pesquisa, observou-se que grande parte apresenta uma concentração de pulsos em uma faixa específica de ângulos de fase de um semiciclo da forma de onda da tensão fundamental, podendo se repetir, ou não, no semiciclo complementar. O cálculo realizado pelo algoritmo deste estudo resulta em um valor médio da taxa de repetição dos pulsos. Nos extremos do intervalo, observa-se que os pulsos se encontram, na maioria das vezes, mais espaçados quando comparados com os pulsos presentes no meio do intervalo.

O cálculo da taxa de repetição se inicia determinando-se o intervalo de tempo entre dois pulsos consecutivos. Isto é feito calculando-se as diferenças discretas (número de amostras) entre os pulsos a partir do *array* de índices dos picos, obtido anteriormente, resultando em um

array de distâncias entre picos consecutivos. Neste cálculo, o resultado apresenta também a distância entre o último pico de um agrupamento e o primeiro pico do agrupamento subsequente, o qual é eliminado por meio da determinação dos valores atípicos (*outliers*), por meio do princípio do diagrama de caixa.

Tomando-se o *array* das distâncias, são calculados o primeiro e o terceiro quartis dos valores, Q_1 e Q_3 , respectivamente, a partir dos quais é calculada a amplitude interquartil, *IQR*, conforme a equação (9). Os limites (*whiskers*) superior (*upper*) e inferior (*lower*) são então calculados, permitindo a determinação dos valores atípicos, seguindo a equação (10) e a equação (11), respectivamente.

$$IQR = Q_3 - Q_1 \quad (9)$$

$$upper\ whisker = Q_3 + 1.5 \cdot IQR \quad (10)$$

$$lower\ whisker = Q_1 - 1.5 \cdot IQR \quad (11)$$

Os valores acima do *upper whisker* e abaixo do *lower whisker* são considerados atípicos. Neste caso, estes valores atípicos são as distâncias entre agrupamentos consecutivos de pulsos e são, então, eliminados. Desta forma, os valores restantes no *array* de distâncias são apenas aqueles relativos a distâncias entre pulsos agrupados, Δk_i , as quais são expressas em número de amostras.

Considerando-se a taxa de amostragem, o intervalo de amostragem, T_S , é obtido pelo seu inverso. Ao se multiplicar o intervalo de amostragem pelas distâncias entre os pulsos, como na equação (12), o resultado são os intervalos de tempo entre os pulsos, Δt_i , a partir dos quais o valor médio, $\overline{\Delta t}$, é calculado para os n intervalos de tempo, através da equação (13). A taxa de repetição média dos pulsos, \bar{r} , é então obtida através do inverso de $\overline{\Delta t}$, como mostra a equação (14).

$$\Delta t_i = T_S \Delta k_i = T_S (k_i - k_{i-1}) \quad (12)$$

$$\overline{\Delta t} = \frac{1}{n} \sum_{i=1}^n \Delta t_i \quad (13)$$

$$\bar{r} = \overline{\Delta t}^{-1} \quad (14)$$

Desta forma, tem-se dois importantes parâmetros em relação à atividade de descargas parciais descritos pela literatura científica, como descrevem alguns autores citados a seguir. Paralelamente, foram levantados alguns parâmetros adicionais que poderiam contribuir para o cálculo do grau de severidade das descargas.

A estimativa da severidade da atividade de descargas parciais é um tópico constante na literatura, especialmente quando se trata de máquinas elétricas e cabos, e alguns estudos acerca deste tem são citados a seguir. Diversos métodos já foram propostos tendo em vista métodos de inspeção *online* e *offline*, diferentes tipos de sensores e diferentes parâmetros considerados.

A literatura cita o monitoramento da tendência da atividade das descargas parciais como a melhor maneira de se estimar a condição de máquinas elétricas e cabos (AHMED; SRINIVAS, 2001; STONE et al., 2002). Além disso, a medição da carga aparente é frequentemente substituída pela medição da magnitude de tensão dos pulsos de descargas em métodos de inspeção *online*, a qual é considerada bastante eficaz na avaliação da condição de um isolamento.

Entretanto, quando o monitoramento da tendência da atividade de descargas não pode ser realizado, ou quando não existe um banco de dados disponível para consulta, a magnitude dos pulsos, por si só, não é totalmente confiável, dada a influência das condições de operação (STONE et al., 2002). Neste caso, a magnitude sempre deve ser considerada em conjunto com outros parâmetros, como a taxa de repetição, ângulo de fase de ocorrência e número de pulsos (AHMED; SRINIVAS, 2001).

Em um artigo publicado, Ahmed e Srinivas (2001) definiram cinco níveis para descrever a severidade das descargas, correlacionando cada nível à taxa de deterioração da isolação de cabos e ao tempo estimado para falha. Entretanto, os parâmetros para a estimativa destes níveis são extraídos dos dados de monitoramento, o qual é realizado na ordem de 6 a 12 meses.

O estudo de Stewart et al. (2006) correlaciona as magnitudes de carga dos pulsos de descargas e, implicitamente, a taxa de repetição com a severidade da atividade, afirmando que um engenheiro experiente é capaz de avaliar as consequências potenciais da atividade para o isolamento. Além disso, Stewart et al. (2006) também afirma que quanto menor o intervalo de tempo entre pulsos consecutivos de descargas, mais severo é o dano ou degradação sobre o material isolante. Portanto, observa-se que a taxa de repetição desempenha um papel fundamental como indicador para o diagnóstico da condição do isolamento.

Desconsiderando-se o uso da amplitude absoluta como parâmetro para a estimativa da severidade, é possível adaptar alguns dos cálculos apresentados nas referências citadas, em alguns casos, utilizando a amplitude relativa após a normalização. Desta forma, além de se tomar o número de pulsos e a taxa de repetição como parâmetros de avaliação, o primeiro parâmetro adicional considerado é a entropia dos pulsos.

A entropia é uma medida da incerteza e da complexidade da informação, em outras palavras, se os valores produzidos por uma variável aleatória possuem uma distribuição

homogênea de probabilidades, o seu comportamento é mais imprevisível e, portanto, possui maior entropia do que o de uma variável que possui uma distribuição não homogênea de probabilidades e maior previsibilidade (KHAN ACADEMY, 2014). O cálculo da entropia é mostrado na equação (15). Analogamente, a intensificação da atividade das descargas parciais aumenta a entropia (DONG et al., 2015), como é demonstrado experimentalmente.

$$H = - \sum_{i=1}^n p_i \log p_i \quad (15)$$

A partir da equação (15), Dong et al. (2015) propõe um cálculo da entropia dos pulsos de descargas parciais, En , empregando, porém, a magnitude absoluta medida. Neste caso, o presente trabalho utiliza o mesmo cálculo, porém aplicado ao sinal com a magnitude normalizada (máximo valor igual a 1), e eliminando o sinal negativo proposto originalmente, uma vez que os resultados, para os sinais utilizados, sempre serão maiores que zero. Portanto, a equação (16) é utilizada por este trabalho. Experimentalmente, constatou-se que a grandeza proposta varia de acordo com o número de pulsos e com a amplitude relativa entre eles, isto é, varia proporcionalmente à atividade de descargas parciais.

$$En = \sum_{i=1}^n \left(\left(u_i \sum_{i=1}^n u_i \right) \log \left(u_i \sum_{i=1}^n u_i \right) \right) \quad (16)$$

onde n representa o número de pulsos e u_i representa suas amplitudes.

O segundo parâmetro adicional considerado é baseado no estudo desenvolvido por Stewart et al. (2006), que propõe um cálculo direto da severidade da atividade de descargas parciais, S , baseando-se na carga aparente Q_i e na grandeza d_i , associada aos intervalos de tempo entre pulsos consecutivos de descargas, calculados, respectivamente, seguindo a equação (17) e a equação (18).

$$S = \frac{1}{C} \sum_{i=1}^n \left(\frac{Q_i}{d_i} \right) \quad (17)$$

$$d_i = \sqrt{\Delta T_i^2 + \Delta T_{i-1}^2} \quad (18)$$

onde n representa o número de pulsos, C representa o número de ciclos da frequência fundamental, ΔT_i representa o intervalo de tempo entre um dado pulso e o pulso seguinte, e ΔT_{i-1} representa o intervalo de tempo para o pulso anterior.

Como, entretanto, a carga aparente não é uma grandeza disponível neste estudo, uma vez que ela depende de uma medição confiável da amplitude dos pulsos de corrente, a equação (17) é modificada para uma carga aparente fixada em 1, tornando o cálculo dependente apenas dos intervalos de tempo entre os pulsos através da grandeza d_i . Portanto, utiliza-se a equação (19).

$$S = \frac{1}{C} \sum_{i=1}^n \left(\frac{1}{d_i} \right) \quad (19)$$

Desta forma, estes quatro parâmetros selecionados foram calculados para o conjunto de dados de sinais coletados em campo em São Luís. Através do coeficiente de correlação de postos de Spearman (WEISSTEIN, 2020a), verificou-se que estes quatro parâmetros possuem uma relação monotônica positiva, isto significa que, com o aumento do número de pulsos de descargas parciais, os demais parâmetros selecionados também aumentam. Estes quatro parâmetros são, portanto, bons indicadores da evolução da atividade das descargas parciais.

A monotonia observada nos parâmetros dos sinais do conjunto utilizado coincide com o histórico de eventos observados nas regiões onde os sinais foram coletados e com os relatos da equipe de manutenção da Equatorial, isto é, as regiões com histórico mais severo de descargas parciais e de interrupções no fornecimento de energia apresentam os valores mais altos dos parâmetros selecionados. Desta forma, baseando-se nestes quatro parâmetros, é proposto um grau de severidade para permitir ao usuário do equipamento avaliar a condição da estrutura inspecionada. Este grau compreende uma faixa de valores inteiros de 0 até 10, onde 0 indica ausência de risco para o isolador inspecionado e 10 indica risco iminente de falha.

O processo para se obter este índice é baseado em um sistema de inferência *fuzzy* (FIS, do inglês: *fuzzy inference system*). Um FIS é um *framework* baseado em regras do tipo “se-então” que relaciona as entradas com as saídas, ambas das quais são variáveis *fuzzificadas*. O processo de *fuzzificação* das entradas é realizado por meio de funções de pertinência, a partir das quais uma variável passa a apresentar graus de pertinência em relação aos conjuntos de entrada. De maneira semelhante, a saída do FIS encontra-se *fuzzificada* e deve passar por um processo de *defuzzificação* para se obter o resultado.

Os quatro parâmetros selecionados são tomados como as entradas do FIS, que são, inicialmente, *fuzzificadas* através de sete funções de pertinência, sendo: baixíssimo, mais baixo, baixo, médio, alto, mais alto e altíssimo; cada um destes conjuntos consiste em uma subfaixa de valores de cada parâmetro, isto é, a faixa de valores de cada parâmetro é subdividida em sete subfaixas, porém com sobreposições em alguns trechos. Um conjunto de regras então relaciona cada associação dos conjuntos de entrada a um conjunto de saída, como o exemplo a seguir:

SE entrada₁ é FP_1 **E** entrada₂ é FP_2 **ENTÃO** saída é FP_3

No exemplo, esta regra associou a função de pertinência 1 (FP_1) da primeira entrada com a função de pertinência 2 (FP_2) da segunda entrada por meio da operação de conjunção lógica (E), e relacionou esta associação à função de pertinência 3 (FP_3) da saída. A lógica *fuzzy* é baseada em graus de incerteza, então o valor verdade de uma variável não é mais binário, do tipo verdadeiro (1) ou falso (0), ao invés disso, ele varia entre completamente falso ($x = 0$), parcialmente verdadeiro ($0 < x < 1$) e completamente verdadeiro ($x = 1$). São as funções de pertinência que atribuem a um valor de entrada um grau de pertinência a um ou mais conjuntos.

A implementação do sistema *fuzzy* em Python é feita pelo *toolbox* SciKit-Fuzzy (skfuzzy) e a inferência *fuzzy* é realizada pelo método Mamdani. Desta forma, combinando-se a intensidade da regra com as funções de pertinência de saída, é gerada uma distribuição de saída, que é então *defuzzificada* pelo método do centroide, que consiste em se calcular o centroide da área da distribuição de saída resultante do processo de inferência para se obter um valor numérico.

Cada uma das entradas é composta de sete funções de pertinência triangulares, baseadas na faixa de valores de cada parâmetro. Estas funções de pertinência são então relacionadas, por meio do conjunto de regras, com a saída, também composta de sete funções de pertinência cobrindo a faixa de -1 a 11 antes do processo de *defuzzificação*, a qual resulta em uma faixa de valores de saída variando de 0 até 10 após a *defuzzificação*, representando o grau de severidade.

Para se obter a faixa desejada de valores de saída após a *defuzzificação*, é necessário o posicionamento de uma estreita função de pertinência em cada um dos extremos da faixa, de forma que os centroides das áreas destas funções resultem nos extremos da faixa desejada de severidade. O conjunto de regras utilizado é mostrado no Quadro 2.

O grau de severidade é calculado e atribuído apenas aos sinais classificados como positivos pela rede neural. Os sinais classificados como negativos não contêm descargas parciais ou contêm descargas oriundas de ambientes com excesso de ruídos ou descargas com padrões típicos de corona em equipamentos de subestações. Este padrão se apresenta como uma sequência de pulsos quase ininterrupta, de amplitude praticamente constante, com altíssima taxa de repetição. A um padrão como este, muito provavelmente, seria atribuído um alto grau de severidade, por este motivo, a classificação o descarta da análise.

Portanto, uma vez classificado como positivo pela rede neural, os parâmetros são calculados e apresentados ao FIS, que, por sua vez, retorna o grau de severidade. A função de

análise dos dados retorna então o grau de severidade, a classificação realizada pela rede neural, o número de pulsos de descargas parciais e sua taxa de repetição.

Quadro 2 – Conjunto de regras de inferência utilizados pelo sistema *fuzzy*

| i_1 | i_2 | op. | i_3 | op. | i_4 | out |
|------------|------------|-----|------------|-----|------------|------------|
| baixíssimo | - | - | - | - | - | baixíssimo |
| mais baixo | - | - | - | - | - | mais baixo |
| baixo | - | - | - | - | - | baixo |
| médio | - | - | - | - | - | médio |
| alto | - | - | - | - | - | alto |
| mais alto | - | - | - | - | - | mais alto |
| altíssimo | - | - | - | - | - | altíssimo |
| - | baixíssimo | E | baixíssimo | E | baixíssimo | baixíssimo |
| - | mais baixo | OU | mais baixo | OU | mais baixo | mais baixo |
| - | baixo | OU | baixo | OU | baixo | baixo |
| - | médio | OU | médio | OU | médio | médio |
| - | alto | E | alto | E | alto | alto |
| - | mais alto | E | mais alto | E | mais alto | mais alto |
| - | altíssimo | E | altíssimo | E | altíssimo | altíssimo |

Fonte: Próprio autor

onde i_1 , i_2 , i_3 e i_4 representam as entradas *fuzzificadas* do FIS respectivas a cada parâmetro, *out* representa a saída *fuzzificada* do FIS e *op.* indica a operação lógica de associação das entradas.

CAPÍTULO 6 – RESULTADOS

Todos os dados de amostragem dos sinais coletados, tanto em campo quanto em laboratório, foram salvos como arquivos no formato CSV e as formas de onda foram salvas como imagens no formato PNG. Considerando-se os ensaios de poluição artificial pelo método da camada sólida, o comportamento observado foi a diminuição da densidade (taxa de repetição) dos pulsos de descargas de acordo com a diminuição da umidade relativa no interior da câmara.

Os arquivos coletados no formato CSV foram então utilizados para se aplicar os algoritmos de análise de dados desenvolvidos, com o objetivo de se avaliar seu desempenho e de se observar a resposta produzida para o grau de severidade. O gráfico exibido na Figura 43 mostra a variação do grau de severidade produzido pelos algoritmos de análise de dados em função da variação da umidade no interior da câmara de ensaio, considerando uma contaminação pelo método da camada sólida correspondente ao mês de outubro.




Figura 43 – Grau de severidade em função da umidade para o caso da camada sólida correspondente à poluição para o mês de outubro.

Fonte: Próprio autor

O que se observa, neste caso, é a diminuição do grau de severidade da atividade de descargas com a diminuição da umidade relativa no interior da câmara de ensaio. O processo pode ser descrito da seguinte forma: a elevada umidade no interior da câmara é absorvida pela camada de contaminação formada por caulim e sal.

Conforme já mencionado, a camada de contaminação se torna condutiva, passando a se observar um aumento substancial da corrente de fuga ao longo da superfície do isolador. Esta corrente provoca o aquecimento da camada de contaminação, levando à evaporação da umidade

previamente absorvida. Esta evaporação leva ao surgimento de bandas secas, isto é, a umidade acumulada sobre a superfície do isolador passa a apresentar uma distribuição não homogênea, com regiões ainda úmidas e regiões já secas. Como as regiões úmidas permanecem condutivas, o campo elétrico passa a se concentrar de forma mais intensa sobre as bandas secas, o que desencadeia o fenômeno das descargas parciais.

Conforme a umidade relativa no interior da câmara diminui, a umidade acumulada na camada de contaminação também diminui, deixando-a cada vez mais seca e, portanto, aumentando as regiões secas e diminuindo a concentração de campo elétrico sobre estas e, portanto, diminuindo também a atividade de descargas parciais. Quando a camada se torna livre de umidade, a corrente de fuga diminui substancialmente, para valores da ordem de alguns microampères, cessando a atividade de descargas parciais. Como o grau de severidade proposto é baseado, de uma forma geral, nos pulsos de descargas parciais, esse processo resulta na sua diminuição.

A calibração inicial do FIS foi baseada nos sinais coletados em campo em São Luís, sendo o grau de severidade igual a 10 atribuído aos piores cenários observados durante o dia, período em que a concessionária fazia as inspeções. Para a maior parte dos ensaios realizados em laboratório, o grau de severidade caiu para valores inferiores a 5 sempre que a umidade diminuía para valores inferiores a 70%.

Além da contaminação para o mês de outubro, este mesmo procedimento foi utilizado para se realizar os ensaios do corpo de prova com contaminações equivalentes à metade do valor para o mês de outubro e a um quarto deste valor, relativos aos períodos aproximados de duas semanas e de uma semana, respectivamente. Neste procedimento, os nebulizadores permaneceram ligados por um período entre 5 e 10 minutos, dependendo da umidade relativa ambiente, até que a umidade relativa no interior da câmara de ensaio atingisse um valor próximo a 85%, e então estes foram desligados e a tensão nominal foi aplicada sobre o corpo de prova. Na Figura 44 são contemplados os resultados do grau de severidade para os três períodos mencionados, para valores de umidade relativa acima de 70%.

Embora uma diminuição no grau de severidade seja observada entre a contaminação equivalente ao mês de outubro e as contaminações respectivas aos outros dois períodos, como mostram os valores da média (triângulo verde) e da mediana (segmento laranja), os valores médios do grau de severidade relativos aos períodos de duas semanas e de uma semana do mês de outubro não apresentam a mesma monotonia. Considerando-se a pequena quantidade de sal utilizada nestes dois últimos casos, a homogeneidade ideal da distribuição do depósito de sal sobre a superfície do corpo de prova pode não ter sido alcançada, causando esta divergência.

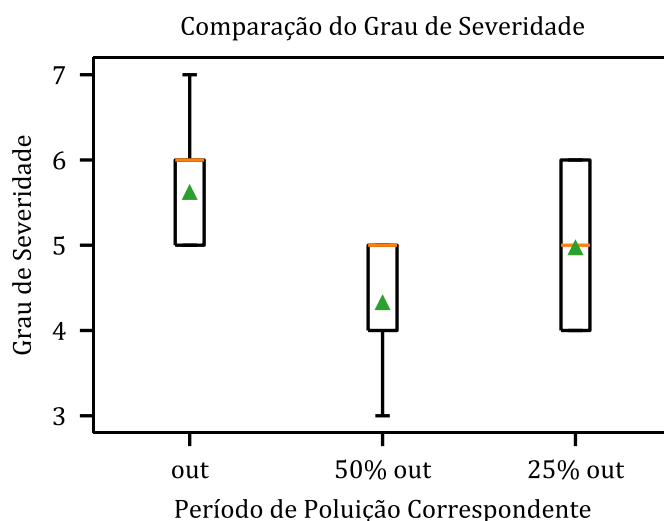


Figura 44 – Comparação do valor do grau de severidade para três períodos de poluição.
Fonte: Próprio autor

Além das quantidades de NaCl equivalentes à poluição dos períodos relativos ao mês de outubro, foram realizados ensaios relativos aos períodos de julho a outubro e de metade deste período. Nestes ensaios, os nebulizadores foram ligados por mais tempo que os ensaios acima, até que uma quantidade considerável de umidade tivesse sido absorvida pela camada de contaminação do corpo de prova. Em seguida, os nebulizadores foram desligados e tensão nominal foi então aplicada sobre o corpo de prova. Os resultados para estes dois períodos são mostrados na Figura 45, novamente, apenas valores de grau de severidade para valores de umidade relativa acima de 70% são exibidos.

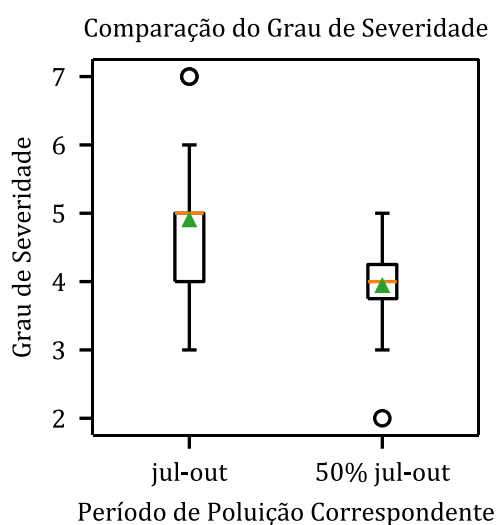


Figura 45 – Comparação do valor do grau de severidade para dois períodos de poluição.
Fonte: Próprio autor

Os algoritmos desenvolvidos funcionam como módulos em linguagem de programação Python, isto é, definições de funções e variáveis de uso frequente são salvos em um arquivo de extensão PY, de forma que possam ser importados por outros módulos ou pelo programa principal. Assim, os módulos desenvolvidos são utilizados por uma aplicação *web* desenvolvida pelos membros da equipe de ciência da computação do P&D, sendo o *frontend* implementado em HTML, CSS e JavaScript e o *backend* implementado em Python. Este *software* fornece uma interface para o usuário, realiza configurações pertinentes do equipamento desenvolvido, acesso aos bancos de dados – registros de colaboradores, de linhas de transmissão e das estruturas georreferenciadas – e realiza o ensaio propriamente dito, através dos algoritmos desenvolvidos.

Em termos do *hardware* desenvolvido pelos membros da equipe de eletrônica e mecânica, a execução do *software* ocorre em um Raspberry Pi 4 Modelo B com 4 GB de memória, ao qual são conectados a PicoScope, para a aquisição de dados, e um *display touchscreen*, para fornecer interface ao usuário. A alimentação do sistema é fornecida por uma bateria recarregável. Todos estes equipamentos são posicionados dentro de uma maleta protetora, permitindo que seja levada a campo pela equipe da concessionária para a realização das inspeções nas estruturas.

Portanto, é desta forma que o algoritmo desenvolvido por este estudo, cujo desenvolvimento é descrito neste trabalho, compõe o sistema *software-hardware* compacto e portátil desenvolvido pelo P&D. Este algoritmo se trata do núcleo principal de aquisição e análise de dados do sistema. É ele que fornece todas as funcionalidades do equipamento desenvolvido.

A realização da inspeção se dá com o apontamento da antena desenvolvida na direção da estrutura ou do grupo de isoladores que se deseja avaliar. Através da interface desenvolvida, o usuário configura e inicia o ensaio. O algoritmo irá então coletar os sinais através da PicoScope, os quais serão classificados e analisados. O resultado instantâneo é exibido na forma de uma escala linear formada por dez círculos, que se colorem de acordo com o valor do grau de severidade. Resultados mais detalhados são salvos em um arquivo PDF para eventual exportação.

O sistema como um todo (*hardware* e *software*) foi testado em laboratório para se avaliar o seu comportamento. Estes resultados são os exibidos na Figura 43, na Figura 44 e na Figura 45. O que se observa é que a umidade relativa e o nível de poluição têm impacto direto no grau de severidade, que responde da forma desejada para cada condição simulada em laboratório. Além disso, o algoritmo foi calibrado com os sinais de campo coletados em São Luís. A seguir,

são exibidas algumas formas de onda destes sinais de campo e o detalhamento da sua classificação e da obtenção do grau de severidade pelo sistema de inferência *fuzzy*.

A forma de onda exibida na Figura 46 mostra um exemplo da atividade mais intensa de descargas parciais observada neste estudo. As medições foram realizadas com a antena e a aquisição foi realizada com a PicoScope. Os relatos da concessionária, com relação à região da Forquilha, indicam uma área de severidade intensa, os quais são corroborados pelos relatos dos moradores da região, que afirmam avistar, na parte da noite, centelhamento acompanhado de luz visível nos isoladores.

Esta medição foi realizada durante a noite e sem o filtro de baixas frequências, de forma que é possível se observar os três ciclos da forma de onda da tensão fundamental. Além disso, observa-se um número extremamente elevado de pulsos de descargas, preenchendo quase a totalidade da janela de medição, resultando em uma altíssima taxa de repetição de pulsos.




Figura 46 – Forma de onda relativa à atividade mais severa de descargas parciais na Forquilha.
Fonte: Próprio autor

A partir deste sinal são, então, extraídos os quatro parâmetros utilizados no cálculo do grau de severidade proposto. Estes parâmetros, ao serem apresentados ao sistema *fuzzy*, ativam algumas funções de pertinência, de acordo com o seu valor, como mostra a Figura 47. O conjunto de regras de inferência relaciona, então, estas entradas *fuzzificadas* a funções de pertinência de saída, considerando a intensidade de ativação das respectivas regras.

Esta condição, contudo, foi observada somente durante a noite, sendo necessário considerar que a concessionária faria os ensaios somente durante o dia. Portanto, para este caso, os parâmetros extrapolam as faixas de valores de entrada e a ativação das funções de pertinência da saída cria, então, a distribuição mostrada na Figura 48, a partir de cujo centroide é obtido o grau de severidade, que, para este caso, resultou no valor 10.

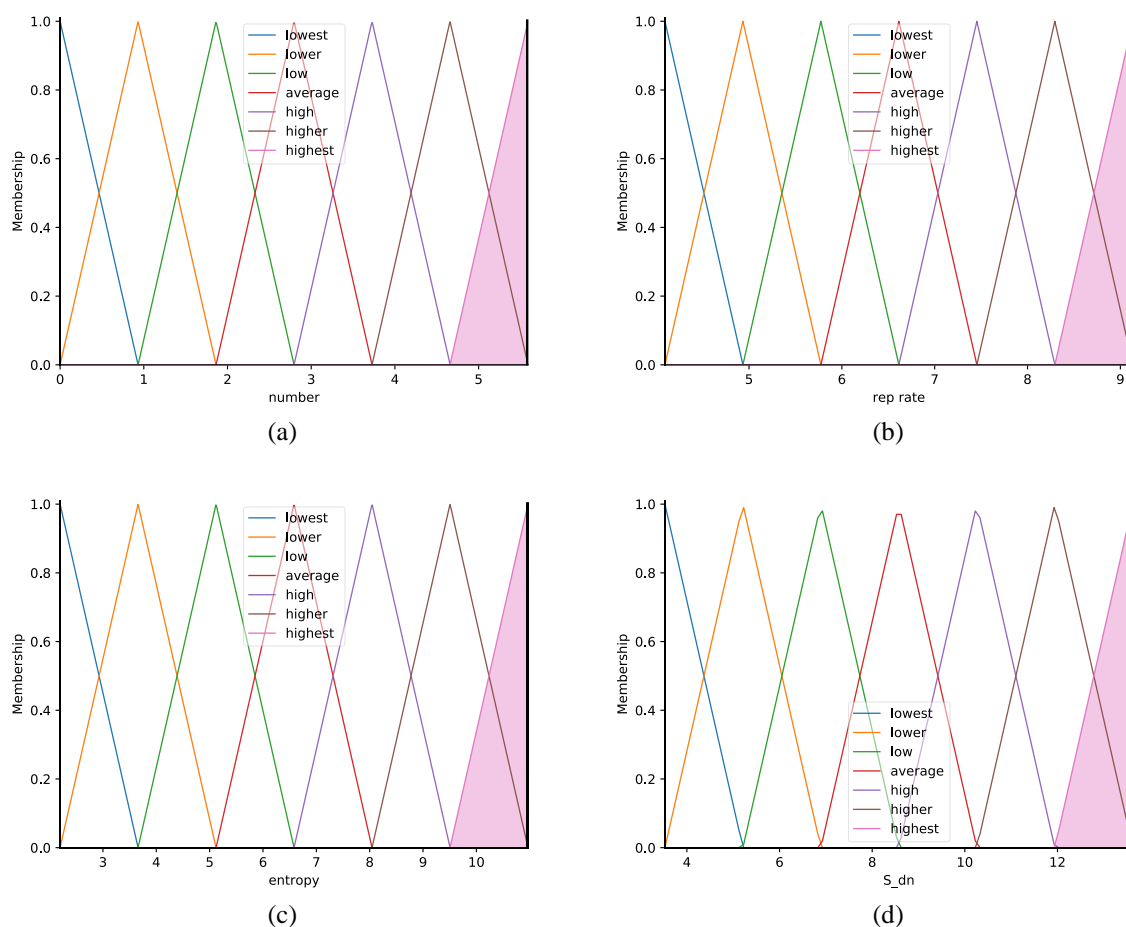


Figura 47 – Funções de pertinência ativadas por cada um dos parâmetros: (a) número de pulsos; (b) taxa de repetição de pulsos; (c) entropia dos pulsos; (d) métrica da severidade.

Fonte: Próprio autor




Figura 48 – Funções de pertinência ativadas pelas regras de inferência.

Fonte: Próprio autor

A forma de onda exibida na Figura 49, por sua vez, representa a medição realizada em outra estrutura na Forquilha, na qual foi observada a atividade mais severa no período do dia. Observam-se magnitudes de pulsos maiores, em termos absolutos, contudo, o número de pulsos de descargas e a sua taxa de repetição são menores em relação ao caso anterior. Portanto, os sinais coletados nesta estrutura foram utilizados para se calibrar o sistema, tendo sido utilizados

como referência de maior severidade, considerando-se o cenário em que a concessionária realizaria as inspeções.

Calculando-se os parâmetros e apresentando-os ao sistema *fuzzy* desenvolvido, foram obtidas as entradas *fuzzificadas* mostradas na Figura 50. Observa-se que os parâmetros, para este caso, possuem alto grau de pertinência com relação ao penúltimo conjunto, em roxo, correspondente à faixa de valores mais altos de cada parâmetro. Contudo, cada um dos parâmetros também ativou, com certo grau de pertinência, o último conjunto, representado em rosa, representativo dos valores altíssimos de cada parâmetro.

Tomando-se o conjunto de regras exibido no Quadro 2 da Seção 4.2, observa-se que, quando o valor de qualquer um dos parâmetros pertence ao conjunto “mais alto” (roxo), a função de pertinência de saída respectiva aos valores mais altos deve ser ativada. A operação realizada para três dos parâmetros, neste caso, é a conjunção lógica (E), isto é, o grau de pertinência da função de saída deve ser igual ao mínimo grau de pertinência observado dentre os conjuntos “mais altos” de entrada, como mostra a equação (20).

$$\mu_O = \min(\mu_A, \mu_B, \mu_C, \mu_D) \quad (20)$$

Onde μ_O representa o grau de pertinência do conjunto de saída e $\mu_A, \mu_B, \mu_C, \mu_D$ representam os graus de pertinência de cada um dos conjuntos de entrada. Contudo, para o primeiro parâmetro, as regras não envolvem a associação com os demais parâmetros, portanto a distribuição final de saída é obtida a partir de uma combinação das regras ativadas. O mesmo procedimento é realizado aqui para o conjunto “altíssimo” (rosa).

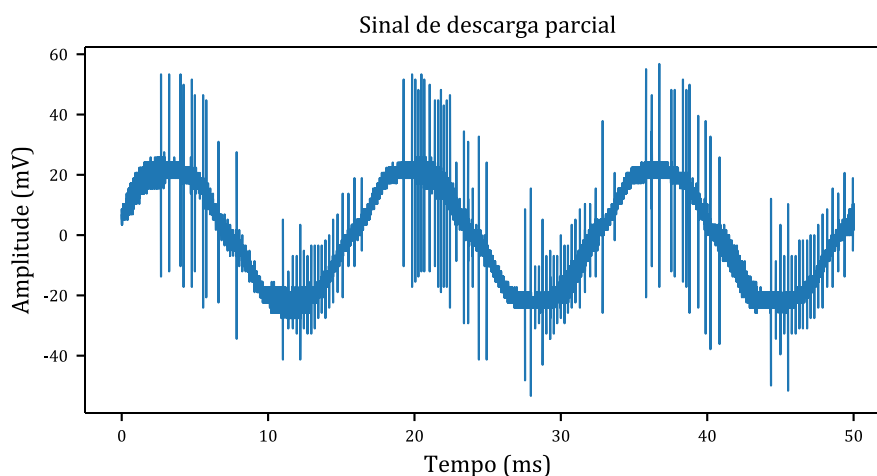


Figura 49 – Forma de onda relativa à atividade intermediária de descargas parciais na Forquilha.
Fonte: Próprio autor

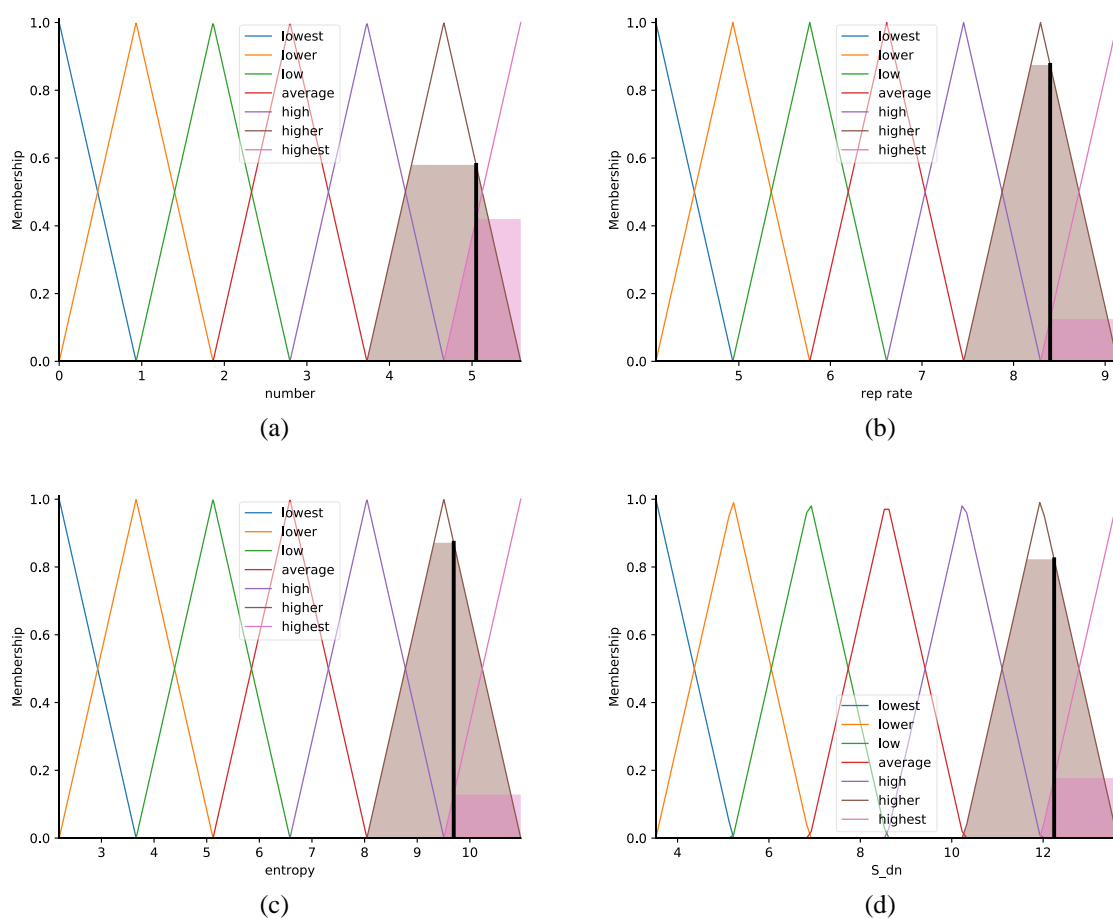


Figura 50 – Funções de pertinência ativadas por cada um dos parâmetros: (a) número de pulsos; (b) taxa de repetição de pulsos; (c) entropia dos pulsos; (d) métrica da severidade.

Fonte: Próprio autor

Neste caso, seguindo-se o conjunto de regras de inferência, a distribuição resultante é obtida da união das áreas definidas pelas respectivas funções de pertinência e seus respectivos graus de pertinência. O centroide desta área é calculado, como indicado pela linha vertical preta na Figura 51, o qual representa o valor do grau de severidade, que, neste caso, é igual a 9.

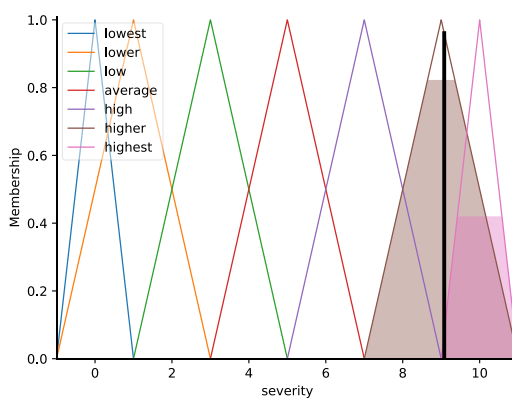


Figura 51 – Funções de pertinência ativadas pelas regras de inferência.

Fonte: Próprio autor

A Figura 52 mostra o sinal, coletado com o uso de um filtro passa-altas, da atividade menos severa de descargas parciais observada na Forquilha, em uma terceira estrutura inspecionada. A Figura 53 mostra as funções de pertinência ativadas para este caso.

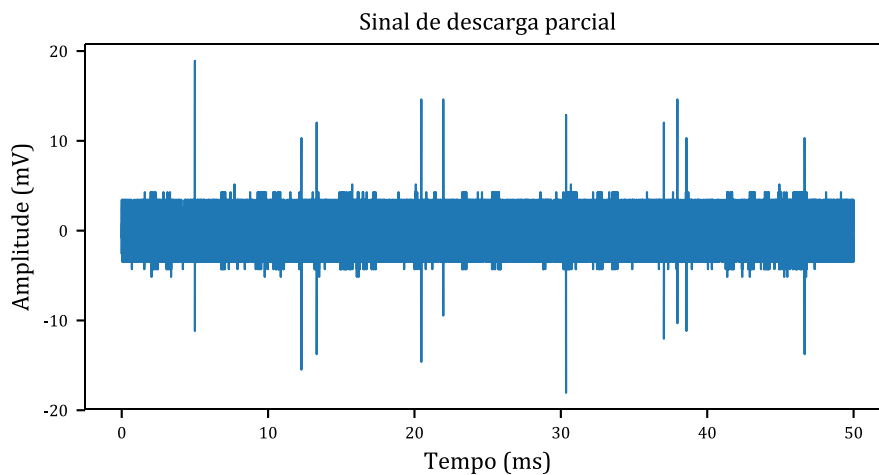


Figura 52 – Forma de onda relativa à atividade menos severa de descargas parciais na Forquilha.
Fonte: Próprio autor

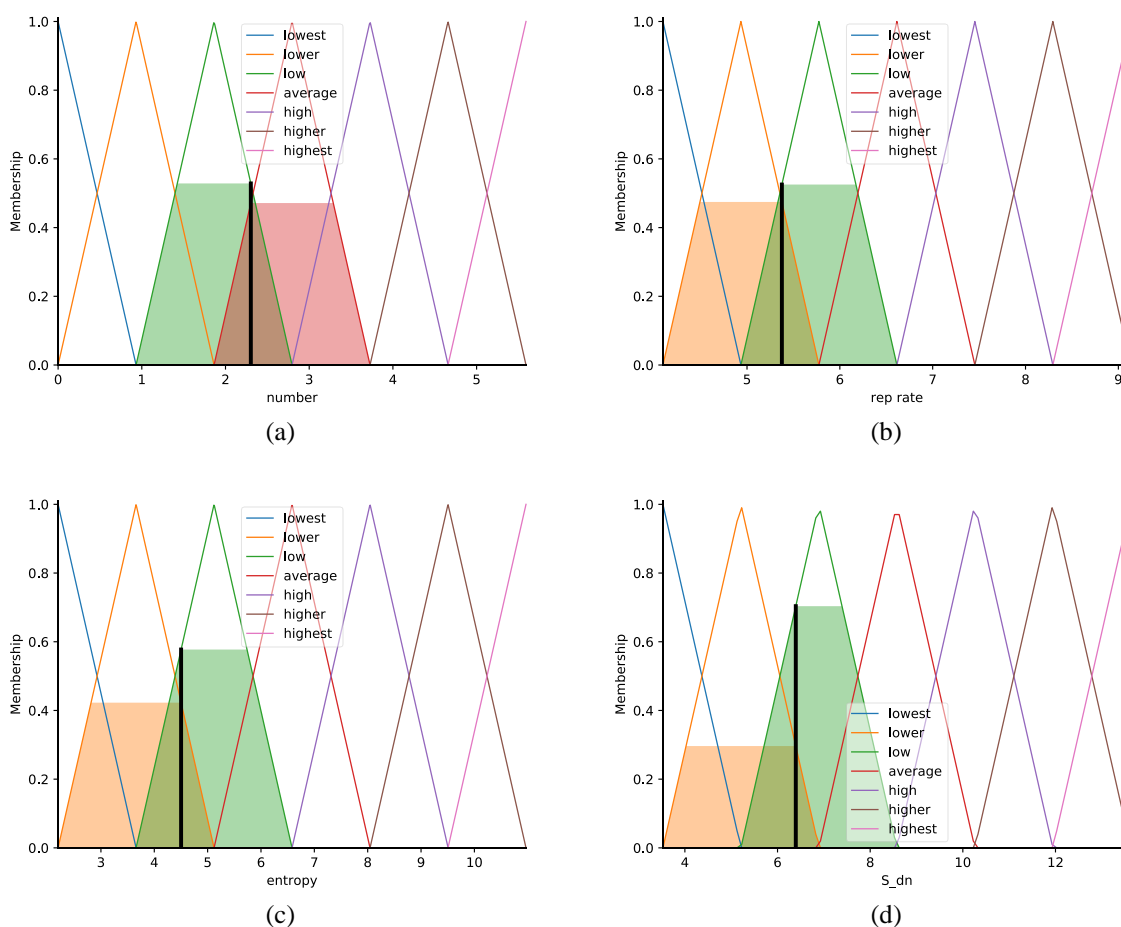


Figura 53 – Funções de pertinência ativadas por cada um dos parâmetros: (a) número de pulsos; (b) taxa de repetição de pulsos; (c) entropia dos pulsos; (d) métrica da severidade.

Fonte: Próprio autor

Neste caso, cada um dos parâmetros ativou com maior intensidade a sua respectiva função de pertinência relativa ao conjunto “baixo” (verde). Além disso, os três últimos parâmetros também ativaram, em menor grau, as suas respectivas funções de pertinência relativas ao conjunto “mais baixo” (laranja), enquanto o primeiro parâmetro ativou a sua função de pertinência relativa ao conjunto “médio” (vermelho). Tanto as ativações do conjunto “baixo” quanto a ativação do conjunto “mais baixo”, que ocorrem na entrada do sistema, ativam estas respectivas funções na saída do sistema.

Entretanto, diferentemente do descrito pela equação (20), neste caso, as regras utilizam a operação de disjunção lógica (OU). Isto é implementado pelo máximo grau de pertinência observado dentre os conjuntos de entrada, como demonstra a equação (21). Da mesma forma que o caso anterior, a regra relativa ao primeiro parâmetro não considera a associação com os demais parâmetros. Portanto, para este caso, a distribuição de saída observada é a exibida pela Figura 54, cujo cálculo do centroide da área resulta em um grau de severidade igual a 3.

$$\mu_O = \max(\mu_A, \mu_B, \mu_C, \mu_D) \quad (21)$$




Figura 54 – Funções de pertinência ativadas pelas regras de inferência.

Fonte: Próprio autor

Uma vez demonstrado o processo de obtenção do grau de severidade através do sistema de inferência *fuzzy*, o Apêndice A mostra algumas formas de onda de sinais de descargas parciais obtidos através dos ensaios em campo e em laboratório, de forma a compor e ilustrar a metodologia implementada por este estudo.

CAPÍTULO 7 – CONSIDERAÇÃO FINAIS

7.1 COMENTÁRIOS FINAIS

Do ponto de vista das redes neurais artificiais, o que se observou foi a variedade de arquiteturas e métodos para a análise dos sinais coletados. Por exemplo, redes *perceptron* de múltiplas camadas necessitam, em sua camada de entrada, de um neurônio para cada amostra do sinal no domínio do tempo, resultando em um grande número de parâmetros, dependendo da taxa de amostragem e da janela de aquisição utilizados.

As redes convolucionais, por outro lado, implementam o compartilhamento de pesos, reduzindo drasticamente a complexidade e o tamanho da rede, tornando-a mais eficiente, podendo ser implementadas tanto sobre sinais no domínio do tempo, quanto sobre dados bidimensionais. Por este motivo, um dos principais destaques do uso da arquitetura convolucional envolve a utilização dos dados puros, com mínimo ou nenhum processamento prévio, uma vez que as redes deste tipo são especialistas em extração de características, eliminando a necessidade de uma seleção cognitiva para obtenção de um conjunto de características.

A antena utilizada para a detecção de interferências de radiofrequência provenientes da atividade de descargas parciais se mostrou uma alternativa eficiente e barata para a inspeção de estruturas de alta tensão, em relação a outros sensores utilizados para este fim. O emprego deste sensor possibilita o resguardo de uma distância segura da estrutura de ensaio e elimina a necessidade de acesso ao condutor de aterramento da estrutura, sendo, portanto, um método de inspeção não intrusivo. Além disso, a diretividade oferecida pela antena é suficiente para se obter uma medição confiável da estrutura desejada.

Embora a versão final do equipamento desenvolvido empregue a antena como sensor, é importante ressaltar que o HFCT pode ser utilizado de forma intercambiável. As razões para a utilização da antena neste caso de estudo consistem no seu custo inferior, em relação ao HFCT, e na infraestrutura de aterramento da grande maioria das estruturas do sistema elétrico da cidade de São Luís, que impossibilita o uso do HFCT. Portanto, caso se deseje utilizar um HFCT como sensor, basta conectá-lo ao equipamento da mesma forma como é feito com a antena, sem a necessidade de maiores modificações.

Com respeito ao equipamento portátil desenvolvido pela equipe do P&D, existe a possibilidade de se utilizar os mesmos fundamentos da sua concepção para se implementar um equipamento fixo associado a um sistema de comunicação. Isto permite que ele seja instalado

em pontos estratégicos do sistema da concessionária, que apresentem histórico de eventos críticos, sendo o equipamento, portanto, capaz de enviar os dados de severidade para um servidor remoto. Desta forma, esta alternativa permite o monitoramento à distância de estruturas selecionadas, possibilitando o agendamento de rotinas de manutenção preventiva, como a lavagem dos isoladores poluídos, conforme a evolução do grau de severidade ao longo do tempo.

Além da utilização da análise e classificação dos padrões dos sinais de descargas parciais, uma alternativa que pode ser implementada de forma paralela é a análise do conteúdo harmônico da corrente de fuga. A poluição superficial dos isoladores afeta diretamente a linearidade da componente resistiva destes aparatos, provocando o surgimento de componentes harmônicas que afetam significativamente a forma de onda da corrente de fuga. O estudo deste comportamento e a determinação das ordens dos harmônicos afetados pela poluição superficial compreende uma possibilidade de trabalho futuro, com o objetivo de se obter esta correlação e utilizá-la como um parâmetro adicional para a determinação da condição dos isoladores em operação.

7.2 CONCLUSÕES

O algoritmo implementado permite que o sistema desenvolvido não seja totalmente dependente de um profissional experiente na inspeção *in loco*, possibilitando que qualquer profissional realize a inspeção, uma vez que o equipamento fornece um diagnóstico direto e claro. Claramente, este novo diagnóstico não elimina a opinião do profissional experiente, mas, ao invés disso, vem agregar ao seu trabalho como uma ferramenta de apoio à decisão. Ao se combinar o histórico das estruturas e os métodos tradicionais de inspeção aos resultados fornecidos pelo sistema desenvolvido, é possível se obter um diagnóstico mais preciso com relação às estruturas inspecionadas, permitindo o agendamento de rotinas de manutenção mais adequadas, visando a prevenção de falhas dos isoladores.

Desta forma, para a concessionária, o objetivo do sistema *software-hardware* desenvolvido pelo P&D é fornecer uma alternativa aos métodos de inspeção tradicionais, funcionando como uma ferramenta de apoio à decisão e agregando maior certeza ao diagnóstico, oferecendo, assim, uma orientação quanto à real condição das estruturas. Do ponto de vista do algoritmo, cujo desenvolvimento é descrito ao longo deste trabalho, os objetivos propostos inicialmente foram atingidos com êxito. O que se observa, de forma clara, é que o

algoritmo de análise permite a classificação dos sinais de descargas parciais e a obtenção de um grau de severidade indicativo da condição do isolador em operação.

O presente trabalho, como um todo, traz diversas contribuições para o tema de descargas parciais e inteligência artificial. Da necessidade de se obter um método de inspeção voltado para a condição de campo, duas vertentes de estudos se desenvolveram. Primeiramente, tem-se os ensaios extensivos de sensores para a detecção de descargas parciais. O HFCT se confirmou como um método extremamente confiável para esta detecção, apresentando boa blindagem e faixa de detecção adequada. Entretanto, na ausência da possibilidade de se utilizar este sensor, uma antena log periódico (LPDA) se mostrou uma alternativa e baixo custo e efetiva na detecção de descargas em campo.

Em segundo lugar, ainda considerando o foco na condição de campo, têm-se os parâmetros que foram definidos para o cálculo do grau de severidade. Grande parte do que é descrito na revisão bibliográfica deste trabalho foca na observação de longo prazo do fenômeno e na criação de extensivos bancos de dados para então se obter um parâmetro para a estimativa da severidade da atividade das descargas. Alternativamente, são sugeridos, também na revisão bibliográfica, cálculos que exigem parâmetros ligados à magnitude das descargas, porém também inviáveis para este estudo, dada a falta de controle das condições de operação em uma inspeção em campo.

Por esses motivos, este trabalho definiu parâmetros independentes de magnitudes absolutas, permitindo a análise de sinais coletados de forma não intrusiva. As incertezas envolvidas nesta definição, ao se eliminar valores absolutos, foram tratadas justamente por um sistema de inferência *fuzzy*, que tem como princípio o tratamento de incertezas através da lógica nebulosa. Os resultados obtidos para grau de severidade representam a validação do desempenho do sistema desenvolvido no diagnóstico da condição dos isoladores.

Além do uso do sistema de inferência *fuzzy* como ferramenta de inteligência artificial, também foi implementada a rede convolucional de classificação para sinais de descargas parciais. Este trabalho corrobora, portanto, o uso desta arquitetura de rede neural na classificação de padrões de sinais. As redes convolucionais implementam, neste caso, a capacidade de análise da variação do conteúdo de frequências do sinal ao longo do tempo, a qual se conclui ser uma representação válida da natureza do sinal.

Tratando-se das descargas parciais propriamente ditas, os ensaios em laboratório confirmaram a hipótese de que os padrões das descargas variam conforme o grau de poluição e o nível de umidade relativa aos quais os isoladores estão submetidos. Afinal, a premissa inicial deste trabalho se baseou justamente no desenvolvimento de algoritmos que fossem capazes de

detectar e interpretar estes padrões. E este objetivo foi alcançado com o uso da rede neural artificial, do sistema de inferência *fuzzy* e dos parâmetros adequados ao caso de estudo. E o que se conclui, portanto, é que é possível se utilizar estes padrões para estimar o grau de severidade da atividade de descargas parciais.

Dos pontos de vista técnico, do P&D e do equipamento desenvolvido para ser utilizado pela concessionária, os algoritmos descritos neste trabalho representam o cerne do sistema desenvolvido, fornecendo as funcionalidades essenciais ao cumprimento da tarefa desejada. E, a partir do diagnóstico fornecido, o que se visualiza é a redução dos custos de manutenção, a melhor capacidade de gerenciamento de recursos e a prevenção de falhas e interrupções no sistema elétrico.

REFERÊNCIAS BIBLIOGRÁFICAS

ABADI, M. et al. **TensorFlow**: Large-Scale Machine Learning on Heterogeneous Distributed Systems, 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>. Acesso em: 20 dez. 2019.

ABU-ELANIEN, A.E.B.; SALAMA, M.M.A.; IBRAHIM, M. Calculation of a Health Index for Oil-Immersed Transformers Rated Under 69 kV Using Fuzzy Logic. In: **IEEE Transactions on Power Delivery**, v. 27, n. 4, pp. 2029-2036, Oct. 2012, doi: 10.1109/TPWRD.2012.2205165.

AGUIAR DO NASCIMENTO, D. et al. **Evaluation of Partial Discharge Signatures Using Inductive Coupling at On-Site Measuring for Instrument Transformers**. International Journal of Emerging Electric Power Systems, v. 19. n. 1. jan. 2018. doi: 10.1515/ijeeps-2017-0160.

AHMED, N.; SRINIVAS, N. Partial discharge severity assessment in cable system, **2001 IEEE/PES Transmission and Distribution Conference and Exposition**. Developing New Perspectives (Cat. No.01CH37294), Atlanta, GA, USA, 2001, pp. 849-852 vol.2, doi: 10.1109/TDC.2001.971349.

ANACONDA Software Distribution. Computer software. Vers. 2-2.4.0. Anaconda, Nov. 2016. Web. <<https://anaconda.com>>.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 15643: Isoladores poliméricos para uso interno e externo, com tensão nominal superior a 1 000 V - Ensaios de projeto. Rio de Janeiro, p. 19. 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 5032: Isoladores para linhas aéreas com tensões acima de 1 000 V — Isoladores de porcelana ou vidro para sistemas de corrente alternada. Rio de Janeiro, p. 61. 2014.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 5472: Isoladores para eletrotécnica — Terminologia. Rio de Janeiro, p. 17. 2012.

BARRIOS, S. et al. **Partial Discharge Classification Using Deep Learning Methods—Survey of Recent Progress**. Energies 2019, 12, 2485, doi: 10.3390/en12132485.

BERGSTRA, J.; BENGIO, Y. **Random Search for Hyper-Parameter Optimization**. Journal of Machine Learning Research. v. 13. n. 10. pp. 281-305, 2012.

BOGGS, S.A. Partial discharge: overview and signal generation. In: **IEEE Electrical Insulation Magazine**, vol. 6, no. 4, pp. 33-39, July-Aug. 1990a, doi: 10.1109/57.63057.

BOGGS, S.A. Partial discharge. III. Cavity-induced PD in solid dielectrics. In: **IEEE Electrical Insulation Magazine**, vol. 6, no. 6, pp. 11-16, Nov.-Dec. 1990b, doi: 10.1109/57.63094.

CAPELINI, R.M. **Inspeção Remota de Isoladores em Linhas de Transmissão a Partir de Sinais de Descargas Parciais Externas**. 2015. 194p. Tese (Doutorado) – Laboratório de Alta Tensão, Universidade Federal de Itajubá, Itajubá, 2015.

CHERNEY, E.A. Partial discharge. V. PD in polymer-type line insulators. In: **IEEE Electrical Insulation Magazine**, vol. 7, no. 2, pp. 28-32, March-April 1991, doi: 10.1109/57.75766.

CHOLLET, F. et al. **Keras**, 2015. Disponível em: <<https://keras.io/>>. Acesso em: 20 dez. 2019.

DETTAT, A. **Applied Deep Learning - Part 4: Convolutional Neural Networks** – Towards Data Science, 2017. Disponível em: <<https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>>. Acesso em: 01 jul. 2020.

DONG, Y.-L. et al. Features Extraction and Mechanism Analysis of Partial Discharge Development under Protrusion Defect. **Journal of Electrical Engineering and Technology**. v.10, n.1, pp. 344–354, jan. 2015. Disponível em: <<https://doi.org/10.5370/jeeet.2015.10.1.344>>. Acesso em: 08 jul. 2020.

DUMOULIN, V.; VISIN, F. **A guide to convolution arithmetic for deep learning**. ArXiv e-prints:1603.07285, mar. 2016. Disponível em: <<https://arxiv.org/abs/1603.07285>>. Acesso em: 05 fev. 2019.

ELEKTOR MAGAZINE. **PicoScope 2000: 6 instruments, 15 protocols in one ultra-portable package**. Artigo por Jan Buiting, 28 abr. 2016. Disponível em: <<https://www.elektormagazine.com/news/picoscope-2000-series-oscilloscopes-6-instruments-15-protocols-in-one-ultra-portable-package>>. Acesso em: 08 jul. 2020.

ENGELBRECHT, C. et al. **Artificial Pollution Test for Polymer Insulators**. CIGRE Technical Brochure 555 (2013).

FONTANA et al. Sensor Network for Monitoring the State of Pollution of High-Voltage Insulators Via Satellite. In: **IEEE Transactions on Power Delivery**, v. 27, n. 2, pp. 953-962, April 2012, doi: 10.1109/TPWRD.2012.2183623.

FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics** 36, 193–202 (1980). doi: 10.1007/BF00344251.

GOODFELLOW, I., et al. **Generative Adversarial Networks**. ArXiv e-prints: 1406.2661, jun. 2014. Disponível em: <<https://arxiv.org/abs/1406.2661>>. Acesso em: 20 dez. 2019.

HADIPOUR, M.; SHIRAN, M.A. Various Pollutions of Power Line Insulators. **Majlesi Journal of Electrical Engineering**. v.6, n.1, nov. 2017.

HAEFELY TEST AG. **DDX 9121b Partial Discharge Detector** – Operating Instructions (Manual de Equipamento), Suíça: 2014.

HUBEL, D.H.; WIESEL, T.N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. **The Journal of physiology**, 160(1), 106–154. 1962. doi: 10.1113/jphysiol.1962.sp006837.

HVPD. **High Frequency Current Transformer** – Part Code: HFCT100 (Folha de Dados), Salford (Reino Unido): 2018.

INMET Instituto Nacional de Meteorologia. **Normais Climatológicas do Brasil: 1981-2010**. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=clima/normaisClimatologicas>>. Acesso em: 25 abr. 2020.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 60060-1: High-voltage test techniques - Part 1: General definitions and test requirements. Genebra, p. 149. 2010.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 60168: Tests on indoor and outdoor post insulators of ceramic material or glass for systems with nominal voltages greater than 1 000 V. Genebra, p. 91. 2001.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 60270: High-voltage test techniques - Partial discharge measurements. Genebra, p. 226. 2015.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 60507: Artificial pollution tests on high-voltage ceramic and glass insulators to be used on a.c. systems. Geneva, p. 77. 2013.

JAHANGIRI T. et al. Electrical Design of Fully Composite Pylon. In: **Electrical Design of a 400 kV Composite Tower**. Lecture Notes in Electrical Engineering, vol 557. Springer, Cham, 2020, doi: 10.1007/978-3-030-17843-7_4.

JANGHEL, R.R. et al. Breast cancer diagnosis using Artificial Neural Network models. **The 3rd International Conference on Information Sciences and Interaction Sciences**, Chengdu, 2010, pp. 89-94, doi: 10.1109/ICICIS.2010.5534716.

KERAS. **Why choose Keras?** Disponível em: <https://keras.io/why_keras/>. Acesso em: 20 dez. 2019.

KHAN ACADEMY. **Information entropy**. (Vídeo), 28 abr. 2014. Disponível em: <<https://www.khanacademy.org/computing/computer-science/informationtheory/moderninfotheory/v/information-entropy>>. Acesso em: 08 jul. 2020.

KLUYVER T. et al. Jupyter Notebooks—a publishing format for reproducible computational workflows. **Positioning and Power in Academic Publishing: Players, Agents and Agendas**. pp. 87-90, 2016. doi:10.3233/978-1-61499-649-1-87. Software available from jupyter.org.

LECUN, Y. et al. Backpropagation Applied to Handwritten Zip Code Recognition, **Neural Computation**, 1(4):541-551, Winter 1989.

LECUN, Y. et al. Object Recognition with Gradient-Based Learning. In: **Shape, Contour and Grouping in Computer Vision. Lecture Notes in Computer Science**, vol 1681. Springer, Berlin, Heidelberg, 1999. doi: 10.1007/3-540-46805-6_19.

LECUN, Y.; BENGIO, Y. Convolutional Networks for Images, Speech, and Time-Series. In: Arbib, M. A. (Eds), **The Handbook of Brain Theory and Neural Networks**, MIT Press, 1995.

LEE, G.R. et al. PyWavelets: A Python package for wavelet analysis. **Journal of Open Source Software**, 4(36), 1237, 2019. Disponível em: <<https://doi.org/10.21105/joss.01237>>. Acesso em: 06 nov 2019.

LI G. et al. **Partial discharge patterns recognition with deep Convolutional Neural Networks**. 2016 International Conference on Condition Monitoring and Diagnosis (CMD), Xi'an, 2016, pp. 324-327, doi: 10.1109/CMD.2016.7757816.

LI, G. et al. **Partial Discharge Recognition with a Multi-Resolution Convolutional Neural Network**. *Sensors* 2018, 18, 3512, doi: 10.3390/s18103512.

LOOMS, J.S.T. Insulators for high voltages—(IEE power engineering series; 7). Peter Peregrinus Ltd. London: 1988.

LOTFY, M. et al. Investigation of Focal Loss in Deep Learning Models For Femur Fractures Classification. **2019 International Conference on Electrical and Computing Technologies and Applications (ICECTA)**, Ras Al Khaimah, United Arab Emirates, 2019, pp. 1-4, doi: 10.1109/ICECTA48151.2019.8959770.

LU, Y. et al. **Convolutional Neural Network Based Transient Earth Voltage Detection**. 2016 15th International Symposium on Parallel and Distributed Computing (ISPDC), Fuzhou, 2016, pp. 386-389, doi: 10.1109/ISPDC.2016.65.

LUMBA, L.A. et al. The Step of Partial Discharge Pattern Recognition Using Fuzzy Logic. In: **2019 2nd International Conference on High Voltage Engineering and Power Systems**

(**ICHVEPS**), Denpasar, Bali, Indonesia, 2019, pp. 035-039, doi: 10.1109/ICHVEPS47643.2019.9011078.

MIAO, Y. et al. Calculation Method of Partial Discharge Severity Assessment Index Weight Using Factor Analysis Based on Mutual Information. In: **2018 IEEE International Conference on High Voltage Engineering and Application (ICHVE)**, ATHENS, Greece, 2018, pp. 1-4, doi: 10.1109/ICHVE.2018.8642001.

MILIOUDIS, A.; ANDREOU, G.; LABRIDIS, D. On-line partial discharge monitoring system for underground MV cables–Part II: Detection and location. **International Journal of Electrical Power & Energy Systems**, v. 109, p. 395-402, 2019.

MONTANARI, G.C.; SERI, P.; CONTIN, A. How to Deal with the Severity of Different Partial Discharge Sources in Rotating Machines: The Definition of a New Health Index. In: **2018 IEEE Electrical Insulation Conference (EIC)**, San Antonio, TX, 2018, pp. 469-472, doi: 10.1109/EIC.2018.8481118.

MONTEIRO PORFÍRIO, D. **O Intemperismo Tropical como Agente de Degradação de Cadeias de Isoladores de Alta Tensão em Subestações na Amazônia Oriental: Estudo de Caso em Barcarena-PA e São Luís-MA**. 2018. 243p. Tese (Doutorado) – Instituto de Geociências, Universidade Federal do Pará, Belém, 2018.

NEWARK. **PICOSCOPE 2206B - PICO TECHNOLOGY - PC USB Oscilloscope, Digital Triggering, PicoScope 2000 Series**. Disponível em: <<https://www.newark.com/pico-technology/picoscope-2206b/oscilloscope-usb-2-ch-50mhz-500msps/dp/81Y4874>>. Acesso em: 08 jul. 2020.

NGK INSULATORS. **Anti-Contamination | Products | NGK INSULATORS, LTD**. Ordinary Glaze Insulator. Disponível em: <<https://www.ngk-insulators.com/en/product/insulator/technical/scg.html>>. Acesso em: 28 jul. 2020.

NISHA et al. Tuning of PID parameters using artificial neural network. **2009 International Multimedia, Signal Processing and Communication Technologies**, Aligarh, 2009, pp. 309-312, doi: 10.1109/MSPCT.2009.5164237.

O'FLYNN, C.; HARFOUCHE, M. **pico-python**. (Biblioteca Python), 2013. Disponível em: <<https://github.com/colinoflynn/pico-python/>>. Acesso em: 08 jul. 2020.

PARK, S.; JUNG, K. Design of a Circularly-Polarized UHF Antenna for Partial Discharge Detection. In: **IEEE Access**, v. 8, pp. 81644-81650, 2020, doi: 10.1109/ACCESS.2020.2991158.

PÉREZ, F.; GRANGER, B. E. IPython: A System for Interactive Scientific Computing, **Computing in Science and Engineering**, v.9, n.3, pp. 21-29, May/June 2007, doi:10.1109/MCSE.2007.53. Software available from ipython.org.

PETRI, L.P.S. et al., Partial Discharge Spectrogram Data Augmentation based on Generative Adversarial Networks. **2019 International Conference on Electrical and Computing Technologies and Applications (ICECTA)**, Ras Al Khaimah, United Arab Emirates, 2019, pp. 1-5, doi: 10.1109/ICECTA48151.2019.8959711.

QI, Y. et al. Design of Ultra-Wide Band Metal-Mountable Antenna for UHF Partial Discharge Detection. In: **IEEE Access**, v. 7, pp. 60163-60170, 2019, doi: 10.1109/ACCESS.2019.2910211.

RADAR ENGINEERS. **Model 242** – AM-UHF RFI Locator 500KHz-1000MHz – Operation Manual (Manual de Equipamento), Portland, OR (EUA): 2012.

RADAR ENGINEERS. **Model 242 AM-UHF RFI Locator**. (Folha de Dados). Disponível em: <<http://www.detektor.no/Resource/File/0/BR-RE-RFI-242.PDF>>. Acesso em: 08 jul. 2020b.

RADAR ENGINEERS. **Model 250** – Parabolic Pinpointer – Instruction Manual (Manual de Equipamento), Portland, OR (EUA): 1998.

RADAR ENGINEERS. **RFI TVI Locators**. Disponível em: <<http://www.radarengineers.com/10-rfi-tvi-locators.aspx>>. Acesso em: 08 jul. 2020a.

RADFORD, A.; METZ, L.; CHINTALA, S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. ArXiv e-prints: 1511.06434, jan. 2016. Disponível em: <<https://arxiv.org/pdf/1511.06434.pdf>>. Acesso em: 07 jul. 2020.

RAMOS HERNANZ, J.A. et al. Insulator pollution in transmission lines. **Renewable Energy & Power Quality Journal**, v.1, n.4, abr. 2006. Disponível em: <<https://doi.org/10.24084/repqj04.256>>. Acesso em: 08 jul. 2020.

ROCHA, P. H. V. et al. Inspection in overhead insulators through the analysis of the irradiated RF spectrum. **International Journal of Electrical Power & Energy Systems**, v. 113, p. 355-361, 2019.

SHARMA, K. **Polymeric Insulators**. (Technical Article). Disponível em: <<http://www.appstate.edu/~clementsjs/surfaceflashover/insulatortesting.pdf>>. Acesso em: 12 abr. 2020.

STANFORD. **CS231n Convolutional Neural Networks for Visual Recognition**. (Stanford Computer Vision class), 2020. Disponível em: <<https://cs231n.github.io/convolutional-networks/>>. Acesso em: 30 jul. 2020.

STEWART, B.G. et al. A Simple Metric for Assessing the Severity of Partial Discharge Activity Based on Time-Sequence-Analysis-Discharge Level Patterns. **Transactions on Electrical and Electronic Materials**, v.7, n.6, pp. 313–318, dez. 2006. Disponível em: <<https://doi.org/10.4313/TEEM.2006.7.6.313>>. Acesso em: 07 jul. 2020.

STONE, G.C. et al. Advances in Interpreting Partial Discharge Test Results from Motor and Generator Stator Windings. In: **CIGRE**, Paper 11-202 (2002).

STONE, G.C. Partial discharge. VII. Practical techniques for measuring PD in operating equipment. In: **IEEE Electrical Insulation Magazine**, vol. 7, no. 4, pp. 9-19, July-Aug. 1991, doi: 10.1109/57.87656.

SUWARNO. **Study on the wave form of leakage current on the 20 kV post-pin ceramic insulators under various conditions**. Proceedings of 2001 International Symposium on Electrical Insulating Materials (ISEIM 2001). 2001 Asian Conference on Electrical Insulating Diagnosis (ACEID 2001). 33rd Symposium on Electrical and Ele, Himeji, Japan, 2001, pp. 387-390, doi: 10.1109/ISEIM.2001.973682.

TAHERIAN, R. Application of Polymer-Based Composites: Polymer-Based Composite Insulators, **Electrical Conductivity in Polymer-Based Composites: Experiments, Modelling and Applications**. Elsevier: 2019. pp. 131–181.

TANG, J. et al. Assessment of PD severity in gas-insulated switchgear with an SSAE. In: **IET Science, Measurement & Technology**, v. 11, n. 4, pp. 423-430, 7 2017, doi: 10.1049/iet-smt.2016.0326.

TENBOHLEN, S. et al. Partial discharge measurement in the ultra high frequency (UHF) range. In: **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 15, n. 6, pp. 1544-1552, December 2008, doi: 10.1109/TDEI.2008.4712656.

TENSORFLOW. **An Open Source Machine Learning Framework for Everyone** – GitHub. Disponível em: <<https://github.com/tensorflow/tensorflow>>. Acesso em: 20 dez. 2019.

TRINH, N.G. Partial discharge XIX: discharge in air part I: physical mechanisms. In: **IEEE Electrical Insulation Magazine**, vol. 11, no. 2, pp. 23-29, March/April 1995, doi: 10.1109/MEI.1995.1025997.

WEISSTEIN, E.W. **Spearman Rank Correlation Coefficient**. From MathWorld—A Wolfram Web Resource. Disponível em: <<https://mathworld.wolfram.com/SpearmanRankCorrelationCoefficient.html>>. Acesso em: 26 jul. 2020a.

WEISSTEIN, E.W. **Zero-Sum Game**. From MathWorld—A Wolfram Web Resource. Disponível em: <<https://mathworld.wolfram.com/Zero-SumGame.html>>. Acesso em: 07 jul. 2020b.

APÊNDICE A – FORMAS DE ONDA DE SINAIS DE DESCARGAS PARCIAIS

Como descrito anteriormente, as redes neurais são utilizadas, neste trabalho, para a classificação dos sinais que se deseja analisar e se obter o grau de severidade. Um exemplo de sinal que, embora não contenha pulsos de descargas parciais, compõe o conjunto que não se deseja analisar é mostrado na Figura 55. Trata-se de um sinal medido na Subestação Itajubá 3, que contém uma densidade muito elevada de pulsos, devido ao grande número de aparatos de alta tensão.

É possível se observar três pulsos distintos, de magnitude mais alta, sincronizados com os ciclos da tensão fundamental. Contudo, a faixa de amplitude próxima de 10 mV, que aparenta ser um tipo de ruído de fundo, é, na verdade, uma sequência de pulsos de descargas parciais, com magnitude e presença praticamente constantes, como mostra, em detalhe, a Figura 56 em uma janela de 1 ms do sinal. Esta medição foi feita por meio da antena e do filtro passa-altas.

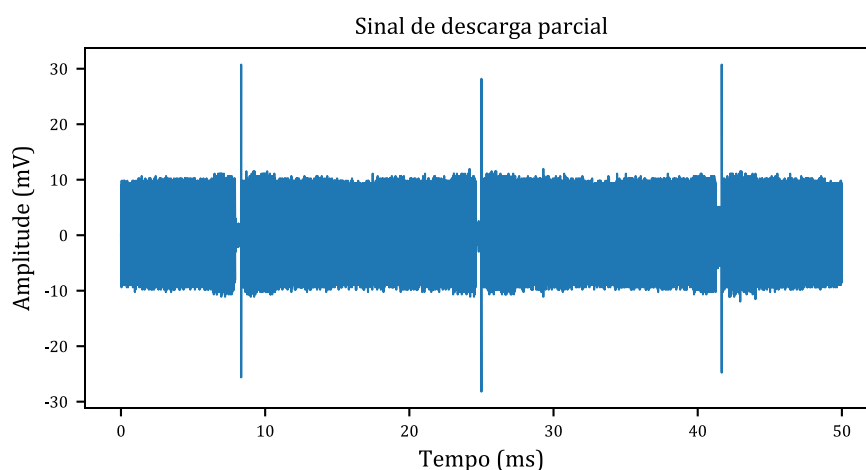


Figura 55 – Forma de onda relativa à atividade de descargas parciais na Subestação Itajubá 3 (janela de 50 ms).
Fonte: Próprio autor




Figura 56 – Forma de onda relativa à atividade de descargas parciais na Subestação Itajubá 3 (janela de 1 ms).
Fonte: Próprio autor

A seguir, retornando-se para os ensaios em laboratório, são mostradas algumas formas de onda de descargas parciais obtidas através do ensaio não padronizado pelo método do centelhador e do ensaio padronizado de poluição artificial, tanto pelo método da névoa salina, quanto pelo método da camada sólida. Estes sinais são classificados pela rede neural como descargas parciais.

Primeiramente, a Figura 57 mostra a forma de onda do ensaio com o centelhador formando um *gap* de aproximadamente 1 mm, obtida através de medições utilizando-se o HFCT. Observa-se que os pulsos das descargas se apresentam de forma bastante destacada, com duas ou três ocorrências por semiciclo da tensão fundamental. A Figura 58, por sua vez, apresenta a forma de onda para um *gap* de 5 mm, a partir da qual é possível se observar uma redução na ocorrência dos pulsos, passando para apenas um pulso por semiciclo da tensão fundamental.




Figura 57 – Forma de onda relativa ao uso do centelhador com um *gap* de 1 mm.
Fonte: Próprio autor

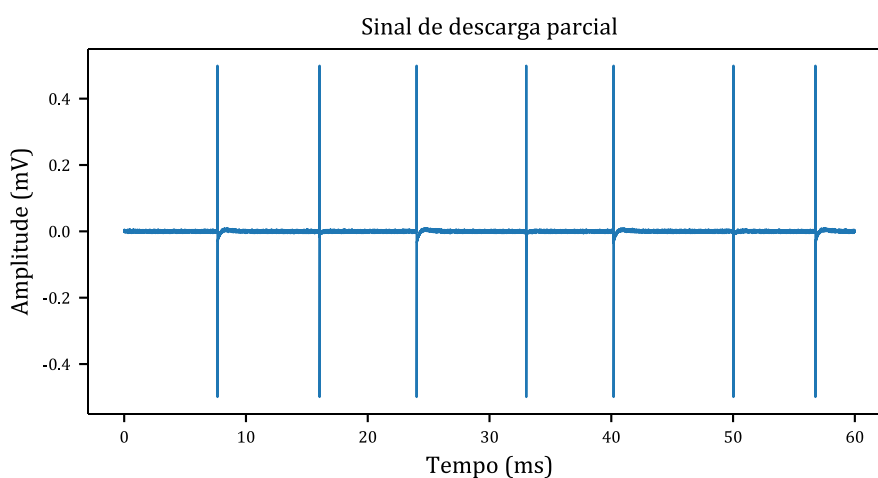


Figura 58 – Forma de onda relativa ao uso do centelhador com um *gap* de 5 mm.
Fonte: Próprio autor

Considerando-se o ensaio de poluição artificial pelo método da névoa salina, utilizando uma solução de concentração igual a 80 kg/m^3 de NaCl, a Figura 59 mostra a forma de onda obtida durante o procedimento de suportabilidade, após 1 hora de tensão aplicada. As medições neste ensaio foram realizadas com o resistor *shunt*, por este motivo, a escala vertical mostra a amplitude da corrente de fuga, medida em miliampères. A Figura 60 mostra, em detalhe, uma janela de tempo menor deste mesmo sinal, onde é possível se observar os pulsos das descargas parciais ocorrendo sobre o corpo de prova.




Figura 59 – Forma de onda relativa ao ensaio de poluição artificial pelo método da névoa salina.
Fonte: Próprio autor




Figura 60 – Forma de onda relativa ao ensaio de poluição artificial pelo método da névoa salina (detalhe).
Fonte: Próprio autor

Finalmente, foram realizados os ensaios de poluição artificial pelo método da camada sólida. Estes ensaios trouxeram os resultados mais próximos à condição observada em campo, como nos isoladores da Forquilha, por exemplo, e em outras estruturas inspecionadas em São Luís. Neste ensaio, foi considerada a variação da umidade relativa no interior da câmara de ensaio, de forma que o padrão do sinal se alterou ao longo do ensaio, isto é, o número de pulsos

diminuiu com a redução da umidade relativa. As formas de onda mostradas a seguir foram coletadas próximas ao início do ensaio, após a tensão ser aplicada ao corpo de prova, quando o valor da umidade ainda estava próximo de 80% ou mais.

A Figura 61 mostra a forma de onda para o ensaio com a contaminação equivalente ao período de julho a outubro. A amostragem do sinal foi realizada logo no início do ensaio, com uma tensão aplicada de 30 kV. Observa-se uma densidade elevada de pulsos, com agrupamentos em ambos os semiciclos da tensão fundamental, dos quais, aqueles que apresentam picos de maior magnitude correspondem aos semiciclos positivos da tensão.

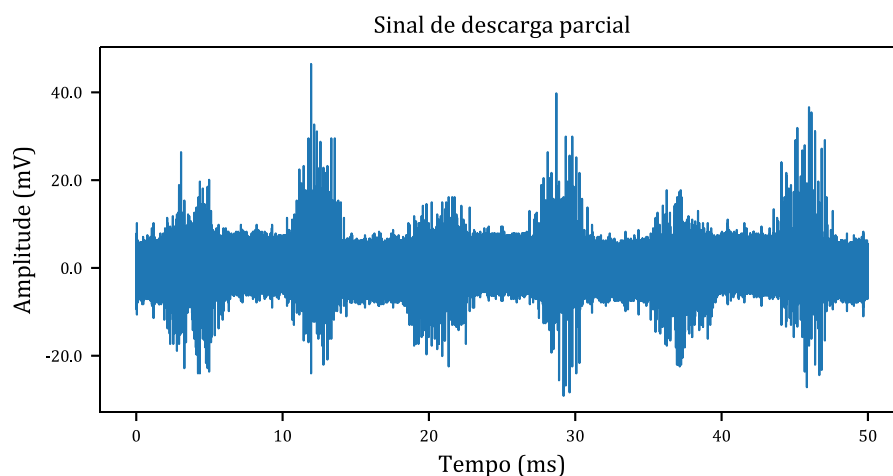


Figura 61 – Forma de onda relativa ao ensaio de poluição artificial pelo método da camada sólida (jul.-out.).
Fonte: Próprio autor

A Figura 62 mostra a forma de onda para o ensaio com a contaminação equivalente ao mês de outubro. A amostragem do sinal foi realizada a uma umidade relativa de 78% no interior da câmara de ensaio, com uma tensão aplicada de 29 kV. Observam-se os agrupamentos de pulsos em cada semiciclo da tensão fundamental, porém agora com picos mais expressivos, de maior magnitude que os observados no caso anterior, correspondendo aos semiciclos positivos da tensão.

A Figura 63 mostra a forma de onda para o ensaio com a contaminação equivalente à metade do mês de outubro. A amostragem do sinal foi realizada a uma umidade relativa de 80% no interior da câmara de ensaio, com uma tensão aplicada de 40 kV. Observam-se os agrupamentos de pulsos em cada semiciclo da tensão fundamental, porém agora com uma densidade de pulsos menor que os casos anteriores. Os agrupamentos com menor número de pulsos correspondem aos semiciclos positivos da tensão.




Figura 62 – Forma de onda relativa ao ensaio de poluição artificial pelo método da camada sólida (out.).
Fonte: Próprio autor




Figura 63 – Forma de onda relativa ao ensaio de poluição artificial pelo método da camada sólida (50% out.).
Fonte: Próprio autor