



PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



MATHEUS SANTOS MACEDO

DISSERTAÇÃO

**CLASSIFICAÇÃO DA HIDROFOBICIDADE EM ISOLADORES ELÉTRICOS UTILIZANDO  
ANÁLISE DE FREQUÊNCIA E RNA**



São Cristóvão  
2022

MATHEUS SANTOS MACEDO

CLASSIFICAÇÃO DA HIDROFOBICIDADE EM ISOLADORES ELÉTRICOS UTILIZANDO ANÁLISE DE FREQUÊNCIA E  
RNA

*Dissertação submetida ao programa de pós-graduação em Engenharia Elétrica (PROEE), da instituição Fundação Universidade Federal de Sergipe, como parte dos requisitos para a obtenção de título de mestre em Engenharia Elétrica.*

Área de Concentração: Sistema Elétrico de Potência.

Orientador: Professor Tarso Vilela Ferreira, D. Sc.

Aprovado pelo colegiado do PROEE em 29/08/2022.

São Cristóvão  
2022



UNIVERSIDADE FEDERAL DE SERGIPE  
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA  
COORDENAÇÃO DE PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA-PROEE

## TERMO DE APROVAÇÃO

### "Classificação da Hidrofobicidade em Isoladores Elétricos Utilizando Análise de Frequência e RNA"

Discente:

**Matheus Santos Macedo**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Sergipe, como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica.

Aprovada pela banca examinadora composta por:

**Prof. Dr. Jugurta Rosa Montalvão Filho (PROEE/UFS)**  
**Presidente**

**Prof. Dr. George Victor Rocha Xavier (DEL/UFS)**  
**Examinador Externo**

**Prof. Dr. Marcus Tullius Barros Florentino (IFPE)**  
**Examinador Externo**

**Matheus Santos Macedo**  
**Candidato**

Cidade Universitária "Prof. José Aloísio de Campos", 29 de agosto de 2022.

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL  
UNIVERSIDADE FEDERAL DE SERGIPE**

M141c Macedo, Matheus Santos  
Classificação da hidrofobicidade em isoladores elétricos utilizando análise de frequência e RNA / Matheus Santos Macedo ; orientador Tarso Vilela Ferreira. - São Cristóvão, 2022.  
124 f. : il.

Dissertação (mestrado em Engenharia Elétrica) – Universidade Federal de Sergipe, 2022.

1. Isoladores e isolamentos elétricos. 2. Processamento de imagens – Técnicas digitais. 3. Redes neurais (Computação). I. Ferreira, Tarso Vilela orient. II. Título.

CDU 621.3

*Dedico este trabalho a Deus, criador de todas as coisas, a meus pais, José Henrique e Creunice, meus queridos irmãos e a minha amada noiva Letícia, sem vocês nada disso seria possível.*

## AGRADECIMENTOS

Agradeço primeiramente a Deus, Pai e Criador, por ter me concedido forças e me mantido sempre firme nessa jornada, mesmo durante os percalços e dificuldades do caminho. Fruto Dele ainda é a dádiva de ter seres humanos tão especiais quanto José Henrique e Creunice em minha vida e dádiva maior ainda poder chamá-los de pai e mãe. Obrigado por me acompanharem nessa jornada, tanto aqui no plano terreno, quanto no celestial. Sei que aí do céu, meu pai, o senhor continua rogando por nossa família.

Agradeço ainda a minha amada noiva Letícia, que sempre se manteve ao meu lado, sendo meu maior suporte. Obrigado por toda cumplicidade, paciência e por sempre fazer-me sentir tão amado. Esta conquista é apenas uma das muitas que iremos compartilhar juntos.

Estendo minha gratidão a meus queridos irmãos, Carol e Felipe que sempre se fizeram presentes, compartilhando a felicidade em cada conquista.

Agradeço a meu querido amigo Juan, o irmão que a vida me presenteou. Sua amizade e cumplicidade me ensinam a cada dia a dar sempre o melhor de mim em todas as investidas nessa vida.

Ao meu orientador, Tarso Vilela Ferreira, um ser humano fantástico, dotado de uma personalidade magnética, capaz de fazer este engenheiro de controle e automação embrenhar-se no mundo da elétrica de potência, e gostar... Ao senhor, professor, externo meu muito obrigado pela oportunidade de poder trabalhar contigo, pela paciência e confiança depositadas, pelo incentivo e compreensão.

Sou muito grato a toda a equipe do Laboratório de Automação Controle e Simulação (LACS) da Universidade Federal de Sergipe (UFS), em especial aos colegas de mestrado Thiago Mota, Bruno Silveira, Gustavo Aragão e Rebeca Maia pela ajuda na rotina de pesquisa e pelas discussões sempre tão produtivas.

Externo minha gratidão aos professores do Departamento de Engenharia Elétrica (DEL) e do Programa de Pós-Graduação em Engenharia Elétrica (PROEE), pelas lições ensinadas e pela ajuda nas questões científicas inerentes a este trabalho.

Agradeço ainda às Centrais Elétricas de Sergipe SA (CELSE), pelo apoio no desenvolvimento prático deste trabalho, no âmbito do projeto de Pesquisa e Desenvolvimento “Gestão dos Impactos da Salinidade em Isolamentos” (GImpSI), e conceder acesso às suas instalações para que a validação do método proposto neste trabalho fosse realizada.

Obrigado à CAPES pela bolsa de estudos que recebi durante todo o mestrado.

Por fim, agradeço a todos que de uma forma ou de outra contribuíram para essa conquista.

*“E o que há algum tempo era jovem novo  
Hoje é antigo, e precisamos todos rejuvenescer  
[...] No presente a mente, o corpo é diferente  
E o passado é uma roupa que não nos serve mais.”*

Belchior

## RESUMO

As linhas de transmissão realizam o transporte da energia produzida nas centrais geradoras até os centros de distribuição. Nessas linhas, os isoladores desempenham o papel de segregar regiões de potencial elétrico diferente, enquanto realizam a função mecânica de suporte dos cabos. Devido à natureza da sua função, os isoladores estão expostos a esforços elétricos e mecânicos durante toda sua vida útil, além de suportarem a ação do meio ambiente através da irradiação solar, umidade, poluição e demais intempéries. No que tange aos isoladores de alta tensão do tipo polimérico, muito empregados no cenário atual, esses esforços levam à diminuição da sua hidrofobicidade de superfície, permitindo que a umidade se acumule sobre o isolador, facilitando o aumento da corrente de fuga e a probabilidade de ocorrência de uma descarga disruptiva (*flashover*). Nesse sentido, o presente trabalho apresenta uma metodologia para avaliação e classificação da hidrofobicidade de superfície de isoladores de alta tensão do tipo polimérico com base no método proposto pelo *Swedish Transmission Research Institute* (STRI). A classificação proposta é realizada de forma automática, utilizando uma rede neural artificial do tipo Perceptron de Múltiplas Camadas, com base no processamento digital de imagens, utilizando informações de frequência espacial. Um método para segmentação de imagens de hidrofobicidade produzidas sob iluminação não uniforme e com baixo contraste também é proposto. Ademais, uma base de imagens contendo 1200 amostras de superfície hidrofóbica em vários estágios de degradação foi criada. Imagens de uma coluna isolante coletadas no ambiente de uma subestação de 500 kV também foram utilizadas para validar o método. Os resultados obtidos foram comparados com outros dois métodos da literatura e pôde-se perceber que a metodologia desenvolvida foi capaz de segmentar e classificar com sucesso imagens de hidrofobicidade de superfície, obtendo uma taxa de acerto superior a 78% para a base de dados utilizada.

**Palavras-chave:** Hidrofobicidade, Isoladores Poliméricos, Processamento Digital de Imagens, Rede Neural Artificial, STRI.

## ABSTRACT

Transmission lines transport the energy produced in power plants to distribution centers. In these lines, insulators perform the role of segregating regions of different electrical potential, while accomplishing the mechanical function of supporting the cables. Due to the nature of their function, insulators are exposed to electrical and mechanical stress throughout their life span, in addition to withstanding the wear caused by the environment through solar radiation, moisture, pollution and other weather conditions. Regarding polymeric high voltage insulators, which are the kind of insulator most widely used in the current scenario, these stresses lead to a decrease in their surface hydrophobicity, allowing moisture to accumulate on the insulator, giving rise to a leakage current and increasing the probability of a flashover to occur. In this sense, the present work presents a methodology for evaluating and classifying the surface hydrophobicity of polymeric high voltage insulators based on the method proposed by the Swedish Transmission Research Institute (STRI). The classification is performed automatically, using a Multilayer Perceptron artificial neural network, based on digital image processing, using spatial frequency information. A method for segmenting hydrophobicity images produced under unbalanced lighting conditions and with low contrast is also proposed. Furthermore, an image database containing 1200 hydrophobic surface samples in various stages of degradation was created. Images of an insulating column collected in the environment of a 500 kV substation were also used to validate the proposed method. The results obtained were compared with two other methods in the literature and it could be seen that the methodology developed was able to successfully segment and classify surface hydrophobicity images, obtaining a success rate above 78% for the database used.

**Keywords:** Hydrophobicity, Polymeric Insulators, Digital Image Processing, Artificial Neural Network, STRI.

# SUMÁRIO

|                                                                   |      |
|-------------------------------------------------------------------|------|
| Lista de Ilustrações                                              | xiii |
| Lista de Tabelas                                                  | xv   |
| Lista de Abreviaturas e Siglas                                    | xvi  |
| 1 Introdução                                                      | 17   |
| 1.1 Objetivos                                                     | 21   |
| 1.1.1 Objetivo Primário                                           | 21   |
| 1.1.2 Objetivos Secundários                                       | 21   |
| 1.1.3 Estrutura do Trabalho                                       | 22   |
| 2 Fundamentação teórica                                           | 23   |
| 2.1 Isoladores de Alta Tensão                                     | 23   |
| 2.2 Hidrofobicidade em Isoladores                                 | 26   |
| 2.3 Processamento Digital de Imagens                              | 30   |
| 2.3.1 A Imagem Digital                                            | 33   |
| 2.3.2 Segmentação de Imagens                                      | 35   |
| 2.3.3 Processamento Morfológico                                   | 37   |
| 2.3.4 Equalização Adaptativa de Histograma Limitada por Contraste | 39   |
| 2.3.5 Correção de Iluminação em Imagens                           | 41   |
| 2.4 Transformada de Fourier                                       | 42   |
| 2.5 Redes Neurais Artificiais                                     | 44   |
| 2.5.1 O Neurônio Artificial                                       | 46   |
| 2.5.2 Rede Perceptron de Camada Única                             | 48   |
| 2.5.3 Rede Perceptron de Múltiplas Camadas                        | 49   |
| 3 Revisão Bibliográfica                                           | 52   |
| 4 Metodologia                                                     | 60   |
| 4.1 Geração da Base de Dados                                      | 60   |
| 4.2 Pré-Classificação das Imagens                                 | 62   |
| 4.3 Procedimento Computacional                                    | 63   |
| 4.3.1 Rotina de Segmentação                                       | 63   |
| 4.3.2 Extração de Características de Frequência                   | 68   |
| 4.3.3 Classificação das Amostras                                  | 70   |
| 5 Resultados                                                      | 74   |
| 5.1 Rotina de Segmentação                                         | 74   |
| 5.2 Análise da Segmentação                                        | 81   |

|       |                                                                                   |     |
|-------|-----------------------------------------------------------------------------------|-----|
| 5.3   | Análises da Classificação .....                                                   | 88  |
| 5.3.1 | Rede Neural Artificial .....                                                      | 90  |
| 5.3.2 | Avaliação da Classificação .....                                                  | 93  |
| 5.4   | Avaliação da Metodologia em Caso Real .....                                       | 96  |
| 5.5   | Achados Pós-Defesa .....                                                          | 102 |
| 6     | Conclusões e Trabalhos Futuros .....                                              | 106 |
|       | Publicações .....                                                                 | 110 |
|       | Referências .....                                                                 | 111 |
|       | Apêndice A – Guia para classificação do Banco de Imagens de Hidrofobicidade ..... | 115 |
|       | Apêndice B – Exemplos de Classificação STRI .....                                 | 118 |

## LISTA DE ILUSTRAÇÕES

|                                                                                                                                          |    |
|------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 - Conjunto de teste GD-710 para propriedades hidrofóbicas de isoladores compostos. ....                                         | 19 |
| Figura 2 - Isoladores de vidro em linha de transmissão. ....                                                                             | 24 |
| Figura 3 - Partes constituintes de um isolador polimérico. ....                                                                          | 25 |
| Figura 4 - Ângulo de contato em superfícies para avaliação da hidrofobicidade. ....                                                      | 26 |
| Figura 5 - Exemplos das classes de hidrofobicidade de HC1 a HC6. ....                                                                    | 29 |
| Figura 6 - Panorama geral no processamento de digital de imagens. ....                                                                   | 31 |
| Figura 7 - Representação simplificada de uma imagem digital. ....                                                                        | 33 |
| Figura 8 - Representação de imagem colorida e respectivos canais de cores RGB. ....                                                      | 35 |
| Figura 9 - Valores típicos de uma imagem (a) e sua respectiva imagem integral (b). ....                                                  | 36 |
| Figura 10 - Comparação entre diferentes métodos de limiarização. ....                                                                    | 37 |
| Figura 11 - Exemplos de operações de erosão e dilatação. ....                                                                            | 38 |
| Figura 12 - Comparação entre equalização de histograma global e CLAHE. ....                                                              | 41 |
| Figura 13 - Modelo de um neurônio artificial. ....                                                                                       | 46 |
| Figura 14 - Gráfico característico da função logística. ....                                                                             | 47 |
| Figura 15 - Gráfico característico da função tangente hiperbólica. ....                                                                  | 47 |
| Figura 16 - Gráfico característico da unidade linear retificada. ....                                                                    | 48 |
| Figura 17 - Representação de uma rede do tipo SLP. ....                                                                                  | 49 |
| Figura 18 - Arquitetura de uma rede MLP. ....                                                                                            | 50 |
| Figura 19 - Sistema de iluminação e amostra de hidrofobicidade. ....                                                                     | 61 |
| Figura 20 - Amostra do banco de imagens produzido, pertencente à classe HC1. ....                                                        | 62 |
| Figura 21 - Fluxograma do algoritmo de segmentação de imagens proposto. ....                                                             | 63 |
| Figura 22 - Representação simplificada da TDC de uma imagem 8 × 8: (a) TDC da Imagem; (b) Frequências removidas durante o processo. .... | 66 |
| Figura 23 - Gráficos dos coeficientes verticais e horizontais da TDC em relação à frequência. ....                                       | 67 |
| Figura 24 - Amostra original e a aplicação dos filtros no domínio da frequência para estimar o gradiente. ....                           | 67 |
| Figura 25 - Fluxograma do processo de extração de características de frequência a partir da TRF unidimensional. ....                     | 69 |
| Figura 26 - Fluxograma da metodologia desenvolvida e aplicada. ....                                                                      | 73 |
| Figura 27 - Amostra original de superfície hidrofóbica. ....                                                                             | 75 |
| Figura 28 - Amostra após equalização de histograma CLAHE. ....                                                                           | 75 |
| Figura 29 - Amostra após a realização de operações morfológicas. ....                                                                    | 76 |
| Figura 30 - Resultado da execução do filtro de aguçamento. ....                                                                          | 76 |
| Figura 31 - Resultado da etapa de balanceamento de brilho. ....                                                                          | 77 |
| Figura 32 - Resultado da reconstrução do fundo de uma imagem. ....                                                                       | 77 |
| Figura 33 - Resultado da correção de fundo aplicada à imagem filtrada. ....                                                              | 78 |
| Figura 34 - Resultado do limiar de imagem por limiarização adaptativa por partes. ....                                                   | 78 |
| Figura 35 - Resultado final após operações morfológicas. ....                                                                            | 79 |
| Figura 36 - Limiarização de amostra através de método de Otsu e do método proposto. ....                                                 | 80 |
| Figura 37 - Detalhamento das etapas do processo de segmentação. ....                                                                     | 80 |
| Figura 38 - Comparação entre resultados de segmentação. ....                                                                             | 82 |
| Figura 39 - Comparação entre a segmentação dos métodos analisados em um segundo conjunto de imagens. ....                                | 84 |
| Figura 40 - Comparação dos resultados dos métodos analisados em um terceiro conjunto de amostras. ....                                   | 85 |
| Figura 41 - Resultados do método proposto em um conjunto de amostras com adição de corante. ....                                         | 88 |
| Figura 42 - Vetores de características para cada classes de hidrofobicidade utilizando a TRF 1D. ....                                    | 89 |
| Figura 43 - Vetores de características para cada classes de hidrofobicidade utilizando a TRF 2D. ....                                    | 89 |
| Figura 44 - Destaque na porção central dos Vetores de características para cada classe de hidrofobicidade utilizando a TRF 2D. ....      | 90 |
| Figura 45 - Fotos capturadas de coluna isolante em campo. ....                                                                           | 97 |

|                                                                                                                          |     |
|--------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 46 - Amostras da hidrofobicidade de superfície da coluna isolante. ....                                           | 98  |
| Figura 47 - Amostras de hidrofobicidade de superfície da coluna isolante após segmentação. ....                          | 99  |
| Figura 48 - Média dos vetores de características de 50 amostras de cada classes submetidas a pré-<br>processamento. .... | 103 |
| Figura 49 - Média dos vetores de características de 50 amostras originais de cada classes. ....                          | 104 |
| Figura 50 - Fluxograma da metodologia desenvolvida desconsiderando a etapa de pré-processamento. ....                    | 105 |

## LISTA DE TABELAS

|                                                                                                                                         |     |
|-----------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 1 - Critérios para classificação da hidrofobicidade de superfície. ....                                                          | 29  |
| Tabela 2 - Parâmetros de classificação e método de tomada de decisão utilizados na bibliografia.....                                    | 59  |
| Tabela 3 - Topologia, parâmetros de entrada e taxa de acerto para cada método.....                                                      | 72  |
| Tabela 4 - Tempo de processamento computacional.....                                                                                    | 87  |
| Tabela 5 - Taxa de acerto média para 10 treinamentos em uma rede com 9, 12 e 15 neurônios na camada oculta. ....                        | 91  |
| Tabela 6 - Taxa de acerto média para 10 treinamentos utilizando diferentes vetores de características. ...                              | 92  |
| Tabela 7 - Representação das 10 MC do método proposto sobre 180 amostras do grupo de Teste. ....                                        | 92  |
| Tabela 8 - Representação das 10 MC do método proposto sobre o grupo de teste considerando níveis arbitrários. ....                      | 93  |
| Tabela 9 - Tempo de processamento de 1200 amostras para geração das entradas para RNA.....                                              | 94  |
| Tabela 10 - Representação das 10 MC – Método de Alves (2018). ....                                                                      | 95  |
| Tabela 11 - Representação das 10 MC – Método de Yang <i>et al.</i> (2018). ....                                                         | 95  |
| Tabela 12 - Representação das 10 MC do método de Alves (2018) sobre o grupo de teste considerando níveis arbitrários. ....              | 96  |
| Tabela 13 - Representação das 10 MC do método de Yang <i>et al.</i> (2018) sobre o grupo de teste considerando níveis arbitrários. .... | 96  |
| Tabela 14 - Confiabilidade da RNA na classificação das amostras nos 6 níveis de hidrofobicidade. ....                                   | 101 |
| Tabela 15 - Confiabilidade da RNA na classificação das amostras nos três níveis operacionais. ....                                      | 101 |
| Tabela 16 - Representação das 10 MC – Método proposto sem pré-processamento.....                                                        | 102 |

## LISTA DE ABREVIATURAS E SIGLAS

|       |                                                         |
|-------|---------------------------------------------------------|
| ANFIS | <i>Adaptive Neuro-Fuzzy Inference System</i>            |
| CLAHE | <i>Contrast-Limited Adaptive Histogram Equalization</i> |
| EPDM  | Etileno-propileno-dieno-monômero                        |
| FFT   | <i>Fast Fourier Transform</i>                           |
| HC    | Classe de Hidrofobicidade                               |
| MC    | Matriz de Confusão                                      |
| MLP   | <i>Multilayer Perceptron</i>                            |
| PDI   | Processamento Digital de Imagens                        |
| RAP   | Receita Anual Permitida                                 |
| RNA   | Rede Neural Artificial                                  |
| RNC   | Rede Neural Convolucional                               |
| RNP   | Rede Neural Probabilística                              |
| RTV   | <i>Room Temperature Vulcanized</i>                      |
| SLP   | <i>Single Layer Perceptron</i>                          |
| STRI  | <i>Swedish Transmission Research Institute</i>          |
| TDC   | Transformada Discreta do Cosseno                        |
| TDF   | Transformada discreta de Fourier                        |
| TF    | Transformada de Fourier                                 |
| TRF   | Transformada Rápida de Fourier                          |

# 1 INTRODUÇÃO

Ao longo da história contemporânea, a energia elétrica tem se tornado um recurso cada vez mais importante no desenvolvimento das sociedades. Potencialmente uma das formas de energia mais utilizadas, a eletricidade é quase impossível de substituir. A fim de suprir a grande demanda mundial por energia elétrica, sistemas cada vez mais complexos e interligados para geração, transmissão e distribuição de energia são necessários.

Para garantir o funcionamento eficiente e seguro do sistema elétrico, é indispensável segregar regiões com diferentes potenciais elétricos. Desta forma, materiais isolantes de muitas naturezas são empregados em várias configurações, de acordo com necessidades particulares (FERREIRA, GERMANO e DA COSTA, 2012).

Historicamente, isoladores de vidro e porcelana, conhecidos como isoladores cerâmicos, desenvolveram a função de isolamento nos sistemas de alta tensão. Os chamados isoladores orgânicos ou não-cerâmicos surgiram no mercado há quase 30 anos, e usam como principais materiais isolantes os compostos de carbono, tais como: borracha de etileno-propileno-dieno-monômero (EPDM); silício; resina epóxi; entre outros. Estes também são chamados isoladores poliméricos (ou isoladores compostos) e são uma realidade crescente nas últimas décadas, graças a propriedades desejáveis, tais quais: estabilidade química; resistência a intempéries, peso reduzido e alta hidrofobicidade de superfície, além de se apresentarem como uma alternativa viável em relação aos isoladores cerâmicos em localidades com altos índices de vandalismo.

Quando aplicados em alta tensão e sistemas de extra alta tensão, estes isoladores são, geralmente, compostos de uma haste de fibra de vidro reforçada com resina epóxi, para fornecer resistência mecânica, recoberta por material polimérico que irá desempenhar o papel dielétrico. Ambos os materiais têm alto desempenho como meio isolante. Além disso, o revestimento de material polimérico protege a fibra de vidro de intempéries e outros agentes degradantes.

Entre as propriedades desejadas em um isolador polimérico, a hidrofobicidade exerce um papel fundamental. De acordo com a norma IEC TS 62073:2016 Ed. 2.0 (*Guidance on the measurement of hydrophobicity of insulator*) a hidrofobicidade é definida como o estado de

uma superfície com uma baixa tensão superficial e que, portanto, é repelida ou repele a água. De modo semelhante, a propriedade oposta, a hidrofiliabilidade, é definida como o estado de uma superfície com alta tensão superficial e que, portanto, é atraída ou atrai a água, na forma de um filme sobre a mesma. Já a tensão superficial é definida como uma região de contato entre dois materiais diferentes, que possui espessura finita (geralmente menor que  $0,1\ \mu\text{m}$ ) e na qual a composição e a energia variam continuamente (IEC, 2016). Desse modo, a formação de filmes d'água sobre a superfície de um isolador é indesejável pois cria um trajeto de baixa resistência elétrica que intensifica as correntes de fuga de superfície que, por conseguinte, levam à degradação da capacidade isolante do equipamento e aumentam a probabilidade de um *flashover* (JIA e GUAN, 2002).

Por conseguinte, falhas nos isolamentos de linhas de transmissão ou distribuição e em subestações trazem diversas consequências indesejadas, desde interferências em sinais de rádio ou televisão, até danos materiais que podem retirar a linha de transmissão ou subestação de operação (FERREIRA, 2011), acarretando prejuízos financeiros de grande magnitude tanto para as unidades consumidoras, quanto para as concessionárias e permissionárias de energia. A ocorrência de desligamentos não programados pode causar danos aos equipamentos dos consumidores, bem como da própria concessionária, além de gerar custos de manutenção e incorrer à incidência de multa por parte das agências reguladoras.

Em perspectiva, as linhas de transmissão Cascavel Oeste - Salto Caxias (CVO-SCX), Cascavel Oeste – Subestação de Transmissão Foz do Iguaçu (CVO-STFI) e Salto Caxias – Salto Santiago (SCX-SSA), pertencentes à Copel Geração e Transmissão S.A. e operando em tensão de linha de 500 kV, localizadas na região oeste do estado do Paraná acumularam no período de 2008 a 2013 um total de 182 inspeções para manutenção, sendo 112 preditivas, 70 preventivas e 3 corretivas totalizando um custo de aproximadamente R\$ 14,6 milhões, representando aproximadamente 27,94% da Receita Anual Permitida (RAP) para as linhas em questão. No tangente a desligamentos não programados, no mesmo período foi registrado um episódio na linha SCX-SSA que durou 1 hora e 52 minutos e gerou uma perda no RAP de R\$ 349.218,00 (ROCHA, 2014).

Desse modo, é necessário buscar formas de avaliar a degradação dos isolamentos das linhas de transmissão, visando a redução da probabilidade de uma descarga disruptiva capaz de gerar um desligamento não-programado, além de agregar informação para o melhor planejamento das manutenções da linha que, como visto, possuem um alto impacto financeiro.

Quando a superfície de isoladores poliméricos é exposta às condições climáticas, a hidrofobicidade característica tende a desgastar-se devido à oxidação, acúmulo de poluentes e

graças ao envelhecimento natural, devido à exposição à radiação UV (ultravioleta) e intempéries, desse tipo de isolador (AMIN, AKBAR e AMIN, 2007). Consequentemente, é de interesse que se desenvolvam técnicas capazes de avaliar o estado da hidrofobicidade dos isoladores enquanto os mesmos encontram-se conectados à rede elétrica, sem a necessidade de removê-los para um laboratório. Existem atualmente muitos métodos para medir ou estimar a hidrofobicidade da superfície do isolador. O mais simples e amplamente utilizado em aplicações de campo é o método de pulverização combinado com o sistema de classificação de hidrofobicidade proposto pelo *Swedish Transmission Research Institute* (STRI) (STRI, 1992). Neste método, a amostra testada é pulverizada com água destilada a partir de um borrifador comum, capaz de produzir uma névoa fina. O spray deve ser aplicado 1 - 2 vezes por segundo a uma distância de 15-35 cm e deve continuar durante 20-30 segundos. Então, o padrão formado na superfície do isolador deve ser identificado dentro de uma das sete classes de hidrofobicidade (HC), variando de HC1 (altamente hidrofóbica) a HC7 (altamente hidrofílica), e definida de forma não objetiva de acordo com a forma das gotas de água e a porcentagem de regiões em que houve acúmulo de água na superfície do isolador. Note-se ainda que o procedimento deve ser realizado a uma pequena distância do isolador, para tal, existem soluções comerciais que visam realizar tanto o procedimento de aspersão a partir de uma distância segura utilizando-se de um bastão isolante, como a captura de imagens e posterior avaliação da imagem, como o conjunto de testes de hidrofobicidade de isoladores GD-710 fabricado pela HV Hipot Electric Co., Ltd., que pode ser visto através da Figura 1.

Figura 1 - Conjunto de teste GD-710 para propriedades hidrofóbicas de isoladores compostos.



Fonte: (M MADE-IN-CHINA, 2022).

O método STRI apresenta ainda algumas desvantagens relacionadas à subjetividade do procedimento, como: requerer técnicos habilidosos e tempo experimental adequado (DONG, FANG, *et al.*, 2015) e não apresentar uma modelagem adequada da propriedade (ALVES, DA COSTA, *et al.*, 2017), deixando a tarefa de classificação para a interpretação humana. Portanto, métodos objetivos baseados em processamento de imagem e extração, reconhecimento e que permitam uma classificação de padrões de forma automática são desejados. A este respeito, quase todos os métodos que dependem de processamento de imagem irão envolver uma etapa de segmentação, com a finalidade de separar as regiões molhadas e as gotas da superfície do isolador, para em seguida, analisar cada segmento separadamente. Assim, técnicas confiáveis, acuradas, preferencialmente de implementação simples e baixo custo computacional, capazes de segmentar adequadamente as gotas d'água do fundo circundante, são necessárias.

O desenvolvimento de técnicas passíveis de implementação em testes de campo é de grande interesse. Portanto, é necessário considerar parâmetros como iluminação desequilibrada, uma vez que fotos tiradas em ambientes externos podem não ter iluminação uniforme. No mais, técnicas de realce e processamento de imagens são necessárias para destacar as gotas e regiões molhadas do fundo da imagem, uma vez que, devido à transparência da água, o contraste entre os objetos de interesse e o fundo é reduzido. Alguns trabalhos foram realizados na segmentação de gotas de água para a classificação da hidrofobicidade de isoladores, conforme relatado por Dong *et al.* (2015), Liang *et al.* (2012) e Iruansi *et al.* (2016).

Desta forma, visando facilitar a identificação e classificação de imagens de superfícies de isoladores enquanto ainda em campo, o presente trabalho pretende desenvolver uma metodologia capaz de processar imagens de regiões hidrofóbicas e realizar a classificação de tais amostras em uma das sete classes de hidrofobicidade propostas pelo STRI. Para tal, serão utilizadas técnicas de processamento digital de imagens (PDI), baseadas em transformada do cosseno e processamento morfológico para segmentar as áreas referentes às gotas e regiões molhadas do restante da imagem para, em seguida, realizar a classificação do grau de hidrofobicidade. Ademais, buscando sua futura implementação em dispositivos móveis, é importante também que os algoritmos desenvolvidos possuam um baixo esforço computacional.

## 1.1 OBJETIVOS

### 1.1.1 OBJETIVO PRIMÁRIO

O objetivo principal do presente trabalho é desenvolver uma metodologia capaz de segmentar imagens contendo padrões de hidrofobicidade em condições de iluminação variadas e adversas e realizar sua posterior classificação em níveis de hidrofobicidade padronizados.

### 1.1.2 OBJETIVOS SECUNDÁRIOS

Como forma de atingir o objetivo primário deste trabalho, também foram definidos os seguintes objetivos secundários:

- i. Constituir uma base de dados estruturada com diversos níveis de hidrofobicidade em diversas condições de iluminação;
- ii. Desenvolver uma rotina computacional capaz de compensar variações na iluminação nas imagens, quando necessário;
- iii. Desenvolver uma rotina computacional capaz de segmentar as imagens da base de dados em plano de interesse (regiões molhadas) e plano de fundo, com baixo esforço computacional, visando futura implementação em dispositivos móveis;
- iv. Desenvolver rotinas computacionais específicas para extração de parâmetros a partir das amostras da base de dados, no domínio da frequência;
- v. Propor um método de classificação das imagens com base nos atributos das imagens no domínio da frequência e que demande baixo esforço computacional, visando futura implementação em dispositivos móveis.

### 1.1.3 ESTRUTURA DO TRABALHO

Este trabalho é organizado em 5 capítulos, além da introdução. No Capítulo 2, denominado “Fundamentação Teórica”, são descritos os isoladores elétricos, os fundamentos da imagem digital bem como suas técnicas de processamento, a Transformada de Fourier e por fim, as redes neurais artificiais (RNA).

No Capítulo 3, intitulado “Revisão Bibliográfica”, são expostos os trabalhos relacionados à classificação da hidrofobicidade de isoladores poliméricos de alta tensão por meio da utilização de técnicas de processamento digital de imagens, elencando o que existe de mais relevante na literatura até os dias atuais.

No Capítulo 4, “Metodologia”, são apresentados os algoritmos de segmentação, extração de características e classificação de hidrofobicidade desenvolvidos no decorrer dessa pesquisa.

As simulações, análises de dados e resultados obtidos ao longo da pesquisa são apresentados no Capítulo 5.

No Capítulo 6 são apresentadas as considerações finais e as recomendações para a continuidade da pesquisa desenvolvida nesta dissertação.

Por fim, são apresentadas as referências bibliográficas que fundamentaram a pesquisa.

## 2 FUNDAMENTAÇÃO TEÓRICA

Esta seção aborda os princípios construtivos dos isoladores de alta tensão e apresenta o conceito de hidrofobicidade aplicado a estes isoladores. Além disso, são apresentados os fundamentos das técnicas de PDI utilizadas neste trabalho, bem como a descrição de técnicas como a transformada rápida de Fourier (TRF) e as redes neurais artificiais (RNA).

### 2.1 ISOLADORES DE ALTA TENSÃO

Em geral, isoladores elétricos são equipamentos utilizados sempre que há a necessidade de segregar regiões com diferentes potenciais elétricos. No que tange aos isoladores de alta tensão, estes devem, além de fornecer isolamento elétrico entre as suas extremidades, prover sustentação mecânica aos cabos da linha de transmissão que compõe o sistema elétrico de potência.

Um isolador de alta tensão, utilizado no âmbito do sistema elétrico de potência, é composto basicamente por três estruturas: o dielétrico; ferragens ou eletrodos terminais, e partes internas que auxiliam na conexão entre o dielétrico e os eletrodos (GORUR, CHERNEY e BURNHAM, 1999). O tipo de dielétrico aplicado na construção do equipamento normalmente é a principal característica do isolador. Dessa forma, são utilizados atualmente isoladores do tipo cerâmico, em que o dielétrico é fabricado em porcelana ou vidro, bem como os isoladores à base de compósitos (também chamados de compostos), onde o dielétrico é construído em material polimérico (borracha de etileno-propileno-dieno ou silicone).

Por um longo período, os isoladores de porcelana e vidro comum dominaram as aplicações na indústria da eletricidade e, consequentemente, o mercado. Posteriormente, na década de 1930 surgiram os isoladores de vidro temperado, que se destacaram principalmente devido à facilidade de inspeção, visto que, em caso de defeitos, o material dielétrico sofreria um estilhaçamento que permite uma identificação visual de isolador defeituoso de modo muito

mais fácil, justificando seu uso até a atualidade em substituição aos isoladores de vidro comum. No entanto, com o desenvolvimento de novos materiais, os isoladores poliméricos começaram a ser utilizados comercialmente a partir da década de 1980 na América do Norte, substituindo gradualmente os isoladores de porcelana e vidro em várias aplicações (GUBANSKI, DERNFALK, *et al.*, 2007; GORUR, CHERNEY e BURNHAM, 1999).

Além de prover a separação elétrica de condutores com potenciais diferentes, outra função muito importante dos isoladores é a sustentação dos condutores. Tendo em vista essa função, os isoladores de porcelana e de vidro mais utilizados são os isoladores de suspensão tipo disco. Esse tipo de isolador é empregado na forma de cadeias, em que cada unidade é mecanicamente conectada à outra através de ferragens terminais, como apresentado na Figura 2. O comprimento da cadeia e a suportabilidade individual de cada isolador à carga mecânica dependem da classe de tensão da linha de transmissão.

Figura 2 - Isoladores de vidro em linha de transmissão.




Fonte: (SEDIVER, 2020).

Apesar de possuírem diversas características desejáveis, tais quais: uma alta resistência à degradação natural; serem quimicamente inertes frente à maioria dos compostos químicos e possuírem elevada resistência ao calor gerado por arcos elétricos, os isoladores cerâmicos

possuem uma superfície altamente hidrofílica, de modo que a umidade proveniente de neblina, condensação ou chuva tende a formar uma camada condutiva sobre a superfície do isolador, intensificando a corrente de fuga de superfície entre as extremidades do isolador e favorecendo a ocorrência de *flashovers* (KIM e CHERNEY, 1992).

Os isoladores poliméricos, por sua vez, são constituídos de uma peça isolante contínua, sem ferragens intermediárias. Em geral, nas aplicações de alta e extra alta tensão, são compostos por uma haste de fibra de vidro reforçada com resina epóxi que é recoberta por material polimérico, conforme observado através da Figura 3. Ambos os materiais possuem alto desempenho como dielétrico, além disso, o revestimento de material polimérico protege o núcleo fibra de vidro contra intempéries e outros agentes degradantes.

Figura 3 - Partes constituintes de um isolador polimérico.



Fonte: (RODURFLEX, 2004 apud FERREIRA, 2007).


Diferentemente dos isoladores cerâmicos, os poliméricos possuem uma baixa energia de superfície, o que acarreta uma superfície isolante altamente hidrofóbica (GORUR, CHERNEY e BURNHAM, 1999). Desse modo, a umidade do ambiente forma pequenas gotas distribuídas sobre a superfície e afastadas umas das outras, dificultando a formação de uma corrente de fuga entre os terminais do isolador. Em contrapartida, também estão mais propensos à degradação por reações químicas, exposição a intempéries, bem como ao aquecimento proveniente de arcos elétricos (GORUR, CHERNEY e BURNHAM, 1999).

## 2.2 HIDROFOBICIDADE EM ISOLADORES

Devido à constante expansão dos sistemas de geração, transmissão e distribuição de energia elétrica, num esforço para acomodar a sempre crescente demanda em todo o mundo, é previsível que há grande probabilidade de haver também um maior número absoluto de interrupções no fornecimento de energia elétrica. Uma vez que, uma maior complexidade no sistema elétrico de potência, ocasionada pelo aumento no número de linhas de transmissão, distribuição e componentes do sistema em geral, levará a uma maior probabilidade de ocorrência de falhas que podem gerar uma interrupção (THOMAZINI, 2009). Nesse contexto, falhas nos isolamentos das linhas de transmissão ocasionadas pela perda da hidrofobicidade de superfície em isoladores poliméricos estão entre os fatores que podem causar a interrupção do fornecimento de energia e, portanto, é de grande importância que a manutenção e monitoramento dos isolamentos da linha sejam mantidos em ordem. O desempenho dos isoladores elétricos é de fundamental importância para a qualidade do serviço, segurança e confiabilidade do sistema elétrico de potência como um todo (GODOY, 2007; ALVES, 2018).

A hidrofobicidade, do grego *hýdrophóbos*, em que *hýdro* significa água, e *phóbos* é a aversão ou repelência a algo (LIDDELL, SCOTT, *et al.*, 1996). Segundo a norma IEC TS 62073:2016 Ed. 2.0 a hidrofobicidade é definida como o estado de uma superfície com uma baixa tensão superficial e que, portanto, é repelida ou repele a água. Enquanto a tensão superficial é definida como uma região de contato entre dois materiais diferentes, que possui espessura finita (geralmente menor que  $0,1 \mu\text{m}$ ) e na qual a composição e a energia variam continuamente (IEC, 2016). Assim, hidrofobicidade refere-se à propriedade de uma superfície repelir ou ser repelida pela água. Em geral, uma superfície é dita hidrofóbica quando seu ângulo estático de contato com a água  $\theta$  é  $> 90^\circ$  e dita hidrofílica quando  $\theta < 90^\circ$ , conforme observado através da Figura 4 que apresenta um ângulo inferior a  $90^\circ$  e, portanto, caracteriza uma superfície hidrofílica. (LAW, 2014).

Figura 4 - Ângulo de contato em superfícies para avaliação da hidrofobicidade.



Fonte: adaptado de (STRI, 1992).

Desse modo, uma superfície hidrofóbica, ao ser molhada, tende a formar gotas circulares ou semicirculares, também chamadas de gotas discretas, separadas umas das outras, enquanto uma superfície hidrofílica possibilita a interação entre a água e as moléculas que compõe esta superfície, permitindo que o líquido forme um filme sobre ela (THOMAZINI, 2009). Quando aplicado aos isoladores elétricos, esse conceito permite afirmar que: quando da perda da hidrofobicidade de superfície nos isoladores, é mais provável a formação de um caminho de baixa resistência que permitirá a presença de uma corrente de fuga mais intensa entre os terminais do isolador. Esse efeito pode ser agravado quando o isolador está instalado em locais com alto índice de poluição salina, visto que a umidade acumulada na superfície irá diluir os sais depositados sobre o isolador, formando uma solução iônica que possui baixíssima resistência à passagem de corrente elétrica, elevando a probabilidade de ocorrência de uma descarga disruptiva (*flashover*).

Para minimizar a ocorrência de tais descargas, algumas soluções comumente empregadas são a inspeção e lavagem periódica dos isoladores para remoção dos depósitos superficiais de poluição (ALVES, 2018). No entanto, os materiais poliméricos possuem uma susceptibilidade natural à degradação por irradiações ultravioleta e térmica, reduzindo sua hidrofobicidade de superfície (GORUR, CHERNEY e BURNHAM, 1999). Deste modo, é necessário que se identifique e se mantenha sob monitoramento o estado da hidrofobicidade de superfície dos isoladores em operação, facilitando o planejamento de manutenções preventivas e reduzindo a probabilidade de descargas disruptivas no sistema.

Nesse tópico, a avaliação e classificação da hidrofobicidade de superfície dos isoladores poliméricos, conforme estipulado pela norma IEC TS 62073:2016 Ed. 2.0, pode ser realizada através de métodos, a saber:

- Ângulo de Contato;
- Tensão Superficial;
- Pulverização.

Os três métodos possuem diferenças em relação à exatidão, simplicidade e aplicabilidade. O método de ângulo de contato requer que o isolador seja retirado de operação e avaliado em laboratório e, justamente por esse motivo, é mais objetivo e preciso na determinação da hidrofobicidade. Os métodos de tensão superficial e pulverização possibilitam a avaliação da hidrofobicidade com o isolador em campo e conectado à linha. Dentre esses, o método de pulverização é o mais simples e prático de ser executado, porém, possui uma maior

subjetividade nos resultados, inerente à experiência do avaliador que está conduzindo o experimento.


Justamente devido à possibilidade de execução em ambiente de campo com o isolador conectado à rede, juntamente com a sua simplicidade, o método de pulverização é explorado em diversas pesquisas dentro da área de hidrofobicidade de isoladores. A busca pela redução da subjetividade intrínseca do método é o principal estímulo às pesquisas.

A avaliação através do método de pulverização baseia-se no comportamento de uma superfície após a sua exposição uma tênue névoa de água por um curto período. Para realização do teste, é necessário apenas de um borrifador comum, capaz de produzir uma névoa fina de água destilada. Ainda de acordo com a norma IEC TS 62073:2016 Ed. 2.0, o ensaio deve ser realizado em uma área mínima de 50 cm<sup>2</sup> e inferior a 100 cm<sup>2</sup> e, caso esse requisito não possa ser cumprido, deve-se realizar observação no relatório de ensaio. Em sequência, procede-se à exposição da superfície à névoa por um período de 20 a 30 segundos, realizando a aplicação a uma distância de 25 cm, com uma variação permitida de 10 cm para mais ou para menos. A quantidade de água pulverizada nesse intervalo deve estar entre 10 e 30 ml e a avaliação da hidrofobicidade da superfície deve ocorrer em até 10 segundos após a finalização da exposição.

Para auxiliar na padronização da hidrofobicidade avaliada através do método de pulverização, o STRI definiu sete níveis discretos, ou classes, de hidrofobicidade (HC), conforme exposto na Figura 5, em que a superfície deve ser rotulada. O primeiro nível, denominado HC1 (*Hidrophobicity Class 1*), seria o nível de maior hidrofobicidade, sendo, portanto, o nível ideal para a superfície dos isoladores, pois permitiria a formação apenas de pequenas gotas separadas entre si. Conforme o HC da superfície aumenta, aumenta também a característica hidrofílica da superfície, e por consequência, a hidrofobicidade diminui. O último nível, HC7, não representado na Figura 5, caracteriza a superfície completamente hidrofílica e ocorre quando a superfície é inteiramente coberta por um filme de água.

Os critérios para classificação de acordo com o método proposto pelo STRI estão representados na Tabela 1

Figura 5 - Exemplos das classes de hidrofobicidade de HC1 a HC6.



Fonte: adaptado de (STRI, 1992).

Tabela 1 - Critérios para classificação da hidrofobicidade de superfície.

| HC | Descrição                                                                                                                                                                         |
|----|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | Apenas gotas discretas formadas. Suas formas, quando vistas perpendicularmente à superfície, são praticamente circulares.                                                         |
| 2  | Apenas gotas discretas formadas. Quando vistas perpendicularmente à superfície, possuem forma regular, mas não necessariamente circulares.                                        |
| 3  | Apenas gotas discretas formadas. Normalmente as gotas apresentam forma irregular.                                                                                                 |
| 4  | Ambas, gotas e trilhas molhadas por onde água escoou são observados. Áreas completamente molhadas $< 2 \text{ cm}^2$ . Juntas, as áreas molhadas cobrem $< 90\%$ da área testada. |
| 5  | Algumas áreas molhadas $> 2 \text{ cm}^2$ , que juntas cobrem $< 90\%$ da área testada.                                                                                           |
| 6  | Áreas molhadas cobrem $> 90\%$ da área testada. Pequenas áreas ou pontos não cobertos ainda são observados.                                                                       |
| 7  | Filme contínuo de água sobre toda a área testada.                                                                                                                                 |

Fonte: adaptado de (STRI, 1992).

## 2.3 PROCESSAMENTO DIGITAL DE IMAGENS

O campo de processamento digital de imagens refere-se ao processamento de imagens por um computador digital (GONZALEZ e WOOD, 2010), buscando um aperfeiçoamento em quesitos qualitativos, tais quais realces em regiões de interesse, correção de defeitos, ajustes de contraste ou ainda a extração e tratamento de características quantitativas, como a área de determinado objeto representado, a distância entre objetos, entre outros atributos. Ademais, não existe uma concordância sobre a fronteira entre a área de processamento de imagens e suas áreas correlatas, como a análise de imagens e a visão computacional, visto que os interesses e competências das três muitas vezes se sobrepõem.


De acordo com Gonzalez e Wood (2010), levando em consideração três tipos de processos computacionais, de nível baixo, médio e alto. Os processos de nível baixo envolvem operações primitivas, como o aguçamento e a filtragem de ruído em imagens, bem como o realce de contraste, este nível é caracterizado principalmente pelo fato de tanto a entrada como a saída do processo serem imagens. Já os processos de nível médio englobam as tarefas de segmentação, ou seja, separação de uma imagem em regiões que representam diferentes objetos, ou a separação entre objetos e o plano de fundo de uma imagem. Está incluso também nesse nível o processo de descrição dos objetos segmentados para reduzi-los a uma forma adequada para o processamento computacional ou à classificação dos objetos. Portanto, os processos de nível médio são caracterizados principalmente pelo fato de suas entradas serem imagens, mas suas saídas são atributos e características extraídas dessas imagens, tais quais: bordas; contornos e a identidade de objetos. Por fim, os processos de nível alto envolvem operações cujo objetivo é dar sentido ao conjunto de objetos e descritores proveniente do processamento no nível médio, realizando funções cognitivas normalmente associadas à visão (GONZALEZ e WOOD, 2010).

Deste modo, segundo a lógica determinada por Gonzalez e Wood (2010), os processos de nível baixo pertencem integralmente ao campo de processamento digital de imagens, juntamente com os procedimentos de nível médio. Já os processos que envolvem trazer sentido objetivo ao conteúdo processado, traçando um paralelo entre as características da imagem digital e o mundo real, fazem parte das áreas de análise de imagens digitais e visão computacional, a depender do nível de complexidade da análise. Por exemplo, a aquisição de uma imagem digital de uma área que contém um texto, sua filtragem para remoção de ruídos, correções de contraste e iluminação, aguçamento, seguindo para a extração dos caracteres

individuais, a descrição desses caracteres em um formato adequado para o processamento computacional e o reconhecimento desses caracteres fazem parte do campo de processamento digital de imagens. Enquanto a tarefa de dar sentido ao conteúdo extraído da imagem, ou seja, do conjunto de caracteres, é âmbito da análise de imagens ou ainda da visão computacional, a depender da complexidade desejada no resultado do processo (GONZALEZ e WOOD, 2010).

Conforme se pode observar na Figura 6, o campo de processamento digital de imagens engloba diversos subprocessos, podendo a saída destes tanto ser uma nova imagem como também atributos extraídos da imagem de entrada. Ainda na Figura 6, dentre os processos ilustrados, apenas os procedimentos que envolvem “Imagens Coloridas”, “Wavelets” e “Restauração de Imagens” não foram abordados neste trabalho. Todos os demais desempenham importante papel na metodologia desenvolvida.

Figura 6 - Panorama geral no processamento de digital de imagens.



Fonte: adaptado de (GONZALEZ e WOOD, 2010).

Ainda sob a ótica da Figura 6, autores como Esquef e Albuquerque (2003) agrupam as operações em etapas de aquisição e digitalização, pré-processamento, segmentação, pós-processamento, extração de atributos e classificação ou reconhecimento. Assim, as operações

de aquisição e digitalização expressas na Figura 6 estão agrupadas na primeira etapa, enquanto as operações intermediárias executadas antes da segmentação da imagem, tais quais a filtragem, realce, restauração, processamento em cores, *wavelet*, compressão e processamentos morfológicos fazem parte da etapa de pré-processamento. A segmentação constitui uma etapa por si só, enquanto no pós-processamento estão as operações de representação e descrição, podendo, no entanto, englobar também as operações morfológicas, caso seja necessária alguma adequação ao resultado da operação de segmentação, e na etapa final, as operações de reconhecimento de objetos (ESQUEF, ALBUQUERQUE e ALBUQUERQUE, 2003).

A etapa de aquisição de imagens é o procedimento inicial para qualquer tarefa de processamento digital de imagens, e envolve a formação ou captura da imagem através de dispositivo apropriado e posterior conversão para formato digital. No entanto, o processo de aquisição pode também ser tão simples quanto receber uma imagem que já está em formato digital e realizar o seu redimensionamento.

Nas operações que pertencem à etapa de pré-processamento, busca-se melhorar a qualidade da imagem sob a ótica do problema. Para tanto, são realizadas alterações nos atributos da imagem, tais quais ajustes no contraste, compressões, aplicações de filtros e alterações nos valores individuais de *pixels*.

A segmentação, detalhada em subseção seguinte, consiste em separar a imagem em regiões de interesse diferentes entre si, de modo que, quando uma determinada região ou conjunto de regiões é relevante para o problema abordado, a mesma é referida com “objeto”, enquanto as regiões que não possuem informações relevantes ao problema são denominadas “fundo”. Desta forma, a tarefa básica da segmentação é separar as regiões de objeto das regiões de fundo.

O pós-processamento, realizado logo após a segmentação, traz operações cujo objetivo é corrigir imperfeições no processo de segmentação, realçando as características relevantes dos objetos segmentados ou restaurando-as, caso tenham sido prejudicadas durante a segmentação. É também parte dessa etapa a extração das características dos objetos, tais quais: área das regiões, localização de centroides, dimensões dos objetos, bem como a rotulação da imagem através da atribuição de descritores, rótulos, que identificam cada região de forma individual.

Por fim, a etapa de reconhecimento e classificação utiliza os rótulos criados na etapa anterior para, através de determinado método de classificação, separar as regiões rotuladas em grupos que possuem características semelhantes entre si. O método de classificação a ser utilizado pode variar bastante a depender da natureza e características do problema abordado.


O realce de imagens busca formas de manipular os valores dos *pixels* da amostra, de forma que o resultado seja adequado para uma determinada aplicação. No caso do problema abordado neste trabalho, técnicas de realce são necessárias para destacar as gotas e regiões molhadas do fundo da imagem, uma vez que, devido à transparência da água, o contraste entre os objetos de interesse (áreas molhadas) e o fundo é muito baixo. Dentre as técnicas que fazem parte deste subprocesso, é possível citar a equalização de histograma, limitação de contraste ou ainda uma combinação de ambos (GONZALEZ e WOOD, 2010).

### 2.3.1 A IMAGEM DIGITAL

A imagem digital monocromática é definida como: uma função bidimensional  $f(x, y)$  contínua, na qual  $x$  e  $y$  são coordenadas espaciais e o valor de  $f$  em qualquer ponto  $(x, y)$  é proporcional à intensidade luminosa, também chamada de brilho ou tom de cinza, da imagem naquele ponto (JÄHNE, 1995; GONZALEZ e WOOD, 2010). Naturalmente, devido à incapacidade dos computadores digitais de representar grandezas contínuas, as imagens digitais são tratadas como um conjunto de pontos discretos, em que as coordenadas  $x$  e  $y$  são números inteiros.

Na Figura 7 é representada a estrutura matricial de uma imagem digital monocromática, na qual as linhas e colunas são denotadas pelos índices  $M$  e  $N$ , respectivamente, e a localização de um determinado pixel nessa matriz se denota por  $f(x, y)$ . O valor numérico em cada pixel é limitado entre 0 e 255 e representa o tom de cinza naquele ponto da imagem, sendo o valor 0 correspondente ao preto e o valor 255 ao branco.

Figura 7 - Representação simplificada de uma imagem digital.



Fonte: autoria própria.

De acordo com Gonzales e Wood (2010), a intensidade luminosa no ponto  $f(x, y)$  pode ser decomposta em: componente de iluminação,  $i(x, y)$ , associada à quantidade de luz incidente sobre o ponto  $(x, y)$ ; e a componente de reflectância,  $r(x, y)$ , associada à quantidade de luz refletida pelo ponto  $(x, y)$  (GONZALEZ e WOOD, 2010). O produto de  $i(x, y)$  e  $r(x, y)$ , conforme Equação 1, resulta em:

$$f(x, y) = i(x, y)r(x, y) \quad (1)$$

Em que  $0 < i(x, y) < \infty$  e  $0 < r(x, y) < 1$ , sendo  $i(x, y)$  dependente das características da fonte de iluminação, enquanto  $r(x, y)$  dependente das características das superfícies dos objetos. Sendo  $f(x, y)$  tipicamente limitada, conforme definido anteriormente na Figura 7, de tal modo que  $0 \leq f(x, y) \leq 255$ .

No que tange à representação de imagens coloridas, um pixel pode ser visto como um vetor de três posições, carregando consigo a intensidade das cores básicas: vermelho; verde e azul (RGB, do inglês *Red*, *Green* e *Blue*). Portanto, a imagem final é uma sobreposição de três imagens monocromáticas, que representam a intensidade luminosa de cada cor do sistema RGB num determinado ponto  $(x, y)$ . Essa relação é demonstrada na Equação 2, sendo agora  $f(x, y)$  uma imagem colorida e  $f_i(x, y)$ , para  $i = R, G$ , ou  $B$ , as matrizes monocromáticas de intensidade para cada canal RGB no intervalo de  $0 \leq f_i(x, y) \leq 255$  de um determinado pixel no ponto  $(x, y)$ .

$$f(x, y) = f_R(x, y) + f_G(x, y) + f_B(x, y) \quad (2)$$

Na Figura 8 pode-se perceber o modo como cada imagem monocromática é utilizada na composição de uma imagem colorida, onde os pontos na cor vermelha da imagem em composição RGB são representados na imagem monocromática correspondente ao canal R por valores mais próximos de 255, e, portanto, mais claros. O amarelo da flor, por ser uma combinação das cores vermelha e verde, possui valores mais altos no canal R e G, mas possui valores muito próximos de 0 no canal B, representados pelos tons mais.

Figura 8 - Representação de imagem colorida e respectivos canais de cores RGB.



Fonte: autoria própria.

### 2.3.2 SEGMENTAÇÃO DE IMAGENS

A segmentação de imagens, conforme dito anteriormente, busca a separação das regiões que compõe a imagem em grupos que possuem características semelhantes. Diversos métodos de segmentação estão disponíveis atualmente, sendo que cada técnica é escolhida de acordo com o problema a ser resolvido. A segmentação pode ser baseada nas descontinuidades ou nas similaridades dos diferentes aspectos da imagem, em limites ou bordas e em áreas ou regiões (ALVES, 2018). Os métodos que envolvem a limiarização ou binarização da imagem, ou ainda a detecção de bordas, são amplamente empregados.

Nesse contexto, o processo de limiarização busca representar uma imagem monocromática  $f(x,y)$ , em apenas dois tons de cinza, usualmente o branco e o preto. Tipicamente, busca-se agrupar regiões cujos tons de cinza são semelhantes, mediante a definição de um limiar  $T$ , que separa essas regiões em grupos de objeto e fundo. Assim, uma imagem  $f(x,y)$ , quando submetida a um limiar  $T$ , produza uma imagem  $g(x,y)$ , conforme Equação 3, tal que:

$$g(x,y) = \begin{cases} 1, & \text{se } f(x,y) > T \\ 0, & \text{se } f(x,y) \leq T \end{cases} \quad (3)$$

Os algoritmos de limiarização são diversos, porém, o algoritmo de limiar automático de Otsu (1979), é amplamente citado. Neste algoritmo se propõe um método não paramétrico e não supervisionado na seleção de um limiar para segmentação de imagens. Um limiar ótimo é selecionado quando atende ao critério de maximizar a separabilidade, ou a variância, entre as classes resultantes em níveis de cinza (OTSU, 1979). A ideia básica é que as classes, nesse caso objeto e fundo, com limiares bem estabelecidos devem ser distintas em relação aos valores de intensidade de seus pixels e, portanto, um limiar  $T$  que oferece a melhor separação entre essas classes seria o limiar ótimo. Além do componente ótimo, o método de Otsu tem a vantagem de se basear inteiramente em cálculos realizados no histograma da imagem que é um atributo que pode ser obtido facilmente (GONZALEZ e WOOD, 2010).

No entanto, em casos desafiadores quando há a presença de gradientes de iluminação, mesmo um método de limiar ótimo como apresentado por Otsu (1979) não é suficiente para gerar resultados satisfatórios na limiarização dessas imagens. Para tanto, Bradley e Roth propuseram em 2007 um método para limiarização local de imagens com base na imagem integral.

A imagem integral é definida como a resultante da soma de um pixel  $f(i, j)$ , de uma imagem  $f(x, y)$ , com o valor da imagem integral à esquerda da posição  $(x, y)$  atual, bem como do valor acima, subtraído do valor da imagem integral na coluna e linha anteriores (diagonal superior esquerda), conforme descrito na Equação 4 abaixo e demonstrado através da Figura 9 (a) e (b) (BRADLEY e ROTH, 2007).

$$I(x, y) = f(x, y) + I(x - 1, y) + I(x, y - 1) - I(x - 1, y - 1), \quad (4)$$

sendo  $I(x, y)$  a imagem integral.

Figura 9 - Valores típicos de uma imagem (a) e sua respectiva imagem integral (b).

|   |   |   |   |   |
|---|---|---|---|---|
|   | 0 | 1 |   |   |
| 0 | 4 | 1 | 2 | 2 |
| 1 | 0 | 4 | 1 | 3 |
|   | 3 | 1 | 0 | 4 |
|   | 2 | 1 | 3 | 2 |

(a)


|   |   |    |    |    |
|---|---|----|----|----|
|   | 0 | 1  |    |    |
| 0 | 4 | 5  | 7  | 9  |
| 1 | 4 | 9  | 12 | 17 |
|   | 7 | 13 | 16 | 25 |
|   | 9 | 16 | 22 | 33 |

(b)

Fonte: adaptado de (BRADLEY e ROTH, 2007).

Assim,  $I(x, y)$  pode ser utilizada para acelerar o cálculo da média de uma janela de tamanho  $s \times s$  pixels, centrada em cada pixel de  $f(x, y)$ , apenas através de operações de soma e subtração. Desse modo, caso o valor de um pixel  $f(i, j)$  seja menor que uma determinada porcentagem  $t$ , denominada sensibilidade, da média da janela  $s \times s$  centrada nesse pixel, lhe será atribuído valor 0 e, caso contrário, o valor 255. Um exemplo comparativo considerando uma imagem contaminada por gradiente de iluminação (a), a aplicação do limiar automático de Otsu (b) e o resultado do método proposto por Bradley e Roth (2007) (c) pode ser visto através da Figura 10.

Figura 10 - Comparação entre diferentes métodos de limiarização.



Fonte: adaptado de (BRADLEY e ROTH, 2007).

Nos casos em que a segmentação deve ser executada em larga escala, torna-se necessário o controle do ambiente de captura, garantindo que o contraste se mantenha uniforme de uma imagem para outra (ALVES, 2018). Em contrapartida, imagens capturadas em ambientes externos são de difícil segmentação em larga escala, pois, em geral, apresentam variações em contraste que são particulares de cada imagem e das condições de iluminação do ambiente em que foram capturadas. Desse modo, métodos capazes de compensar automaticamente essas variações de contraste e uniformizar a iluminação das imagens de modo a facilitar a segmentação automática em larga escala são desejados.

### 2.3.3 PROCESSAMENTO MORFOLÓGICO


O processamento morfológico consiste na aplicação dos conceitos de morfologia matemática no âmbito das imagens digitais. Desse modo, são aplicadas operações morfológicas básicas para investigar a interação entre a imagem e um dado elemento estruturante, baseando-se, para tanto, na premissa de que uma imagem consiste em um conjunto de pequenas estruturas

(*pixels*) que podem ser processadas por operações como: união; intersecção; diferença; complemento e translação (TYAGI, 2018).

Em geral, a saída do processamento morfológico de uma imagem pode tanto ser outra imagem, como também um atributo ou característica da amostra de entrada, a depender da operação realizada. Tomando como exemplo o processamento através de uma operação de abertura, a saída do processo será outra imagem, enquanto, ao se realizar a aplicação da operação de transformada *hit-or-miss*, a saída será um conjunto de pontos, muito embora ambos os processos sejam do tipo morfológico (GONZALEZ e WOOD, 2010).

A base do processamento morfológico de imagens é fundamentada em duas operações primitivas: a erosão e a dilatação. Em suma, a erosão permite que se separem regiões próximas mediante o uso de um elemento estruturante, conforme visto através da Figura 11 (a) onde é possível visualizar o efeito de elementos estruturantes de dimensões diferentes, enquanto a dilatação permite a fusão dessas regiões, conforme Figura 11 (b). Quão próximas essas regiões devem estar para serem fundidas (ou separadas) depende da escolha do elemento estruturante, seu tamanho em *pixels* e sua forma (GONZALEZ e WOOD, 2010).

Figura 11 - Exemplos de operações de erosão e dilatação.



Fonte: adaptado de (GONZALEZ e WOOD, 2010).

Os processos de abertura e fechamento são derivados da dilatação e erosão. A operação de abertura é a combinação de uma erosão seguida de uma dilatação, que tende a remover pequenas regiões menores que o elemento estruturante, enquanto preserva a forma e as bordas de regiões maiores. Em contrapartida, a operação de fechamento é definida como a execução de uma dilatação seguida de uma erosão e tem como objetivo o preenchimento de buracos e

falhas, menores que o elemento estruturante, no interior de regiões ou ainda a fusão de regiões próximas, enquanto mantém preservado o contorno das demais regiões. Processamentos mais complexos, como a reconstrução morfológica, a dilatação e a erosão geodésicas tem como base a aplicação dos processos de dilatação, erosão, abertura e fechamento, podendo envolver mais de uma imagem e mais de um elemento estruturante diferente (GONZALEZ e WOOD, 2010).

#### 2.3.4 EQUALIZAÇÃO ADAPTATIVA DE HISTOGRAMA LIMITADA POR CONTRASTE

Imagens capturadas sob iluminação não uniforme e, principalmente, imagens cujo objeto de interesse são gotas de água e regiões molhadas, possuem contraste bastante limitado, devido à transparência da água, fazendo com que os objetos de interesse e o fundo possuam *pixels* com valores bastante próximos uns dos outros. Para mitigar tal efeito, é possível utilizar técnicas que buscam aumentar o contraste das imagens. Nesse contexto, a Equalização Adaptativa de Histograma Limitada por Contraste (CLAHE, do inglês *Contrast-Limited Adaptive Histogram Equalization*), cujo método foi inicialmente proposto por Zuiderveld (1994), proporciona resultados satisfatórios no aguçamento do contraste de imagens capturadas sob baixa iluminação, iluminação desequilibrada, ou com baixo contraste em geral (ZUIDERVELD, 1994).

Basicamente, o método aumenta a distância entre os tons de cinza dos *pixels* da imagem realizando uma equalização de histograma em subdivisões da imagem, ao invés de realizar uma equalização do histograma na imagem inteira. Ademais, o método calcula uma função de transformação do contraste individual para cada subdivisão, o que permite uma otimização do contraste local da imagem.

Uma imagem cujo contraste é baixo tem por característica a concentração dos seus níveis de cinza em numa porção central do histograma. Neste cenário, a imagem possui uma aparência cinza, sem brilho e desbotada (GONZALEZ e WOOD, 2010). Em uma equalização de histograma convencional, os níveis de cinza são redistribuídos de forma uniforme ao longo de todo o espectro, cobrindo a faixa entre 0 e 255. Apesar desse método auxiliar na redistribuição dos tons de cinza de forma uniforme, fazendo com que cubram uma maior faixa de valores, essa abordagem pode resultar numa imagem pior que a original, visto que picos no histograma original podem ser causados por ruído, por exemplo, e o processo de equalização ampliaria a visibilidade desse ruído (ZUIDERVELD, 1994).


Como os olhos humanos adaptam-se ao contexto local de imagens para avaliar seu conteúdo, faz sentido otimizar o contraste das imagens de forma local (PIZER, AMBURN, et

*al.*, 1987). Desse modo, é possível utilizar a equalização do histograma em subdivisões da imagem, de modo localizado. Para tanto, a imagem é subdividida em uma grade de regiões contextuais quadradas, em que o número ótimo de regiões depende do tipo de imagem de entrada. Normalmente, a divisão da imagem em  $8 \times 8$  regiões contextuais retorna bons resultados. Isso implica que uma imagem contendo  $256 \times 256$  *pixels*, por exemplo, seja dividida em 64 regiões contextuais de tamanho  $32 \times 32$  *pixels*. Na sequência, o histograma é calculado para cada uma dessas regiões e equalizado individualmente. Para evitar que as fronteiras das regiões fiquem evidentes durante o processo de equalização, é utilizada uma interpolação bilinear (ZUIDERVELD, 1994).

Apesar de produzir bons resultados, realizando a apresentação das informações presentes na imagem de forma satisfatória, a equalização do histograma de forma local possui o efeito de evidenciar bastante o ruído de fundo, quando presente. Esse problema pode ser reduzido ao limitar o ganho de contraste produzido pela equalização de histograma, principalmente em regiões homogêneas. Esse limite é definido como fator de contraste, que é um múltiplo do conteúdo médio do histograma e, na prática, permite apenas que um determinado número de *pixels* seja associado a cada tom de cinza do histograma local. Caso o número de *pixels* de um determinado tom seja superior ao fator de contraste, os *pixels* em excesso são redistribuídos igualmente ao longo do restante do histograma (ZUIDERVELD, 1994).

Na Figura 12 é ilustrada a comparação entre uma amostra original de baixo contraste (a), o resultado da aplicação da equalização de histograma global (b) e o resultado após a aplicação da equalização de histograma CLAHE (c). Percebe-se, portanto, que apesar de a equalização global de histograma apresentar um ganho significativo de contraste, muitos pontos da imagem apresentam-se saturados no valor máximo da escala e muito do ruído de fundo foi amplificado. Já na amostra (c) é possível perceber que os tons de cinza foram distribuídos de forma mais equilibrada, proporcionando um ganho uniforme no contraste da imagem, sem amplificação do ruído de fundo ou a saturação de regiões.

Figura 12 - Comparação entre equalização de histograma global e CLAHE.



Fonte: adaptado de (ZUIDERVELD, 1994).

### 2.3.5 CORREÇÃO DE ILUMINAÇÃO EM IMAGENS

Um gradiente de iluminação ocorre quando uma cena é iluminada de modo desigual. Desta forma, é necessária a correção deste efeito, pois operações em imagens em escala de cinza e técnicas de binarização por limiar único não podem ser aplicadas em imagens com iluminação não-uniforme (THOMAZINI, 2009). Uma solução inicial para o problema seria otimizar o sistema de iluminação no momento da captura das imagens, para compensar o desequilíbrio na iluminação ambiente. No entanto, em muitos casos não se tem o controle da iluminação, seja devido ao fato de as imagens já terem sido capturadas previamente, seja devido à impossibilidade de se estabelecer um sistema de iluminação uniforme no momento da captura, como é o caso de imagens capturadas em ambientes abertos.

Portanto, se faz necessária a utilização de operações capazes de equilibrar a iluminação em imagens geradas sob condições de luz desequilibrada para, só então, segmentar essas imagens. Nesse quesito, é possível utilizar o balanceamento do brilho para tentar mitigar os efeitos da iluminação não uniforme a que imagens capturadas em ambientes abertos estão sujeitas. O algoritmo para realização desta operação é apresentado no trabalho de Chen e outros (2012) e pode ser descrito através da Equação 5 a seguir:

$$f'(i,j) = f(i,j) \times \frac{\left(\frac{W_x(max)}{W_x(i)}\right) + \left(\frac{W_y(max)}{W_y(j)}\right)}{2}, \quad (5)$$

em que  $f(i,j)$  é uma imagem na forma matricial de dimensão  $M \times N$ ,  $f'(i,j)$  é a imagem com brilho balanceado,  $W_x(i)$  é o nível de cinza médio ao longo da  $i$ -ésima linha,  $W_y(j)$  é o nível

de cinza médio ao longo da  $j$ -ésima coluna,  $W_x(max)$  e  $W_y(max)$  são os valores máximos de  $W_x(i)$  e  $W_y(j)$ , respectivamente.

Ademais, conforme proposto por Obdržálek e Matas em 2003 e por Chen e Kuo em 2008 e posteriormente implementado com sucesso por Chen *et al.* (2013), a transformada discreta do cosseno (TDC), que é largamente utilizada para a compressão de imagens e é a base do formato “*jpg*”, pode ser utilizada na reconstrução do fundo de uma imagem, ou para estimar o gradiente de iluminação, quando a sua frequência espacial é muito menor que a dos objetos (OBDRZÁLEK e MATAS, 2003; CHEN e KUO, 2008; CHEN, CHIEN e NGUYEN, 2013). A TDC de uma imagem  $f(i, j)$  de dimensões  $M \times N$  é definida através das Equações 6 a 8 como:

$$D(x, y) = C(x)C(y) \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} f(i, j) \cos \left[ \frac{(2i+1)x\pi}{2M} \right] \cos \left[ \frac{(2j+1)y\pi}{2N} \right] \quad (6)$$

$$x = 0, 1, \dots, M-1; y = 0, 1, \dots, N-1$$

Ao passo que a transformada inversa é dada por:

$$f(i, j) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} C(x)C(y) D(x, y) \cos \left[ \frac{(2i+1)x\pi}{2M} \right] \cos \left[ \frac{(2j+1)y\pi}{2N} \right] \quad (7)$$

$$i = 0, 1, \dots, M-1; j = 0, 1, \dots, N-1$$

Onde  $C(i)$  e  $C(j)$  são os coeficientes da TDC, dados por:

$$C(x) = \begin{cases} \frac{1}{\sqrt{M}}, & \text{para } x = 0 \\ \sqrt{\frac{2}{M}}, & \text{para } x \neq 0 \end{cases} \quad C(y) = \begin{cases} \frac{1}{\sqrt{N}}, & \text{para } y = 0 \\ \sqrt{\frac{2}{N}}, & \text{para } y \neq 0 \end{cases} \quad (8)$$

## 2.4 TRANSFORMADA DE FOURIER

O estudo de sinais e sistemas usando representações senoidais é denominado Análise de Fourier em homenagem a Joseph Fourier (1768-1830) por ter desenvolvido a teoria por trás das ferramentas matemáticas utilizadas. Desde então, os métodos de Fourier espalharam-se além

do âmbito de sinais e sistemas, sendo utilizados em todos os ramos da engenharia e ciências (HAYKIN e VAN VEEN, 2003). Uma implementação de um dos métodos de Fourier, a Transformada Rápida de Fourier (TRF ou FFT, do inglês *Fast Fourier Transform*), pode ser dita como o mais importante algoritmo numérico da história recente, bem como a transformada discreta mais importante (STRANG, 1994).

Em suma, a Transformada de Fourier (TF) de um sinal contínuo e não-periódico  $f(t)$  é dada conforme Equação 9 abaixo:

$$F\{f(t)\} = \int_{-\infty}^{\infty} f(t)e^{-j2\pi\mu t} dt, \quad (9)$$

sendo  $j = \sqrt{-1}$  e dado que  $t$  e  $\mu$  são variáveis contínuas, como  $t$  é eliminado na integração do sinal sob toda sua extensão, então  $F\{f(t)\}$  é função apenas de  $\mu$ , podendo ser denotada diretamente com  $F(\mu)$ . A variável  $\mu$  é a variável relacionada à frequência e, sendo  $t$  a representação de qualquer variável contínua, as unidades de  $\mu$  dependem das unidades de  $t$ . Considerando, por exemplo, que  $t$  represente o tempo em segundos, então as unidades de  $\mu$  serão ciclos/s (Hz), caso  $t$  represente uma distância em metros, então as unidades de  $\mu$  serão dadas em ciclos/m (GONZALEZ e WOOD, 2010).

Apesar da possibilidade de a TF representar sinais contínuos no tempo como uma superposição de senoides complexas, há de se notar que senoides contínuas com diferentes frequências caracterizam senoides distintas, por isso, a TF envolve a integração em um contínuo de frequências que vai de  $-\infty$  a  $\infty$ . Logo, através da aplicação dessa transformada, não é possível analisar separadamente diferentes trechos de um sinal, visto que os coeficientes da transformada precisam ser definidos em todo o contínuo do espectro de frequência do sinal.

Do ponto de vista computacional, o fato de a TF ser uma transformada de um sinal (ou sequência) de comprimento infinito, além de ser uma função de uma variável contínua ( $\mu$ ) traz grandes problemas à sua implementação, visto que não é possível avaliar computacionalmente um número infinito de somas em incontáveis infinitas frequências. Portanto, faz-se necessário uma aproximação da TF que seja numericamente computável para que a TF possa ser utilizada em análises computacionais.

Nesse contexto, a Transformada de Discreta de Fourier (TDF) é utilizada para representar um sinal discreto e não-periódico como uma superposição de senoides complexas. Em essência, a TDF é uma forma amostrada da Transformada de Fourier, que, como dito, é uma função contínua no tempo. Portanto, a TDF não contém todas as frequências que compõe

o sinal primitivo no domínio do tempo, mas permite conter um número de amostras grande o suficiente para descrever o sinal perfeitamente.

A TDF transforma um conjunto de números  $\{f_n\}$ , que consiste em  $M$  amostras de um sinal contínuo  $f(t)$ , em outro conjunto,  $\{F_m\}$ , de  $M$  valores discretos complexos segundo a Equação 10, expressa abaixo:

$$\{F_m\} = \sum_{n=0}^{M-1} f_n e^{\frac{-j2\pi mn}{M}}, m = 0, 1, \dots, M-1. \quad (10)$$

Essa transformada possui uma propriedade de inversão que define o inverso da transformada, impossibilitando também que duas sequências distintas possuam uma mesma TDF, garantindo uma relação biunívoca entre os conjuntos  $\{f_n\}$  e  $\{F_m\}$ .

De modo similar, a TDF pode também ser aplicada a conjuntos de números organizados em duas dimensões, tais quais matrizes, ou imagens. Neste caso, sendo o conjunto  $\{f(x, y)\}$  uma imagem composta por  $M \times N$  pixels, a sua transformada discreta de Fourier  $\{F(u, v)\}$ , pode ser descrita pela Equação 11.

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (11)$$

## 2.5 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) têm origem no desejo do ser humano de mimetizar o funcionamento do cérebro em uma máquina, visto que o órgão biológico processa informação de uma forma completamente diferente de um computador digital. Dessa forma, enquanto processador de informação, o cérebro é capaz de realizar o reconhecimento de padrões, percepção, controle motor, entre outras tarefas através de processos não-lineares, complexos e paralelos, feitos sem iguais quando comparados às realizações de um computador digital convencional.

Em paralelo, as RNA buscam reproduzir a flexibilidade e plasticidade de processamento presente no cérebro através da aplicação de algoritmos implementados através de componentes eletrônicos ou simulados por programação em ambiente de computação digital. Assim, segundo

Haykin (2001, 2ª Ed., p. 28), uma rede neural pode ser vista como uma máquina adaptativa e formalmente definida como:

“... um processador maciçamente paralelamente distribuído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”

As unidades de processamento simples definidas acima, chamadas de neurônios ou nodos, são dispostas em uma ou mais camadas e interligadas por conexões unidirecionais, chamadas sinapses, que carregam consigo a força, ou peso, da conexão entre os neurônios. Esse arranjo permite agora que o modelo simule o comportamento não-linear e paralelo visto no cérebro.

Dentre as principais características inerentes às redes neurais, está a sua capacidade de adequar-se a novas situações. Para tanto, é necessária uma etapa de treinamento, na qual a rede é exposta ao conhecimento do fenômeno ou problema através de exemplos e os seus pesos sinápticos são ajustados de acordo com um determinado algoritmo de aprendizagem. Posteriormente, essa etapa resulta na capacidade de generalização da classificação, ou seja, quando a rede aplica com sucesso o conhecimento adquirido no treinamento à classificação de padrões não apresentados naquela etapa.

Dessa forma, fica evidente que a capacidade de classificação ou processamento de uma rede está intimamente ligada à sua etapa de treinamento ou aprendizagem. Neste quesito, o treinamento da rede pode ser realizado através de algoritmos que aplicam duas estratégias principais: o aprendizado supervisionado ou o não supervisionado. O aprendizado supervisionado envolve a modificação dos pesos sinápticos da rede pela aplicação de um conjunto de dados de treinamento (composto por entradas e suas respectivas saídas desejadas). Já no aprendizado não supervisionado, não se dispõe de uma saída desejada e a própria rede irá se ajustar as regularidades estatísticas dos dados de entrada, desenvolvendo a capacidade de formar representações internas para codificar as características da entrada e, desta maneira, de criar automaticamente as classes de saída (HAYKIN, 2001).


### 2.5.1 O NEURÔNIO ARTIFICIAL

O neurônio é a unidade de processamento de informação básica na composição da RNA. No diagrama apresentado na Figura 13 é demonstrado um modelo de neurônio utilizado como base nos projetos de redes neurais.

Nesse modelo, uma generalização do apresentado por McCulloch e Pitts (1943), podem ser identificados três elementos básicos que o caracterizam (MCCULLOCH e PITTS, 1943). A saber:

1. Um conjunto de sinapses ou conexões, descrevendo cada conexão através de um peso  $w_{kp}$ , que indica a relevância do sinal na entrada  $p$  do neurônio  $k$ .
2. Um somador para realizar a combinação linear dos sinais das entradas, ponderados pelos respectivos pesos de cada ligação.
3. Uma função de ativação  $\varphi(\cdot)$  para restringir a amplitude da saída do neurônio a um intervalo normalizado, tipicamente  $[0,1]$  ou  $[-1,1]$

Figura 13 - Modelo de um neurônio artificial.



Fonte: adaptado de (HAYKIN, 2001).


O modelo também inclui um termo chamado viés, *bias*, ou polarização, representado por  $b_k$ , que tem o efeito de aumentar ou diminuir a entrada da função, a depender do seu sinal. Em outras representações, o termo de polarização pode ser expresso como uma entrada  $x_0$  com valor fixo em +1 cujo peso sináptico  $w_{k0}$  da sua conexão ao neurônio tem valor igual a  $b_k$  e possui a mesma função de ajustar a entrada da função de ativação.

No tocante à função de ativação, existe uma gama variada de funções que podem ser utilizadas, sendo bastante difundidas atualmente no campo de aprendizado de máquina e redes

neurais as funções: sigmoide ou logística, tangente hiperbólica e a unidade linear retificada (ReLU, do inglês *Rectified Linear Unit*).

A função logística, conforme demonstrado na Figura 14, possui um gráfico em forma de “S” é definida como uma função crescente que equilibra um comportamento linear e não-linear. A saída produzida pela ativação dessa função irá produzir valores reais no intervalo entre 0 e 1 (SILVA, SPATTI, *et al.*, 2017; HAYKIN, 2001).


Figura 14 - Gráfico característico da função logística.



Fonte: autoria própria.

A função tangente hiperbólica é bastante similar à logística, como visto na Figura 15, possuindo forma semelhante e equilibrando um comportamento linear e não-linear. A diferença é na saída produzida por sua ativação, que possui valores no intervalo entre -1 e 1 (SILVA, SPATTI, *et al.*, 2017).

Figura 15 - Gráfico característico da função tangente hiperbólica.



Fonte: autoria própria.


Por fim, unidade linear retificada, muito embora tenha sido descrita pela primeira vez no âmbito das redes neurais por Fukushima ainda em 1969, apenas a partir de 2010 com o trabalho de Nair e Hinton (2010) despertou real interesse acadêmico. Desde então, essa função ganhou relevância rapidamente, de tal forma que se tornou a função de ativação mais utilizada em redes neurais do tipo convolucional e nas redes neurais profundas (*deep networks*).

Em suma, a ReLU é um cálculo simples que retorna o valor de entrada diretamente, caso esse seja positivo, ou retorna o valor zero, caso a entrada seja menor ou igual a zero. Pode ser definida através da Equação 12, ou expressa de forma reduzida através da Equação 13 e o seu gráfico característico pode ser observado através da Figura 16 (FUKUSHIMA, 1969; NAIR e HINTON, 2010).

$$\varphi(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (12)$$

$$\varphi(x) = \max(0, x) \quad (13)$$

Figura 16 - Gráfico característico da unidade linear retificada.



Fonte: autoria própria.


### 2.5.2 REDE PERCEPTRON DE CAMADA ÚNICA

A organização de neurônios em paralelo na forma de camadas, em que na primeira camada estão localizados os nós de fonte, onde a informação é alimentada, e essa se projeta sobre uma camada de neurônios de saída é denominada rede *Perceptron* de Camada Única (SLP - *Single Layer Perceptron*), ou apenas *Perceptron*, conforme representado na Figura 17. De início, a saída da rede é aleatória, visto que a mesma é iniciada com valores aleatórios para os pesos das conexões, mas após o ajuste gradual dos coeficientes através do processo de treinamento, a rede pode fornecer saídas de acordo com os dados do conjunto de treinamento.

Essa topologia de rede ganhou bastante interesse devido à sua simplicidade e sua habilidade de aprender a reconhecer padrões simples, podendo ser aplicada em tarefas de

classificação e problemas de filtragem linear (LIPPMANN, 1987). É perceptível que nesse tipo de arquitetura o número de saídas da rede sempre irá coincidir com o número de neurônios utilizados (SILVA, SPATTI, *et al.*, 2017).

Figura 17 - Representação de uma rede do tipo SLP.



Fonte: adaptado de (SILVA, SPATTI, *et al.*, 2017).


As aplicações dessa rede objetivam classificar corretamente um conjunto de estímulos  $x_1, x_2, \dots, x_n$  aplicados à entrada da rede em uma dentre  $m$  classes a depender dos valores de saída  $y_1, y_2, \dots, y_m$ . Os valores dos sinais de saída dependem da função de ativação utilizada. Para o caso de neurônios ativados por funções logísticas, por exemplo, a saída estará no intervalo  $[0,1]$ . Em geral, é estipulado durante o processo de treinamento que uma saída  $y_m$  mais próxima de 0 determina que o conjunto de informações  $x_1, x_2, \dots, x_n$  não pertence a uma determinada classe  $m$  associada àquele neurônio. Enquanto uma saída  $y_m$  mais próxima de 1 apresenta uma confiança da rede em o conjunto pertencer a uma determinada classe  $m$  associada àquela saída.

### 2.5.3 REDE PERCEPTRON DE MÚLTIPLAS CAMADAS

As redes do tipo Perceptron de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*) representam uma generalização do *perceptron* de camada única (HAYKIN, 2001). Nesse sentido, as redes MLP são alimentadas adiante (*feed-forward*), tal qual as SLP, mas possuem uma ou mais camadas de neurônios entre as camadas de entrada e saída. Essas camadas adicionais contêm neurônios ocultos que não estão diretamente conectados a ambas as camadas de entrada e saída (LIPPMANN, 1987). Conforme mostrado na Figura 18, a camada de entrada da rede é dotada apenas de unidades sensoriais, não realizando nenhum processamento na informação, mas transmitindo-a para a camada oculta subjacente através das

conexões sinápticas. Já as demais camadas são todas constituídas de neurônios e o sinal é propagado através da rede até que o sinal de saída seja computado.

Figura 18 - Arquitetura de uma rede MLP.



Fonte: (FERREIRA, 2011)

Através da adição de camadas ocultas é possível torná-la capaz de extrair estatísticas de ordem elevada e, dessa forma, resolver problemas complexos que envolvam classificação de padrões, síntese e reconhecimento de fala, reconhecimento de padrões visuais, entre uma infinidade de outras aplicações (HAYKIN, 2001). O treinamento empregado nessas redes, em geral, é do tipo supervisionado, sendo o algoritmo de retropropagação do erro baseado na regra de aprendizagem por correção de erro, comumente denominado *backpropagation*, amplamente utilizado.

Durante o processo de treinamento numa rede MLP, o conjunto de pesos das conexões sinápticas, inicialmente possuindo valores aleatórios, será ajustado por meio do algoritmo de treinamento de tal modo que, ao final do processo, o conjunto de pesos obtidos seja capaz de conferir à rede a habilidade de prover uma solução ao problema em que ela está sendo aplicada. Assim, a rede é apresentada a uma informação nos seus nós de entrada e a saída da rede é então confrontada com o resultado esperado. Note-se que é preciso conhecer previamente o fenômeno e ter posse do resultado esperado ao apresentar determinada informação à rede. Dessa maneira, através do cálculo do erro quadrático médio entre saída produzida pela rede e a desejada, é possível avaliar quão distante a saída está do resultado esperado e, a partir dessa informação, reajustar os pesos sinápticos da rede. O processo de propagar a informação do erro de forma

inversa (*backward*) ao sentido de propagação da informação na rede (*forward*) e reajustar os coeficientes baseado no valor do erro é tarefa do algoritmo de *backpropagation*.

Esse algoritmo, originalmente proposto por Rumelhart e McClelland (1986), possui diversas variações, geralmente no que tange ao cálculo do erro, como por exemplo o *quick-backpropagation*, *resilient backpropagation* e métodos baseados no algoritmo de Levenberg-Marquardt, que normalmente apresentam um melhor resultado de aprendizado e tempo reduzido de processamento (RUMELHART e MCCLELLAND, 1986; BAPTISTELLA, 2005). Enquanto o algoritmo tradicional de treinamento por *backpropagation* e suas variações utilizam o método do gradiente descendente como forma de aproximação do mínimo da função do erro, a implementação do *backpropagation* utilizando o algoritmo de Levenberg-Marquardt, primeiramente proposto por Levenberg (1944) e posteriormente redescoberto por Marquardt (1963), utiliza uma aproximação do erro através de uma modificação do método de Gauss-Newton (LEVENBERG, 1944; MARQUARDT, 1963).

As redes MLP, conforme relatado por Lippmann (1987), podem formar qualquer fronteira de decisão convexa no espaço abarcado pelas entradas da rede, incluindo polígonos convexos e regiões convexas não delimitadas, sendo capazes, inclusive, de formar regiões tão complexas quanto as formadas usando misturas de distribuições e classificadores do tipo *k*-ésimo vizinho mais próximo (*k-nearest neighbor*). Dessa forma, as redes MLP se apresentam como um método prático para resolver problemas de natureza complexa (LIPPMANN, 1987).

Este capítulo apresentou a fundamentação teórica sobre os isoladores elétricos de alta tensão, a avaliação da hidrofobicidade nesses isoladores, o processamento digital de imagens e redes neurais artificiais. O próximo capítulo traz o levantamento bibliográfico a respeito das publicações mais relevantes relacionadas ao tema proposto neste trabalho.

### 3 REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentado um levantamento bibliográfico de trabalhos que tratam do processamento digital de imagens e da classificação de níveis de hidrofobicidade de isoladores de alta tensão. Observou-se que a maioria das técnicas relatadas determinam o nível de hidrofobicidade utilizando PDI em imagens obtidas através do molhamento de isoladores elétricos. Sendo os métodos mais difundidos aqueles que utilizam morfologia matemática, e análise de características das gotas e regiões molhadas, como fator de forma, excentricidade, área de regiões, entre outros.

O trabalho de Berg e outros (2001) é considerado um dos pioneiros na utilização de PDI na classificação de hidrofobicidade de isolantes de borracha de silicone. A metodologia desenvolvida utiliza a análise de histogramas, a segmentação por convolução e o desvio padrão das diferenças entre os níveis de cinza das imagens para determinar uma função matemática capaz de indicar o nível de hidrofobicidade da superfície, fazendo uso, para tanto de técnicas como: entropia escalonada; fração de pequenas diferenças; entropia normalizada e médias das entropias normalizadas. As análises foram realizadas em 50 imagens de cada HC para uma superfície inclinada a  $10^\circ$  e  $35^\circ$ , sendo 25 amostras por HC para cada inclinação. Os padrões molhados foram produzidos através de um borrifador comum contendo água destilada e nenhum corante, mantendo a amostra sob iluminação artificial e uniforme. A função denominada média das entropias normalizadas foi capaz de correlacionar as classes de hidrofobicidade conforme determinado pelo STRI, além de apresentar a vantagem de fornecer uma estimativa numérica contínua da hidrofobicidade, ao invés de uma classe discreta. Este trabalho é especialmente relevante, pois foi capaz de demonstrar que técnicas de PDI podem ser utilizadas na classificação da hidrofobicidade de isoladores com sucesso.

Em 2005, Chen e outros realizaram a estimativa do grau de hidrofobicidade de isoladores poliméricos conectados a uma linha de transmissão de 110 kV. Para tanto, os isoladores foram molhados através de um aparato constituído de um borrifador contendo água

destilada sem adição de corante e um braço isolante que permite alcançar o isolador de forma segura. Na sequência, foram produzidas imagens digitais dos isoladores que foram analisadas através de quatro algoritmos, a saber: a média das entropias normalizadas otimizada; o método do ponto de semente; a análise da magnitude frequente e o fator de forma otimizado. Dentre esses, o método do fator de forma otimizado apresentou os melhores resultados para estimar a hidrofobicidade de isoladores poliméricos em serviço, com uma assertividade de aproximadamente 97% dentre 260 amostras analisadas.

Thomazini e outros (2008) propuseram um método de classificação da hidrofobicidade de isoladores poliméricos baseado em dimensão fractal. A classe de hidrofobicidade foi analisada e o tempo de processamento pelo método proposto foi avaliado tendo como objetivo a aplicação do método em dispositivos móveis. As imagens foram produzidas não a partir de um isolador, mas através de uma única superfície hidrofóbica, cuja característica de hidrofobicidade foi artificialmente alterada através da utilização de uma solução de água destilada e álcool isopropílico para produzir a névoa. A porcentagem por volume de álcool na solução variou de 0 a 100% e, desse modo, foi possível reproduzir o comportamento de superfícies das classes HC1 até a HC7.

Na sequência, foram medidos os ângulos de contato das gotas e as texturas foram utilizadas como padrões para os cálculos da dimensão fractal. Para evitar o gradiente de iluminação das imagens fotografadas em condições naturais, foram testados diferentes processos para o equilíbrio da iluminação como a equalização de histograma, filtros *White Top-Hat*, uma combinação de ambos e a detecção de bordas pelo operador de Sobel. Através da dimensão fractal, foi possível determinar uma função matemática capaz de classificar a hidrofobicidade de superfícies poliméricas através da análise da textura de imagens digitais com uma margem de erro inferior a 3% (THOMAZINI, GELFUSO e ALTAFIM, 2008).

Ademais, este trabalho é especialmente relevante pois propõe a utilização da solução de álcool isopropílico em água como forma de alterar artificialmente e de forma prática a hidrofobicidade da superfície, permitindo a criação de bases de dados contendo várias imagens a partir de uma única superfície aspergida repetidamente com diferentes concentrações da solução (THOMAZINI, GELFUSO e ALTAFIM, 2008).

Posteriormente, em 2009, Thomazini desenvolveu uma nova metodologia, também baseada em PDI, para a classificação da hidrofobicidade em isoladores poliméricos. Neste trabalho, a hidrofobicidade foi determinada utilizando a análise da textura de imagens obtidas para materiais de isoladores poliméricos. Essas análises foram avaliadas com base na morfologia matemática, para quantificar as formas presentes nas imagens, dimensão fractal,

entropia, energia, variância e homogeneidade. Assim como em Thomazini e outros (2008), também foi utilizada uma única superfície borrifada com uma solução de álcool isopropílico em água para alterar artificialmente o comportamento hidrofóbico da superfície, variando-se o percentual volumétrico de álcool na solução. Novamente foram utilizadas técnicas de correção de iluminação, como equalização de histograma e/ou aplicação de filtro do tipo *White Top-Hat*.

Na classificação das texturas das imagens através do uso de descritores de textura, os valores obtidos com a entropia apresentaram menor dispersão dentre os resultados, além de baixo tempo de processamento, se apresentando como uma metodologia apropriada para a classificação da hidrofobicidade. A partir dos resultados, foi possível obter uma relação matemática entre as ferramentas aplicadas e as imagens, permitindo definir a classe de hidrofobicidade. No mais, o tempo de processamento das técnicas propostas também foi avaliado, visando a aplicação em dispositivos móveis e foi elaborado um aplicativo embarcado em um *smartphone* para analisar uma imagem em campo de um isolador, mostrando ao operador o valor da classificação da hidrofobicidade em aproximadamente um minuto (THOMAZINI, 2009).

Liang e outros propuseram, em 2012, um algoritmo de segmentação para amostras de hidrofobicidade de superfície de isoladores baseado no espaço de cores HSI (Matiz, Saturação e Intensidade, do inglês *Hue, Saturation e Intensity*) e na transformada *watershed*. As imagens de hidrofobicidade de isoladores no espaço HSI foram decompostas e as gotas de água puderam ser segmentadas em relação ao fundo utilizando a informação do canal de saturação. A transformada *watershed* foi utilizada para reduzir o efeito de pontos de luz de alto brilho refletidos na superfície das gotas. Não foram utilizados métodos de classificação para avaliar o estado da hidrofobicidade de superfície e o método mostrou-se eficaz apenas na segmentação de gotas com formato circular ou elíptico, não apresentando bons resultados na segmentação de áreas molhadas com bordas sinuosas.

Em 2013, Khalayli e outros desenvolveram um estudo que utilizou PDI para classificar a hidrofobicidade de superfície em amostras revestidas de borracha de silicone RTV (do inglês *Room Temperature Vulcanizing*). Características de textura das imagens foram extraídas via matriz de co-ocorrência de bordas e a hidrofobicidade da superfície foi classificada em três níveis: bom; razoável e ruim. Para tal, foi utilizado um classificador polinomial que, dentro de um espaço amostral de 350 imagens, obteve uma taxa de acerto superior a 97%. Apesar de não realizara classificação nos níveis recomendados pelo STRI, os autores agruparam os níveis HC1 e HC2 na classe “bom”, e de modo similar, as classes HC3 e HC4 foram agrupadas no nível “razoável” e as classes HC5 e HC6 no nível “ruim”. Esse fato auxilia ao traçar um paralelo

entre as classes e a condição de operação do isolamento de uma forma que pode ser facilmente compreendida por um inspetor ou operador.

Jarrar *et al.* (2014) buscaram desenvolver um sistema automático para classificar e avaliar a condição da borracha de silicone em isoladores usando técnicas de PDI e reconhecimento de padrões. Para tal, técnicas como as transformadas discreta do cosseno, *wavelet* e *contourlet*, além da matriz de co-ocorrência dos níveis de cinza foram utilizadas para extrair características estatísticas e informações de textura das imagens. Além disso, a regressão *stepwise* foi aplicada para selecionar e reduzir a dimensão dos vetores de características produzidas. Na sequência, vários classificadores foram examinados, incluindo k-ésimo vizinho próximo, rede neural artificial e classificadores lineares. A base de dados utilizada consistia em 358 imagens produzidas a partir de uma única amostra de superfície recoberta por silicone RTV e borrifada com uma solução de água destilada, álcool etílico e álcool metílico para alterar artificialmente o comportamento hidrofóbico da superfície. A base possuía ao menos 40 imagens para cada um dos sete níveis de hidrofobicidade determinados segundo o STRI. Uma taxa de acerto de 96,5% foi alcançada utilizando características selecionadas através de regressão *stepwise* e classificadas a partir de uma rede neural artificial do tipo MLP com 15 neurônios em uma camada oculta. Este trabalho é bem abrangente, buscando avaliar o desempenho de classificadores diferentes explorando diversas técnicas para extração de características. Dessa forma, os autores tornaram evidente que técnicas baseadas em inteligência artificial e redes neurais tem um melhor desempenho no tratamento de problemas dessa natureza quando comparados a classificadores mais simples.

Em 2015 Dong *et al.* desenvolveram um sistema embarcado para avaliação da hidrofobicidade de materiais isolantes. O revestimento de silicone de isoladores poliméricos de alta tensão que estavam em operação e se encontravam em diversas condições de hidrofobicidade foi recortado na forma de placas circulares e utilizados na produção de um banco de dados contendo 140 imagens. Levando em consideração as condições complexas a que a fotografia de isoladores em operação pode estar submetida, foi proposto um método de segmentação, denominado método de segmentação por limiar adaptativo baseado no operador de Canny (do inglês *Canny Operator Adaptive Threshold Segmentation*, COATS) para compensar condições de iluminação adversas e não-uniformes, superfícies irregulares e ângulo de captura variável. Após a segmentação, as imagens foram processadas para a extração de características, tais quais: número de gotas, área, perímetro e centroide das gotas e regiões molhadas. A partir desses parâmetros foram analisados a cobertura molhada da amostra, a uniformidade da distribuição das gotículas, a uniformidade das áreas molhadas e o fator de

forma circular de todas as gotas. A classificação da hidrofobicidade se deu através da aplicação de uma árvore de decisão *MultiBoost*. Os resultados foram julgados satisfatórios com um erro de aproximadamente 0,2% e 0,25% para as classes HC3 e HC5, respectivamente, e os autores concluíram que a metodologia pode ser aplicada numa plataforma DSP (*Digital Signal Processor*) com sucesso.

Wang *et al.* (2016) propuseram uma técnica para avaliar o nível de poluição em buchas poliméricas de transformadores a partir da análise da hidrofobicidade de superfície. Para tal, foi utilizado o PDI para processar um banco de dados contendo 630 imagens e extrair quatro características: maior área molhada; cobertura da água; maior excentricidade e maior fator de forma. A classificação foi realizada através de uma rede do tipo MLP e obteve uma taxa de acerto de 97%. Tal qual outros trabalhos que extraem características intrínsecas às regiões imagem, como tamanho de gotas, excentricidade, entre outros, essa abordagem tende a resultar em algoritmos com uma demanda computacional considerável, o que prejudicaria sua implementação em dispositivos móveis. Uma vez que, para cada região da imagem, diversas propriedades devem ser avaliadas para serem posteriormente submetidas à classificação.

Em 2016 foi apresentado por Iruansi e outros um método de segmentação para amostras de hidrofobicidade de superfície de isoladores poliméricos utilizando contornos ativos e processamento morfológico. O método proposto foi comparado aos desenvolvidos por Liang e outros (2012) e Dong e outros (2015), em que a rotina proposta se mostrou superior às outras duas no problema de segmentação de amostras de hidrofobicidade. Os resultados obtidos indicam que o método apresentou uma segmentação muito superior ao proposto por Liang *et al.* (2012), visto que este é altamente sensível ao ruído e dependente da forma da gota, sendo adequado apenas quando o formato da gota é circular, oval ou possui uma fronteira contínua. Foi realizada uma análise quantitativa entre o método proposto e o desenvolvido por Dong *et al.* (2015), em que o método descrito no trabalho desenvolvido pelos autores apresentou melhores resultados sob as condições e critérios adotados na análise. Os autores não apresentaram nenhum método de classificação para avaliar o estado da hidrofobicidade de superfície de forma automática a partir das imagens processadas.

Em 2017, Alves e colaboradores propuseram uma ferramenta computacional capaz de auxiliar na tomada de decisão e na classificação da hidrofobicidade de isoladores poliméricos de forma quantitativa. As imagens tratadas foram provenientes da superfície de isoladores de vidro temperado de suspensão recobertos com material polimérico e envelhecidos artificialmente por imersão em água e borrifados com sal. As imagens foram obtidas em laboratório sob iluminação uniforme e utilizando um borrifador, para gerar uma fina névoa,

com água e corante, com a finalidade de realçar o contraste artificialmente,. O algoritmo desenvolvido extrai as seguintes características: número de regiões molhadas; tamanho das regiões molhadas; tamanho das regiões secas e distribuição percentual das áreas. A partir desses parâmetros foi feita uma análise comparativa de 5 amostras dos HC de 1 a 5 que foram previamente classificadas subjetivamente, na qual foi possível avaliar, de forma numérica e objetiva, a classe de hidrofobicidade do isolador, dando uma indicação do seu estado operacional e auxiliando na tarefa de classificação. Não foram realizadas avaliações em mais de uma amostra do mesmo HC e, portanto, não foi indicado um percentual de acerto da classificação.

Já em 2018, Alves expandiu sua pesquisa incluindo outras características na avaliação da hidrofobicidade de isoladores poliméricos. Desta vez foram utilizadas o número regiões molhadas, a maior área molhada, a área total molhada, as distâncias média e máxima entre as regiões molhadas, o maior fator de forma e a excentricidade. Foram processadas cerca de 450 imagens obtidas em laboratório sob condições de iluminação uniforme e borrifando uma solução de água, álcool isopropílico e corante. Após a extração de características, a classificação da hidrofobicidade foi realizada através de modelagem probabilística e de uma rede neural do tipo MLP, obtendo uma taxa de acerto de 86,76% julgada, segundo a autora, satisfatória. A autora, no entanto, não aborda cenários de classificação utilizando imagens produzidas sob iluminação não-uniforme.

De modo similar, Yang e outros (2018) propuseram a utilização de uma rede neural artificial do tipo MLP para classificar a hidrofobicidade de isoladores poliméricos baseado em características extraídas das imagens utilizando PDI. Nesse caso, foram avaliadas sete características: o número, excentricidade média e taxa de cobertura das gotículas de água e a taxa de cobertura, perímetro, fator de forma e excentricidade da maior gota. Após a extração, técnicas de otimização de características foram utilizadas para avaliar quais parâmetros, dentre os avaliados, estavam mais bem relacionados à classe de hidrofobicidade. Desse modo, as características que melhor representavam os HC foram: o número de regiões molhadas; taxa de cobertura; taxa de cobertura da maior gota; perímetro da maior gota e fator de forma da maior gota. Essas características foram utilizadas como entrada de uma rede neural do tipo MLP contendo três camadas ocultas com onze neurônios em cada, obtendo uma taxa de acerto de 98,1%.

Sun *et al.* (2018) utilizaram a uma rede neural probabilística (RNP) para classificar a hidrofobicidade de isoladores. De uma base de dados contendo 20 imagens de cada umas das 7 classes, totalizando 140 amostras, foram extraídos os seguintes parâmetros: fator de forma;

razão de área da maior gota e a taxa de cobertura da área molhada. Essas características foram utilizadas como entrada da RNP que obteve uma taxa de acerto de 94,8%.

Ainda em 2018, Jayabal e colaboradores propuseram um classificador baseado no Sistema de Inferência Fuzzy baseado em Redes Adaptativas (do inglês *Adaptive Neuro-Fuzzy Inference System - ANFIS*) para determinar a qualidade da hidrofobicidade de isoladores utilizando imagens digitais. Foram utilizadas 681 imagens produzidas em laboratório sob iluminação uniforme a partir de um único isolador borrifado com uma solução de álcool isopropílico em água. Dez parâmetros estatísticos foram extraídos das imagens e uma redução de características de dois estágios foi aplicada para selecionar os parâmetros mais relevantes, reduzindo para apenas quatro características, a saber: intensidade média; correlação; distorção e homogeneidade. Na sequência, vários classificadores ANFIS foram avaliados, resultando em uma taxa de acerto de 96,4% e 93,3%.

Em 2020, Kokalis e outros discutiram a classificação da hidrofobicidade de isoladores poliméricos utilizando redes neurais convolucionais (RNC). Foram produzidas 4.500 imagens da superfície de isoladores borrifada com uma solução de água e álcool etílico. A concentração de álcool foi variada para reproduzir artificialmente o comportamento das diversas classes de hidrofobicidade. Na sequência, foram testados sete modelos de RNC, um modelo pequeno proposto na pesquisa, os modelos VGG16 e VGG19 treinados previamente, e os modelos VGG16, VGG19, GoogleNet e Resnet retreinados com o banco de imagens produzidos. As redes foram utilizadas para determinar de forma automática a classe de hidrofobicidade das amostras e eliminar a subjetividade do operador. Os experimentos demonstraram que a aplicação RNC GoogleNet atingiu uma taxa de acerto de aproximadamente 98% na classificação das imagens. É notável, no entanto, que os autores necessitaram de um volume consideravelmente maior de amostras no treinamento das redes, quando comparados aos demais métodos que utilizam redes neurais convencionais.

Neste capítulo foi apresentado um panorama dos principais estudos relacionados ao tema abordado neste trabalho. Diante do exposto, percebe-se a relevância da análise, segmentação e classificação da hidrofobicidade em isoladores poliméricos. Nesse contexto, a intenção do presente trabalho é desenvolver um método de segmentação e posterior classificação da hidrofobicidade na superfície de isoladores poliméricos por meio do processamento digital de imagens. Para tal propósito, levou-se em consideração condições de iluminação não-uniforme no momento da captura da imagem e a necessidade de uma técnica que requeira baixo custo computacional para implementação, visando sua implementação em dispositivos móveis, que possuem capacidade de processamento limitada. Nesse cenário, na

Tabela 2 é possível observar a suma dos trabalhos mais significativos desenvolvidos no tema de classificação da hidrofobicidade de isoladores poliméricos de alta tensão. No próximo capítulo será descrita a metodologia aplicada nos procedimentos realizados no decorrer desta pesquisa.

Tabela 2 - Parâmetros de classificação e método de tomada de decisão utilizados na bibliografia.

| Ano  | Pesquisadores           | Técnica                                                                                                                                                                                                              | Características                                                           |
|------|-------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------|
| 2001 | Berg                    | Média das entropias normalizadas.                                                                                                                                                                                    | -                                                                         |
| 2005 | Chen <i>et al.</i>      | Média das entropias normalizadas otimizada;<br>Método de ponto de semente;<br>Magnitude frequente e Fator de forma otimizado.                                                                                        | Parametrização do fator de forma circular.                                |
| 2008 | Thomazini <i>et al.</i> | Dimensão fractal.                                                                                                                                                                                                    | Função matemática.                                                        |
| 2009 | Thomazini               | Morfologia matemática;<br>Dimensão fractal; Entropia;<br>Energia superficial;<br>Variância;<br>Homogeneidade.                                                                                                        | Função matemática.                                                        |
| 2013 | Khalayli <i>et al.</i>  | Morfologia matemática.                                                                                                                                                                                               | Classificação Polinomial.                                                 |
| 2014 | Jarrar <i>et al.</i>    | Transformadas Discreta do cosseno, wavelet, randon e contourlet;<br>Matriz de co-ocorrência dos níveis de cinza;<br>Regressão por <i>stepwise</i> .                                                                  | k-ésimo Vizinho Próximo<br>Rede Neural Artificial<br>Classificador Linear |
| 2015 | Dong <i>et al.</i>      | Cobertura molhada;<br>Distribuição das gotículas;<br>Uniformidade das áreas molhadas;<br>Fator de forma.                                                                                                             | Árvore de decisão<br>MultiBoost.                                          |
| 2016 | Wang <i>et al.</i>      | Maior área molhada;<br>Cobertura da água;<br>Maior excentricidade;<br>Maior fator de forma.                                                                                                                          | Rede Neural Artificial.                                                   |
| 2017 | Alves                   | Número de regiões molhadas;<br>Área das regiões molhadas e secas;<br>Distribuição percentual das áreas.                                                                                                              | -                                                                         |
| 2018 | Alves                   | Número de regiões molhadas;<br>Maior área molhada;<br>Área total molhada;<br>Distâncias máxima entre as regiões molhadas;<br>Distâncias média entre as regiões molhadas;<br>Maior fator de forma;<br>Excentricidade. | Modelo Probabilístico e<br>Rede Neural Artificial.                        |
| 2018 | Yang <i>et al.</i>      | Número de regiões molhadas;<br>Razão de cobertura média e máxima;<br>Perímetro da maior gota;<br>Maior fator de forma.                                                                                               | Rede Neural Artificial                                                    |
| 2018 | Sun <i>et al.</i>       | Fator de forma;<br>Razão de área da maior gota;<br>Taxa de cobertura da área molhada.                                                                                                                                | Rede Neural Probabilística                                                |
| 2018 | Jayabal <i>et al.</i>   | Intensidade média;<br>Correlação;<br>Distorção;<br>Homogeneidade.                                                                                                                                                    | Sistema de Inferência<br>Neuro-Fuzzy                                      |
| 2020 | Kokalis <i>et al.</i>   | -                                                                                                                                                                                                                    | Rede Neural Convolutacional                                               |
| 2022 | Este trabalho           | Média das TDF das linhas e colunas.                                                                                                                                                                                  | Rede Neural Artificial                                                    |

Fonte: autoria própria.

## 4 METODOLOGIA

A metodologia adotada a fim de viabilizar a classificação da hidrofobicidade utilizando PDI é detalhada nas seções seguintes. Foram levadas em consideração as etapas de construção do banco de imagens, a subsequente classificação subjetiva da base de dados de acordo com o disposto no STRI, a elaboração de algoritmos capazes de segmentar as amostras da base de dados e a elaboração de algoritmos capazes de extrair sinais característicos no domínio da frequência para posterior análise e classificação da hidrofobicidade.


### 4.1 GERAÇÃO DA BASE DE DADOS

A geração da base de dados é etapa fundamental para que se possa validar os algoritmos que foram produzidos. Para isto, foram feitas fotografias de uma superfície hidrofóbica previamente borrifada com uma solução de álcool isopropílico em água, como descrito em metodologia proposta nos trabalhos de Thomazini (THOMAZINI, GELFUSO e ALTAFIM, 2008; THOMAZINI, GELFUSO e ALTAFIM, 2008; THOMAZINI, 2009; THOMAZINI, GELFUSO e ALTAFIM, 2012), uma vez que variando a concentração da solução (de 0% a 100% do volume de álcool em água) foi possível obter artificialmente imagens características dos níveis HC1 até HC6. O nível HC7 é desinteressante no âmbito deste trabalho, pois representa uma situação em que a superfície é completamente hidrofílica e se encontra inteiramente coberta pela solução, resultando em uma imagem completamente uniforme. A pulverização foi realizada duas vezes por segundo a uma distância aproximada de  $25 \pm 10$  cm. A quantidade de água pulverizada foi de 12 a 20 ml. A aquisição das imagens foi realizada em até 10 segundos após o término da pulverização.

As imagens foram capturadas por meio de uma câmera digital com resolução máxima de 16 *megapixels* a uma distância fixa de 15 cm. A iluminação foi realizada por meio de três lâmpadas do tipo LED de 15 W cada dispostas de forma simétrica a aproximadamente 120°

uma da outra de modo gerar uma iluminação uniforme sobre a amostra de superfície. Com a finalidade de simular condições de iluminação uniforme e não-uniforme, as imagens foram capturadas tanto com as três lâmpadas ligadas, quanto alternou-se uma lâmpada desligada por vez. Uma representação da disposição das luminárias em relação à amostra pode ser observada através da Figura 19.

Figura 19 - Sistema de iluminação e amostra de hidrofobicidade.



Fonte: autoria própria.

Devido a pretensão de utilizar uma RNA para realizar a classificação, aliada à própria diversidade e complexidade do fenômeno, a base gerada necessitava ser numerosa para permitir um treinamento adequado da rede. Dessa maneira, foram produzidas 1200 amostras, sendo que para cada HC foram capturadas 100 imagens sob iluminação uniforme e 100 sob iluminação não uniforme.

Na Figura 20 é apresentada uma amostra da classe HC1 produzida utilizando o método descrito. Nota-se que não foi utilizada a adição de corante, buscando principalmente criar um método de segmentação robusto o suficiente, capaz de realizar o processamento de amostras incolores, enquanto mantém um baixo nível de demanda computacional. Ao passo que, sendo o método desenvolvido capaz de segmentar amostras sem corante, supõe-se que a segmentação de amostras coloridas artificialmente seja tarefa trivial ao método proposto. Ademais, buscou-se dispensar a necessidade de manter um corante à mão durante inspeções em linhas de

transmissão ou subestações utilizando o método proposto. Esse fato tornou a tarefa de segmentação consideravelmente mais difícil, necessitando de uma metodologia de PDI mais robusta para realizar o processamento das amostras.

Figura 20 - Amostra do banco de imagens produzido, pertencente à classe HC1.



Fonte: autoria própria.

## 4.2 PRÉ-CLASSIFICAÇÃO DAS IMAGENS

Como o treinamento de RNA do tipo MLP é do tipo supervisionado, é necessário que as amostras do banco sejam classificadas previamente, através do método descrito pelo STRI. Ademais, é necessário um parâmetro para comparação dos resultados da classificação produzidos pelo método desenvolvido. Assim, como a base produzida é bastante ampla e volumosa, não seria prático que a classificação fosse feita por somente uma pessoa, ou ainda, que cada amostra fosse classificada por apenas um avaliador, visto que isso reforçaria a subjetividade implícita ao método do STRI. Desta forma, em um primeiro momento, as imagens produzidas sob iluminação uniforme foram distribuídas entre voluntários que se propuseram a realizar a classificação seguindo o guia STRI. Os voluntários foram estudantes do mestrado no PROEE/UFS e da graduação que vinham cursando a disciplina Equipamentos Elétricos no curso de engenharia elétrica da Universidade Federal de Sergipe. Além das fotografias, foi encaminhado aos voluntários um documento para registro da classificação e material explicativo, conforme Apêndice A, além de material contendo exemplos de classificação, detalhado no Apêndice B. Cada imagem do banco foi classificada por três voluntários

diferentes. Nos casos em que uma mesma amostra foi classificada em classes diferentes pelos três voluntários, o autor do trabalho definiu a classe da amostra. Todo o trabalho de classificação foi supervisionado pelo autor deste trabalho.


## 4.3 PROCEDIMENTO COMPUTACIONAL

Uma visão geral do algoritmo para segmentação e classificação das amostras é apresentada nas seções seguintes. Os algoritmos foram implementados através do *software* MATLAB® e foram validados posteriormente através das classificações subjetivas do banco de imagens, conforme descrito em seção anterior.

### 4.3.1 ROTINA DE SEGMENTAÇÃO

Um fluxograma da rotina de segmentação desenvolvido é apresentado na Figura 21. O algoritmo é composto por sub-rotinas com fins específicos no tratamento de imagens matriciais, sendo que, ao fim do processamento, a amostra final está apta para ser processada pela rotina de extração de características. O detalhamento de cada etapa do algoritmo é realizado nas subseções seguintes.

Figura 21 - Fluxograma do algoritmo de segmentação de imagens proposto.



Fonte: autoria própria.

#### 4.3.1.1 CONVERSÃO PARA TONS DE CINZA

Como a superfície do isolador possui cor uniforme, a informação dos canais RGB da imagem é irrelevante e apenas acrescentaria custo computacional desnecessário. Desse modo, o processamento das etapas seguintes é realizado inteiramente em tons de cinza. Assim, sendo  $f_i(i, j)$  uma imagem no espaço RGB, a conversão para o espaço de tons de cinza se dá segundo a Equação 14 abaixo:

$$f(i, j) = 0,2989 \cdot f_R(i, j) + 0,5870 \cdot f_G(i, j) + 0,1140 \cdot f_B(i, j) , \quad (14)$$

em que  $f(i, j)$  é a imagem convertida para tons de cinza, os valores de  $i$  e  $j$  correspondem às linhas e colunas da imagem, respectivamente, e os valores de  $c$  correspondem aos canais RGB, sendo  $c = 1$  o canal vermelho (R),  $c = 2$  o canal verde (G) e  $c = 3$  o canal azul (B). Os valores dos pesos atribuídos a cada canal na Equação 14 advêm da forma como o olho humano percebe a luz, visto que a sensibilidade da visão não é idêntica para as três cores básicas (DAVSON e PERKINS, 2021).

#### 4.3.1.2 EQUALIZAÇÃO ADAPTATIVA DE HISTOGRAMA LIMITADA POR CONTRASTE (CLAHE)

Como as imagens capturadas possuem iluminação não uniforme e, devido à transparência da água, o contraste é bastante limitado, fazendo com que regiões molhadas e o fundo possuam *pixels* com valores bastante próximos uns dos outros, fez-se então necessária a aplicação de técnicas que buscam aumentar o contraste das imagens. Nesse contexto, foi utilizada a Equalização Adaptativa de Histograma Limitada por Contraste (CLAHE, do inglês *Contrast-Limited Adaptive Histogram Equalization*), conforme definida em seção anterior, com a finalidade de melhorar o contraste da imagem e a separabilidade entre regiões de fundo e os objetos de interesse.

#### 4.3.1.3 OPERAÇÕES MORFOLÓGICAS EM TONS DE CINZA

Na sequência, essa etapa consiste na execução de operações morfológicas sobre a imagem em tons de cinza. Foram executadas as operações de abertura e fechamento utilizando um elemento estruturante em formato de disco. Essa sub-rotina é necessária para atenuar e

remover saltos repentinos nos tons de cinza, geralmente causados por luz refletida na superfície das gotas, devido a sombreamento ou introduzidos na etapa anterior.

#### 4.3.1.4 AGUÇAMENTO

Um filtro de aguçamento é utilizado para realçar ainda mais as diferenças entre as regiões de objeto, ou seja, gotas e regiões molhadas, das regiões de fundo. Esse tipo de operação realça as diferenças nas regiões de borda, onde diferentes tons de cinza se encontram. Isto é alcançado subtraindo-se da imagem original uma versão borrada dela mesma.

#### 4.3.1.5 BALANCEAMENTO DO BRILHO

O balanceamento do brilho da amostra é mais uma rotina necessária para mitigar os efeitos da iluminação não uniforme a que imagens capturadas em ambientes abertos estão sujeitas. O algoritmo aplicado foi descrito no trabalho de Chen e outros (2013), conforme visto em seção anterior.


#### 4.3.1.6 RECONSTRUÇÃO DO FUNDO POR TDC

Como etapa final do processo de remoção dos efeitos da iluminação desequilibrada, foi utilizado um algoritmo para estimar o gradiente de iluminação do fundo da amostra. Dado que o fundo da maioria das imagens relacionadas ao problema abordado está associado a uma baixa frequência espacial no domínio da frequência e, conseqüentemente, os objetos estão associados à uma alta frequência espacial. É, então, especialmente efetivo detectar o objeto, inicialmente, através da reconstrução do fundo para, na sequência, encontrar as diferenças entre a amostra inspecionada e o fundo reconstruído (CHEN, CHIEN e NGUYEN, 2013). Conforme explanado na subseção 2.3.4, a TDC pode ser utilizada para estimar o fundo de uma imagem quando sua frequência espacial é muito inferior que a do objeto.

Após o cálculo da TDC da imagem os coeficientes associados às componentes de alta frequência são eliminados. Na Figura 22 (a) é demonstrada a representação simplificada da TDC de uma imagem  $8 \times 8$  e quais são as frequências removidas no processo de reconstrução do fundo, conforme Figura 22 (b). O filtro utilizado pode ser expresso através da Equação 15 abaixo, em que  $D(x, y)$  é a TDC de uma imagem e  $D_f(x, y)$  é a sua versão filtrada.

$$D_f(x, y) = \begin{cases} D(x, y), & x = 0 \text{ ou } y = 0 \\ 0, & \text{caso contrário.} \end{cases} \quad (15)$$

Figura 22 - Representação simplificada da TDC de uma imagem  $8 \times 8$ :  
(a) TDC da Imagem; (b) Frequências removidas durante o processo.



Fonte: autoria própria.


Apesar dessa filtragem, as componentes verticais e horizontais de primeira ordem remanescentes são suficientes para contaminar a imagem com ruído espúrio na forma de faixas verticais e horizontais. Para remover esse ruído, é necessário aplicar um filtro de *cut-off* ao longo da componente vertical e horizontal. Para tal, é necessário determinar as frequências de *cut-off* às quais o filtro deve ser ajustado. Conforme demonstrado por Chen e outros (2008), essas frequências,  $F_x$  para a componente horizontal e  $F_y$  para a vertical, podem ser detectadas analisando-se o gráfico dos coeficientes verticais e horizontais em função da frequência. Conforme ilustrado na Figura 23 (a) e (b), a frequência desejada é o primeiro ponto em que o valor dos coeficientes deixa de ser decrescente e passa a ser crescente.

Esse filtro pode também ser expresso através da Equação 16 abaixo, em que  $D_{cf}(x, y)$  representa a TDC da imagem após a aplicação do filtro de *cut-off*.

$$D_{cf}(x, y) = \begin{cases} D_f(x, y), & x < F_x \text{ ou } y < F_y \\ 0, & \text{caso contrário.} \end{cases} \quad (16)$$


Na Figura 24 é apresentada uma amostra contaminada por gradiente de iluminação (a), em (b) é exibida a estimação do gradiente de fundo após a aplicação do filtro descrito na Equação 15 e em (c) é apresentada a saída final do processo de estimação do gradiente de fundo obtida através da aplicação do filtro descrito na Equação 16.

Figura 23 - Gráficos dos coeficientes verticais e horizontais da TDC em relação à frequência.



Fonte: autoria própria.

Figura 24 - Amostra original e a aplicação dos filtros no domínio da frequência para estimar o gradiente.



Fonte: autoria própria.

#### 4.3.1.7 CORREÇÃO DO FUNDO

Após a reconstrução, a imagem passa pela rotina de correção do fundo, que visa remover qualquer resquício na variação da intensidade luminosa e desequilíbrios na distribuição do brilho que possam ainda estar presentes. Isso é alcançado dividindo-se a imagem proveniente da etapa de balanceamento do brilho pela reconstrução do fundo obtida na etapa anterior. Esse processo tende a atenuar os *pixels* da imagem em que o valor correspondente na mesma posição na imagem de estimação do gradiente de fundo possui valor alto e a amplificar os valores dos *pixels* em que a intensidade do gradiente de fundo é baixa.

#### 4.3.1.8 BINARIZAÇÃO

Nesse ponto, a imagem está pronta para ser limiarizada. O método escolhido foi o limiar adaptativo conforme proposto por Bradley e Roth (2007). Essa técnica determina um limiar local baseado em estatísticas de primeira ordem da vizinhança de um pixel e é superior a outros métodos de determinação de limiar automático, tal qual o método de Otsu.

#### 4.3.1.9 OPERAÇÕES MORFOLÓGICAS EM PRETO E BRANCO

A última etapa do processo de segmentação consiste em aplicar operações morfológicas simples, como: abertura; fechamento e reconstrução geodésica. O objetivo destas operações é remover ruído residual da etapa de binarização, gotas muito pequenas que não contribuem para a classificação da imagem e *pixels* isolados, enquanto as bordas das regiões são preservadas. Buracos no interior dos objetos também são preenchidos nessa etapa. Quando necessário, foi utilizado um elemento estruturante no formato de disco.

Por fim, o método de segmentação desenvolvido foi comparado ao método proposto no trabalho de Iruansi *et al.* (2016) utilizando a base de dados desenvolvida no presente trabalho e realizando o processamento no mesmo computador para analisar os dois métodos. Foram avaliados: a qualidade do processo de segmentação; bem como o tempo necessário para realizar o processo de cada amostra, como forma de estimar a demanda computacional de cada método.

#### 4.3.2 EXTRAÇÃO DE CARACTERÍSTICAS DE FREQUÊNCIA

Partindo da premissa de que a diferença entre as classes de hidrofobicidade reside, principalmente, na frequência espacial das áreas molhadas é possível enxergar uma linha, ou coluna, de *pixels* da amostra segmentada como um sinal discreto e não-periódico.


Desse modo, para extrair as informações de frequência das imagens foi utilizada a Transformada Discreta de Fourier, em especial, a implementação computacionalmente eficiente do algoritmo, a Transformada Rápida de Fourier. Nesse sentido, foram testadas duas estratégias visando a extração dos parâmetros no domínio da frequência que melhor determinassem uma classe de hidrofobicidade em específico.

A primeira abordagem utiliza a TRF unidimensional, computada sobre as linhas e as colunas de forma individual. Na segunda abordagem foi utilizada a TRF bidimensional sobre toda a extensão da imagem.

No primeiro caso, a TRF unidimensional é computada primeiramente para todas as linhas e em seguida para todas as colunas da amostra. Apenas a informação de magnitude é considerada em ambas as operações e, como o espectro resultante é simétrico no seu ponto médio, apenas a segunda metade do espectro é considerada. Na sequência, buscando sintetizar a informação e obter uma curva que represente o comportamento amplo, é computada a média entre todos os vetores contendo as transformadas das linhas e colunas. Por fim, esse vetor é normalizado seguindo duas estratégias: a normalização pelo valor máximo, que restringe o valor dos coeficientes ao intervalo  $[0,1]$ ; e a normalização pela área, que delimita um valor unitário para a área sob a curva formada pelo conjunto dos coeficientes. O impacto das duas estratégias de normalização no processo de classificação foi avaliado. Na Figura 25 é apresentado um fluxograma resumindo o processo.

Para o caso da extração de parâmetros utilizando a TRF bidimensional, o processo é mais simples. Inicialmente, é computada a TRF bidimensional da imagem, novamente, apenas a magnitude do espectro centralizado é levada em consideração. Como o espectro centralizado é simétrico ao longo da diagonal principal da matriz, a informação relevante está confinada a apenas dois quadrantes. Neste trabalho, foram considerados 1º e 2º quadrantes. Assim, a informação de frequência relevante capaz de descrever o comportamento das diferentes classes, capturando as características assimétricas das gotas e regiões, está presente nas diagonais desses dois quadrantes que, quando concatenadas, compõe o vetor de características desejado.

Figura 25 - Fluxograma do processo de extração de características de frequência a partir da TRF unidimensional.



Fonte: autoria própria.

#### 4.3.3 CLASSIFICAÇÃO DAS AMOSTRAS

Por fim, a última etapa da metodologia desenvolvida é a classificação das amostras empregando uma rede neural artificial do tipo MLP. A implementação computacional foi realizada utilizando o software MATLAB® dotado do conjunto de ferramentas denominado Neural Networks Toolbox, que permite a construção e treinamento de RNA.

Após a extração do sinal de entrada de cada uma das 1200 amostras do banco, foi construída uma matriz composta por 1200 colunas e cujo número de linhas depende da quantidade de posições no vetor de características utilizado. Para o caso do vetor proveniente da TRF unidimensional, o número de linhas é 128, quando a normalização pela área é utilizada, ou 127, quando normalizada pelo valor máximo, visto que o primeiro elemento é sempre constante e igual a 1, não agregando informação útil no processo do treinamento da rede. Para o vetor gerado através da TRF 2D, o número de linhas da matriz de informações é igual a 256, independentemente do método de normalização adotado. Cada coluna corresponde ao sinal de frequência espacial de uma amostra. Em sequência, essa matriz foi subdividida, de forma aleatória, em grupos de: Treinamento, compreendendo 840 amostras, que correspondem a 70% do total da base; Teste, compreendendo 180 amostras, que correspondem a 15% do total, e Validação com proporção igual ao grupo de Teste. Por fim, estes grupos foram utilizados nos procedimentos homônimos da rede neural.

A RNA foi implementada no ambiente MATLAB®, empregando-se apenas uma camada oculta, com função de ativação não-linear do tipo sigmoide. Nos neurônios da camada de saída, foi empregada a função Softmax, que é uma variação da função sigmoide, mas normaliza a saída da rede em uma distribuição de probabilidades que consiste em  $k$  probabilidades, sendo  $k$  o número de neurônios na camada de saída. Foram testadas três topologias diferentes, contendo 9, 12 e 15 neurônios na camada oculta.

A etapa de treinamento de uma rede do tipo MLP realiza o ajuste dos pesos sinápticos através da retropropagação do erro (*backpropagation*) ao fim de cada ciclo de treinamento e procura encontrar o mínimo local no espaço dimensional dos coeficientes da rede de forma iterativa, buscando a minimização do erro quadrático médio entre cada iteração. Foram testados quatro algoritmos de treinamento diferentes:

- Gradiente Conjugado com Reinício Powell/Beale;
- Gradiente Conjugado Escalonado;
- Levenberg-Marquardt;
- Retropropagação Resiliente (*Resilient Backpropagation*).

Ademais, é realizada uma comparação entre dois métodos de classificação propostos métodos da literatura que abordam o mesmo problema. Para realizar a comparação de forma isonômica, o método de segmentação proposto neste trabalho foi primeiramente aplicado a todas as amostras do banco de imagens e a classificação pelos métodos avaliados foi realizada nas amostras já segmentadas. Todas as análises foram realizadas utilizando o mesmo computador para avaliar os três métodos, bem como o tempo de processamento necessário para gerar os vetores de características segundo os métodos avaliados.

O método apresentado por Alves (2018) utiliza uma topologia de RNA composta por 4 entradas, uma camada oculta com 12 neurônios e seis classes na camada de saída, correspondendo a cada uma das classes de hidrofobicidade. Todos os neurônios nas camadas ocultas e de saída possuem função de ativação do tipo sigmoide (ALVES, 2018). Os parâmetros utilizados como entrada foram:

- Área da maior região molhada ( $S_{max}$ );
- Área molhada total ( $S_t$ );
- Maior fator de forma ( $fc_{max}$ );<sup>1</sup>
- Número de regiões molhadas ( $n$ ).

O segundo método avaliado na comparação foi desenvolvido por Yang *et al.* (2018) e utiliza uma estrutura de rede formada por 5 entradas, três camadas ocultas com 11 neurônios em cada e seis saídas na última camada. De modo semelhante aos outros métodos analisados, todos os neurônios nas camadas ocultas e de saída possuem função de ativação do tipo sigmoide (YANG, BI, *et al.*, 2018). Os parâmetros de entrada utilizados para classificação são descritos abaixo:

- Maior fator de forma ( $fc_{max}$ );
- Número de regiões molhadas ( $n$ );
- Perímetro da maior gota ( $L_{max}$ );
- Razão de cobertura ( $k_1$ );
- Razão de cobertura máxima ( $k_2$ );

O parâmetro  $k_1$  é definido conforme a Equação 17 a seguir:

$$k_1 = \sum_{i=0}^n \frac{S_i}{S_{total}} \quad (17)$$

---

<sup>1</sup> O fator de forma é a relação entre o perímetro e a área da região molhada (ALVES, 2018).

Onde  $S_i$  é o número de *pixels* da  $i$ -ésima área molhada e  $S_{total}$  é o número total de *pixels* da imagem. Já o parâmetro  $k_2$  é definido como sendo a razão entre o número de *pixels* da maior área molhada ( $S_{max}$ ) e o número total de *pixels* da imagem ( $S_{total}$ ). Na Tabela 3 estão resumidas as principais características de cada método, bem como a taxa de acerto na classificação da base de dados construída para este trabalho.

Tabela 3 - Topologia, parâmetros de entrada e taxa de acerto para cada método.


| <b>Método</b>             | <b>Topologia</b>                                                     | <b>Parâmetros</b>                            | <b>Acertos (%)</b> |
|---------------------------|----------------------------------------------------------------------|----------------------------------------------|--------------------|
| Alves (2018)              | 4 entradas;<br>1 camada oculta com 12 neurônios;<br>6 saídas.        | $S_{max}$ , $S_t$ , $fc_{max}$ e $n$         | 75,83              |
| Yang <i>et al.</i> (2018) | 5 entradas;<br>3 camadas ocultas com 11 neurônios cada;<br>6 saídas. | $fc_{max}$ , $n$ , $L_{max}$ , $k_1$ e $k_2$ | 74,66              |
| Método Proposto           | 128 entradas;<br>1 camada oculta com 15 neurônios;<br>6 saídas.      | TRF unidimensional das linhas e colunas      | 78,59              |

Fonte: autoria própria.

Por fim, também foi proposta a avaliação da hidrofobicidade de superfície através de níveis arbitrários, obtidos ao agrupar os níveis estipulados pelo guia STRI. Visando, dessa maneira, reduzir a subjetividade inerente às classes de hidrofobicidade e traçando um paralelo prático com o estado do isolamento. Para tanto, os níveis HC1 e HC2 foram considerados como indicativo de uma isolação em bom estado, ao passo que os níveis HC3 e HC4 são característicos de um isolamento em estado de operação aceitável e os níveis HC5 e HC6 caracterizam isolamentos fora das condições de operação. No mais, através do fluxograma da Figura 26 pode-se observar um diagrama de blocos que representa a metodologia desenvolvida e aplicada neste trabalho.

Neste capítulo foi descrita a metodologia aplicada para o desenvolvimento deste trabalho, descrevendo os procedimentos de geração da base de dados, processamento via PDI, extração de características e classificação dos dados. No próximo capítulo são apresentados os resultados obtidos na aplicação dessa metodologia.

Figura 26 - Fluxograma da metodologia desenvolvida e aplicada.



Fonte: autoria própria.

## 5 RESULTADOS

Neste capítulo são apresentados os resultados obtidos através da aplicação da metodologia exposta no capítulo anterior. Tais resultados compreendem o desempenho do algoritmo de segmentação das amostras em condições de iluminação adversas, a extração de características da frequência espacial da amostra segmentada e o desempenho do sistema de RNA proposto para executar a classificação da hidrofobicidade das amostras.

### 5.1 ROTINA DE SEGMENTAÇÃO


As imagens que compõe a base de dados utilizada nesta etapa foram produzidas de acordo com as etapas descritas no Capítulo 4, totalizando 1200 imagens de tamanho 256 x 256 *pixels*, sendo 200 amostras para cada uma das seis classes de hidrofobicidade e, dentre essas, 100 amostras em condições de iluminação uniforme e as demais em iluminação não-uniforme.

Na Figura 27 é ilustrada uma amostra pertencente à base de dados sem qualquer processamento prévio. É possível visualizar uma diferença no gradiente de iluminação da imagem, onde o canto superior direito recebeu pouca luz no momento da captura, enquanto o canto inferior esquerdo encontra-se mais iluminado que o restante da imagem. É necessário ressaltar ainda a presença de várias gotas muito pequenas que não influencia na classificação final da amostra, além da presença de sombreamento em várias gotas. Dessa maneira, o método proposto tenta mitigar a influência desses fatores na amostra antes da segmentação e, ao se aplicar esse método na amostra em questão, foram produzidos os resultados ilustrados entre a Figura 28 e a Figura 35, conforme visto a seguir.

A primeira operação realizada após as rotinas de aquisição e conversão da imagem para tons de cinza foi o a equalização adaptativa do histograma através do algoritmo CLAHE. O resultado é visto na Figura 28, por onde é possível perceber um aumento significativo no contraste geral da imagem, provocando um maior distanciamento nos tons de cinza dos *pixels*


das regiões de interesse e do fundo. A execução dessa etapa facilita a determinação dos limiares no processo de binarização na imagem, conforme descrito adiante.

Figura 27 - Amostra original de superfície hidrofóbica.



Fonte: autoria própria.


Figura 28 - Amostra após equalização de histograma CLAHE.



Fonte: autoria própria.

Na sequência, são executadas as operações referentes ao processamento morfológico em tons de cinza. Na Figura 29 é demonstrado o resultado desta etapa, onde é perceptível o efeito das operações na redução dos pontos de alto brilho e do ofuscamento que estava presente em algumas gotas, além da atenuação ou eliminação das gotas menores, que são irrelevantes no processo de classificação e comportam-se como ruído. Nesse estágio, já é possível perceber um ganho considerável na separabilidade entre fundo e objetos da imagem, denotado pela diferença entre seus respectivos tons de cinza.


Figura 29 - Amostra após a realização de operações morfológicas.



Fonte: autoria própria.

Após as operações morfológicas iniciais, foi aplicado um filtro de aguçamento, com o intuito de reforçar as regiões de bordas e transições da imagem. Esse passo resulta na imagem vista na Figura 30, onde é possível perceber que as regiões de bordas e transições entre objeto e fundo estão mais demarcadas, quando comparado à imagem da etapa anterior.


Figura 30 - Resultado da execução do filtro de aguçamento.



Fonte: autoria própria.

A etapa seguinte envolve uma tentativa de balancear o brilho da amostra através do cálculo descrito por Chen e Kuo (2013), visando mitigar os efeitos da iluminação desequilibrada que se encontram presentes na amostra. Para os casos em que a amostra já apresenta uma distribuição uniforme de brilho e iluminação, tanto esta etapa quanto a seguinte possuem pouco ou nenhum efeito sobre a imagem. A partir da Figura 31 é perceptível que os objetos, gotas e regiões molhadas, aprestam tons mais destacados e uniformes entre si, diferentes do fundo.

Figura 31 - Resultado da etapa de balanceamento de brilho.



Fonte: autoria própria.

O próximo passo foi realizar uma estimativa do fundo, ainda conforme o método proposto por Chen e Kuo (2013), e detalhado nos capítulos anteriores. O resultado é visto na Figura 32, onde todos os componentes de alta frequência foram filtrados, preservando apenas as principais características do fundo da imagem e do gradiente de iluminação. Isso é evidenciado pela maior intensidade luminosa dos *pixels* na porção inferior da imagem, onde a incidência de luz foi maior na imagem original, enquanto a porção superior é mais escura, com valores de *pixels* menores.

Figura 32 - Resultado da reconstrução do fundo de uma imagem.




Fonte: autoria própria.

O resultado da correção de fundo, obtido através da divisão da amostra na Figura 31 pela reconstrução do fundo da Figura 32, é visto na Figura 33, sendo possível perceber que a parte superior da imagem tornou-se mais clara, quando comparada à amostra original, enquanto a parte inferior teve resultado inverso e tornou-se um pouco mais escura. Este efeito torna a

distribuição de iluminação ao longo da imagem mais uniforme e é a principal diferença do método de segmentação proposto.


Figura 33 - Resultado da correção de fundo aplicada à imagem filtrada.



Fonte: autoria própria.

A amostra, agora, está pronta para limiarização, pois a contaminação causada pelo ofuscamento presente em algumas gotas e a iluminação desequilibrada foi removida pelas rotinas anteriores. Para tanto, foi utilizado o algoritmo de limiarização adaptativa por partes, conforme descrito no capítulo anterior. O resultado desta operação é mostrado na Figura 34.

Figura 34 - Resultado do limiar de imagem por limiarização adaptativa por partes.




Fonte: autoria própria.

Embora tenha havido perda na forma de algumas gotas, uma vez que as sombras criam uma região de *pixels* com valores baixos que geralmente ficam abaixo dos limiares determinados pelo método de limiarização adaptativa, essa perda não é suficiente para alterar a classe de hidrofobicidade da amostra.

O último passo é realizar as operações morfológicas na imagem segmentada para eliminação de gotas e regiões muito pequenas e preenchimento de buracos. O resultado desta rotina, e resultado final do método de segmentação proposto, é mostrado na Figura 35, onde é possível observar que os buracos dentro das duas gotas na porção inferior da amostra foram fechados, ao passo que todas as gotas e ruídos que eram menores que o elemento estruturante utilizado nestas operações foram removidos.


Figura 35 - Resultado final após operações morfológicas.



Fonte: autoria própria.


Observando a Figura 36 é possível visualizar uma comparação entre a imagem original (a), o resultado da aplicação do processo de limiarização automática através do Método de Otsu na amostra original sem qualquer processamento prévio (b) e o resultado da aplicação do algoritmo de segmentação proposto (c). Enquanto na imagem (b) é evidente o efeito causado pela iluminação distribuída de forma não-uniforme através da imagem, o mesmo efeito não é observado na amostra segmentada através do método proposto. Nota-se, no entanto, que o algoritmo elaborado possui tendência em não segmentar regiões sombreadas nos objetos de interesse, conforme mencionado previamente, não sendo capaz, portanto, de conservar a forma do objeto com perfeição. Porém, essa característica foi verificada apenas em amostras de HC intermediários, HC4 e HC5, e pouco afeta as etapas subsequentes de classificação, visto que a perda na segmentação não seria suficiente para alterar o nível de hidrofobicidade da amostra como um todo. Por fim, na Figura 37 é exibida uma composição com a saída de cada etapa do processo de segmentação descrito nesta seção, com a finalidade de melhor visualizar os efeitos de cada rotina e a evolução do procedimento como um todo.

Figura 36 - Limiarização de amostra através de método de Otsu e do método proposto.



Fonte: autoria própria.

Figura 37 - Detalhamento das etapas do processo de segmentação.



Fonte: autoria própria.

## 5.2 ANÁLISE DA SEGMENTAÇÃO

Conforme exposto na revisão bibliográfica, o método de segmentação de gotas em isoladores desenvolvido por Iruansi *et al.* (2016) demonstrou desempenho superior aos propostos por Liang *et al.* (2012) e Dong *et al.* (2015). O método de segmentação proposto neste trabalho foi, portanto, comparado aos resultados obtidos pela implementação do método proposto por Iruansi *et al.* (2016) (LIANG, YANG e LIAO, 2012; DONG, FANG, *et al.*, 2015; IRUANSI, TAPAMO e DAVIDSON, 2016).

Para tanto, a partir da base de dados construída, foi selecionado um grupo de 18 imagens, três amostras de cada classe de hidrofobicidade, todas com iluminação não-uniforme, que foram posteriormente classificadas manualmente segundo o STRI. Na Figura 38 é demonstrado um conjunto contendo uma amostra de cada classe, o resultado da aplicação do limiar automático de Otsu sem nenhum processamento prévio nas imagens originais e uma comparação entre os resultados obtidos aplicando-se o método proposto, bem como os resultados da aplicação do método descrito por Iruansi *et al.* (2016). Na Figura 38 coluna (a) são exibidas as imagens originais de, respectivamente, HC1 (1) a HC6 (6). De modo semelhante, na coluna (b) são demonstrados os resultados da aplicação direta do limiar automático de Otsu. Já na coluna (c) da mesma figura, são exibidos os resultados do método apresentado por Iruansi *et al.* (2016). Por fim, a coluna (d) mostra os resultados da segmentação pelo método proposto.


Ainda sobre a Figura 38, analisando os resultados na coluna (b) é possível notar que a limiarização deste tipo de amostra não é possível sem uma rotina de pré-processamento, pois o gradiente de iluminação torna a imagem impossível de segmentar usando um limiar único, como visto em (2b) e (3b). Além disso, a presença de pontos claros e ofuscamento, amostra (4a), tende a resultar em um valor de limiar muito alto, gerando uma segmentação imprópria.

Ao comparar os resultados obtidos pelo método de Iruansi *et al.* (2016) em imagens com alta densidade de gotas, amostras (1a) e (3a), com o método proposto, os resultados obtidos através da rotina proposta neste trabalho foram superiores. As gotas próximas umas das outras tendem a ser bem segmentadas, enquanto o método de Iruansi *et al.* (2016) tende a segmentar gotículas próximas umas das outras como uma única região, amostra (1c). Isso se deve ao fato de que a Função de Indicação de Borda, utilizada como função de parada do contorno ativo, base do método de Iruansi *et al.* (2016), é altamente dependente da magnitude do gradiente da imagem, que tende a ser alto em regiões de borda e baixo em regiões uniformes. Mas, quando dois ou mais objetos estão muito próximos, o gradiente entre os dois objetos é pequeno, não

sendo detectado pela Função de Indicação de Borda, resultando no agrupamento de várias gotas em uma mesma região (IRUANSI, TAPAMO e DAVIDSON, 2016).

Figura 38 - Comparação entre resultados de segmentação:

(a) Imagens originais; (b) (OTSU, 1979); (c) (IRUANSI, TAPAMO e DAVIDSON, 2016); (d) Método proposto;



Fonte: autoria própria.

A vantagem do método demonstrado por Iruansi *et al.* (2016) pode ser vista na amostra (5c), onde a rotina proposta tende a preservar a forma das gotas quando a região da borda é bem definida e as gotas estão separadas, enquanto o método proposto não foi capaz de segmentar adequadamente a maior região molhada vista na amostra (5a). Isso se deve ao fato de valores dos *pixels* do fundo estarem muito próximos dos valores do objeto, uma vez que a água é transparente e o método proposto não leva em consideração as informações das bordas (IRUANSI, TAPAMO e DAVIDSON, 2016).

Na segmentação da amostra (4a), o método proposto superou o método apresentado por Iruansi *et al.* (2016) mais uma vez, apesar das regiões de fronteira estarem bem definidas, os pontos de alto brilho foram a causa do resultado insatisfatório do método de Iruansi *et al.* (2016), uma vez que o gradiente nessa região tenderá a ser diferente do restante da borda da gota, causando uma interrupção na borda e resultando em um contorno que segmentará apenas a borda, deixando a gota com uma região vazia no meio, conforme visto na amostra (4c) (IRUANSI, TAPAMO e DAVIDSON, 2016).


Ao considerar a amostra de HC6 (6a), o método proposto produziu um resultado de segmentação superior aos outros dois ao segmentar corretamente as regiões de transição entre as áreas molhada e seca. No entanto, a segmentação não foi perfeita, já que algumas partes do fundo e do objeto foram segmentas em conjunto na porção inferior da imagem (6d). Já o resultado através do método de contornos ativos não foi capaz de encontrar bordas significativas para segmentar, como visto na amostra (6c), e acabou por segregar menos informação quando comparado ao resultado da amostra (6d).

De maneira semelhante ao que foi apresentado na Figura 38, na Figura 39 e na Figura 40 são apresentados conjuntos diferentes de imagens e seus respectivos resultados. Mais uma vez o método proposto demonstrou resultados melhores na segmentação de imagens com alta densidade de gotas, amostras (1a) e (2a) da Figura 39 e da Figura 40, em comparação ao proposto por Iruansi *et al.* (2016).

Novamente, foi observado o mesmo problema com múltiplas gotículas sendo segmentadas na mesma região, agora nas amostras (1c) e (2c) da Figura 39 e da Figura 40. Devido aos efeitos do sombreamento, que geralmente forma uma região com baixos valores de *pixels* próximo às gotas, o método proposto tende a subsegmentar as gotas, como pode ser observado nas amostras (2d), (3d) e (4d) da Figura 39, bem como nas amostras (2d) e (4d) da Figura 40. Enquanto o método desenvolvido por Iruansi *et al.* (2016) vai na direção oposta e tende a sobre segmentar os objetos, também devido à presença de sombras, que são consideradas bordas pela Função de Indicação de Borda. Este comportamento pode ser


observado nas amostras (2c) e (4c) de ambas as figuras (IRUANSI, TAPAMO e DAVIDSON, 2016).

Figura 39 - Comparação entre a segmentação dos métodos analisados em um segundo conjunto de imagens. (a) Imagens originais; (b) (OTSU, 1979); (c) (IRUANSI, TAPAMO e DAVIDSON, 2016); (d) Método proposto;



Fonte: autoria própria.

Figura 40 - Comparação dos resultados dos métodos analisados em um terceiro conjunto de amostras.  
 (a) Imagens originais; (b) (OTSU, 1979); (c) (IRUANSI, TAPAMO e DAVIDSON, 2016); (d) Método proposto;



Fonte: autoria própria.

O mesmo comportamento observado na imagem (5c) da Figura 38 é repetido nas amostras (3c) da Figura 39 e da Figura 40, onde o algoritmo desenvolvido por Iruansi *et al.* (2016) foi capaz de segmentar quase perfeitamente a maioria das gotas. O motivo, mais uma

vez, foi a maior distância entre as gotas, que permitem que o contorno se mova livremente ao redor dos objetos, assim como o fato de as bordas das gotas serem mais pronunciadas que nas outras imagens e, também, a menor incidência de sombras (IRUANSI, TAPAMO e DAVIDSON, 2016).

É possível observar sobre segmentação pelo método proposto na amostra (5d) da Figura 39, onde parte do fundo na porção inferior direita da imagem foi segmentado como um objeto devido ao baixo contraste após a correção do fundo. O mesmo problema apareceu na amostra (5c) da mesma figura, na porção superior direita, agora devido ao pequeno distanciamento entre as gotas, que fez com que o contorno as segmentasse como uma grande região. Embora a amostra (5a) da Figura 40 apresente baixo brilho e algum ruído, o método proposto foi capaz de obter um resultado melhor que o método de Iruansi *et al.* (2016), uma vez que as bordas são fracas e não contínuas (IRUANSI, TAPAMO e DAVIDSON, 2016).

Conforme observado anteriormente nas amostras (6c) e (6d) da Figura 38, os resultados para as imagens de HC6, amostras (6a), na Figura 39 e na Figura 40 foram ruins quando computados através do método de Otsu, mas o método proposto por Iruansi *et al.* (2016) foi capaz de reter alguma informação na segmentação devido às bordas pronunciadas nas pequenas regiões em que o fundo estava exposto. Já o método proposto foi capaz de segmentar as pequenas regiões de fundo presentes nas imagens de forma quase perfeita. Muito embora o tom esteja trocado em relação às demais amostras, visto que agora objeto ocupa a maior área da imagem e apresenta-se em tom de cinza mais escuro que o fundo. (IRUANSI, TAPAMO e DAVIDSON, 2016).

Dada a intensão de aplicar a metodologia em ambiente de dispositivo móvel e, para tanto, visando avaliar o impacto computacional dos métodos, o tempo de processamento computacional também foi verificado para as 18 amostras processadas. Conforme resultados apresentados na Tabela 4, é possível inferir que o algoritmo proposto demanda menos esforço computacional que o outro método, com tempos de processamento menores para todas as amostras.

Além disso, a análise do desvio padrão obtido para ambos os métodos evidencia que o método proposto possui tempos de processamento consistentes, apresentando um desvio padrão pequeno, de apenas 32,4 milissegundos. Isso se deve ao fato de que as operações realizadas são majoritariamente morfológicas e, portanto, relacionadas ao tamanho da imagem, e não às características intrínsecas aos valores dos *pixels*. Enquanto o método de contorno ativo é baseado em um algoritmo iterativo que desenvolve um contorno inicial e tenta encontrar regiões

de alta magnitude de gradiente na imagem, alterando a forma do contorno a cada iteração até que a estabilidade ou o número limite de iterações seja alcançado.

Tabela 4 - Tempo de processamento computacional.

| Imagem               | Tempo de processamento computacional (s) |                              |
|----------------------|------------------------------------------|------------------------------|
|                      | Método Proposto                          | Iruansi <i>et al.</i> , 2016 |
| Figura 38 (1a)       | 1.1032                                   | 1.9657                       |
| Figura 38 (2a)       | 1.1657                                   | 1.9115                       |
| Figura 38 (3a)       | 1.1829                                   | 2.5011                       |
| Figura 38 (4a)       | 1.1672                                   | 4.2245                       |
| Figura 38 (5a)       | 1.1375                                   | 1.4936                       |
| Figura 38 (6a)       | 1.1143                                   | 1.9570                       |
| Figura 39 (1a)       | 1.0805                                   | 1.8361                       |
| Figura 39 (2a)       | 1.1226                                   | 2.4317                       |
| Figura 39 (3a)       | 1.1367                                   | 1.6823                       |
| Figura 39 (4a)       | 1.1439                                   | 3.8144                       |
| Figura 39 (5a)       | 1.1550                                   | 3.4709                       |
| Figura 39 (6a)       | 1.1416                                   | 2.5555                       |
| Figura 40 (1a)       | 1.1767                                   | 2.2117                       |
| Figura 40 (2a)       | 1.1343                                   | 2.3885                       |
| Figura 40 (3a)       | 1.1426                                   | 1.8651                       |
| Figura 40 (4a)       | 1.1324                                   | 1.5373                       |
| Figura 40 (5a)       | 1.2223                                   | 4.3832                       |
| Figura 40 (6a)       | 1.1174                                   | 2.7059                       |
| <b>Média</b>         | 1.1431                                   | 2.4964                       |
| <b>Desvio Padrão</b> | 0.0324                                   | 0.8981                       |


Fonte: autoria própria.

O comportamento iterativo e sua dependência das características dos objetos da imagem no método desenvolvido por Iruansi *et al.* (2016) faz com que o tempo de processamento seja altamente dependente de parâmetros como: forma e tamanho dos objetos; tamanho da imagem; distância entre objetos; contraste; entre outros. Com isso, o desvio padrão do algoritmo de Iruansi *et al.* (2016), como visto na Tabela 4, foi de quase 1 segundo, muito superior ao valor obtido pelo método proposto, devido à correlação entre o tempo de processamento e as características da imagem processada (IRUANSI, TAPAMO e DAVIDSON, 2016).

Ademais, a autora do trabalho Alves (2018) cedeu acesso à sua base de imagens para que o método desenvolvido pudesse ser testado no processamento de amostras de hidrofobicidade em que foi utilizado corante na solução de aspersão. O resultado dessa

aplicação é exibido através da Figura 41, que relaciona uma amostra de cada uma das classes de hidrofobicidade e o respectivo resultado da aplicação do método de segmentação. É possível notar, então, que o método proposto foi eficaz na segmentação de imagens que utilizam corante. Comprovando que o procedimento pode ser utilizado em cenários que utilizem ou não corante na solução, ficando a cargo do inspetor optar por sua utilização.

Figura 41 - Resultados do método proposto em um conjunto de amostras com adição de corante.




Fonte: autoria própria.

### 5.3 ANÁLISES DA CLASSIFICAÇÃO


Conforme descrito no Capítulo 4, foram extraídos dois tipos de sinal de frequência de uma amostra de cada classe de hidrofobicidade. No gráfico da Figura 42 é demonstrada uma comparação entre os sinais obtidos através das TRF unidimensionais das linhas e colunas para todas as classes. Através da análise do gráfico em questão, é possível inferir que cada classe de hidrofobicidade possui um sinal de frequência com comportamento determinado, possuindo uma separabilidade razoável entre uma classe e outra. Já na abordagem utilizando a TRF bidimensional, cujos vetores de características correspondentes a uma amostra de cada HC podem ser vistos na Figura 43, é possível perceber que os sinais ocupam faixas muito próximas.

Figura 42 - Vetores de características para cada classes de hidrofobicidade utilizando a TRF 1D.



Fonte: autoria própria.

Figura 43 - Vetores de características para cada classes de hidrofobicidade utilizando a TRF 2D.




Fonte: autoria própria.

Na Figura 44, o mesmo gráfico da figura anterior é exibido em destaque, de modo que é possível visualizar que, tal qual no sinal proveniente da TRF unidimensional, os sinais de classes diferentes ocupam faixas de magnitudes ligeiramente diferentes, muito embora, essa faixa seja ligeiramente mais estreita. No mais, de modo similar ao que foi realizado com o sinal proveniente da TRF unidimensional, a classificação foi testada utilizando-se o sinal

normalizado através do valor máximo e através da área unitária sob curva, para investigar a influência dessa estratégia na classificação.

Figura 44 - Destaque na porção central dos Vetores de características para cada classe de hidrofobicidade utilizando a TRF 2D.



Fonte: autoria própria.

### 5.3.1 REDE NEURAL ARTIFICIAL

A fim de classificar os níveis de hidrofobicidade das amostras pertencentes ao banco compilado neste trabalho, foi treinada uma rede neural artificial (RNA) do tipo *multilayer perceptron* (MLP). Tal estrutura utiliza os coeficientes do vetor de frequência espacial extraído de cada imagem como parâmetros de entrada, conforme definido em subseção anterior.

No que tange ao algoritmo de minimização do erro quadrático por *backpropagation*, conforme citado na metodologia, foram testados quatro algoritmos diferentes:

- Gradiente Conjugado com Reinício Powell/Beale;
- Gradiente Conjugado Escalonado;
- Levenberg-Marquardt;
- Retropropagação Resiliente (*Resilient Backpropagation*).

Dentre essas rotinas, o algoritmo de Levenberg-Marquardt foi a função de treinamento que apresentou as melhores taxas de acerto. Porém, o custo computacional requerido foi consideravelmente superior às demais rotinas.

A partir da matriz de dados descrita anteriormente, foram testadas várias topologias a fim de determinar a que apresentasse a melhor taxa de acerto e o menor número de neurônios na camada oculta possível. Dentre as diversas topologias testadas, pode-se destacar as redes com 9, 12 e 15 neurônios na camada oculta que, sobre um universo de 10 treinamentos, utilizando o conjunto de vetores de características da TRF unidimensional normalizada pela área e com uma divisão de grupos conforme descrito anteriormente, obtiveram os resultados expostos na Tabela 5.

Tabela 5 - Taxa de acerto média para 10 treinamentos em uma rede com 9, 12 e 15 neurônios na camada oculta.

| <b>Neurônios na Camada Oculta</b> | <b>Taxa de Acerto Média (%)</b> |
|-----------------------------------|---------------------------------|
| 9                                 | 75,61                           |
| 12                                | 77,83                           |
| 15                                | 78,59                           |

Fonte: autoria própria.

Portanto, a topologia utilizando 9 neurônios na camada oculta obteve a menor taxa de acerto entre as estruturas descritas, enquanto a rede composta por 12 neurônios obteve uma taxa de acertos levemente superior, e a topologia que apresentou a melhor taxa de acerto média foi a que utiliza 15 neurônios na camada oculta. Foram avaliadas topologias contendo mais neurônios na camada oculta, bem como um maior número de camadas ocultas, porém, as respectivas taxas de acerto não apresentaram melhora significativa. Ademais, todo o processo de treinamento e classificação foi repetido 10 vezes, a fim de mitigar os efeitos do caráter aleatório intrínseco dessa etapa. Dessa maneira, foram geradas 10 Matrizes de Confusão (MC) resultantes de cada execução do processo de treinamento e classificação. A taxa de acerto final da rede considerada neste trabalho é a média da taxa de acerto indicado por cada MC em todas as execuções.

Definida a topologia da rede, a classificação utilizando os vetores de características propostos foram avaliados e comparados entre si. O resultado desta comparação é apresentado na Tabela 6, a partir da qual é perceptível que o melhor desempenho ocorreu utilizando a informação advinda da transformada unidimensional normalizada pela área. Apesar de a transformada unidimensional estar contida na transformada bidimensional, o resultado da classificação utilizando a informação proveniente da análise em uma dimensão foi superior à classificação considerando duas dimensões. Este fato pode ser atribuído à porção da informação selecionada da transformada 2D não representar o fenômeno tão bem quanto a avaliação unidimensional na horizontal e vertical de forma independente. A expectativa ao selecionar a

diagonal do primeiro e segundo quadrantes da transformada bidimensional da amostra era que essa porção do espectro fosse capaz de reter a informação característica da simetria, ou a falta dela, dos objetos da imagem e que o classificador pudesse adaptar-se às regularidades estatísticas dessas características.

Tabela 6 - Taxa de acerto média para 10 treinamentos utilizando diferentes vetores de características.

| <b>Vetor de Característica</b> | <b>Taxa de Acerto Média (%)</b> |
|--------------------------------|---------------------------------|
| TRF 1D Normalizada pela Área   | 78,59                           |
| TRF 1D Normalizada pelo Máx.   | 74,50                           |
| TRF 2D Normalizada pela Área   | 59,17                           |
| TRF 2D Normalizada pelo Máx.   | 59,05                           |

Fonte: autoria própria.

Ademais, na Tabela 7 é representado o somatório das 10 MC resultantes da classificação dos vetores de características provenientes da TRF unidimensional das 180 amostras do grupo de teste utilizando 15 neurônios na camada oculta. É possível notar ainda que a rede obteve resultados satisfatórios ao realizar a classificação das amostras, principalmente nas amostras pertencentes às classes HC1 e HC2. Nas classes HC3 e HC4, apesar da taxa de acerto também satisfatória, houve uma dispersão da classificação das amostras nas classes adjacentes, o que é esperado em problemas desse tipo.

Tabela 7 - Representação das 10 MC do método proposto sobre 180 amostras do grupo de Teste.

|            | <b>HC1</b> | <b>HC2</b> | <b>HC3</b> | <b>HC4</b> | <b>HC5</b> | <b>HC6</b> | <b>Acertos (%)</b> |
|------------|------------|------------|------------|------------|------------|------------|--------------------|
| <b>HC1</b> | 314        | 2          | 0          | 0          | 0          | 0          | 99,37              |
| <b>HC2</b> | 3          | 255        | 22         | 4          | 0          | 0          | 89,79              |
| <b>HC3</b> | 6          | 43         | 222        | 15         | 0          | 11         | 74,75              |
| <b>HC4</b> | 0          | 0          | 27         | 217        | 26         | 30         | 72,33              |
| <b>HC5</b> | 1          | 0          | 3          | 36         | 176        | 85         | 58,47              |
| <b>HC6</b> | 0          | 0          | 0          | 17         | 53         | 232        | 76,82              |

Fonte: autoria própria.

Ainda sobre a Tabela 7, é possível inferir que os níveis HC5 e 6 foram os que obtiveram as menores taxas de acerto, no caso do nível HC5 houve uma dispersão considerável nas classes adjacentes, enquanto o maior número de classificações equivocadas das amostras da classe HC6 foi no nível HC5.

Por fim, visando traçar um paralelo com as condições operacionais do isolamento do equipamento, conforme exposto no capítulo anterior, foi realizada uma classificação pela mesma rede utilizando como parâmetro de saída o que seria a condição do isolamento, caracterizando-o em “Bom”, correspondente às classes HC1 e HC2, “Aceitável”, em

correspondências às classes HC3 e HC4, e “Ruim”, agrupando as classes HC5 e HC6. Os resultados dessa classificação obtiveram uma taxa de acerto média de aproximadamente 90,3% e um desvio padrão de 2,29% ao longo de 10 execuções. Na Tabela 8 estão organizados os valores das 10 MC resultantes dessa classificação.

Tabela 8 - Representação das 10 MC do método proposto sobre o grupo de teste considerando níveis arbitrários.

|                  | <b>Bom</b> | <b>Aceitável</b> | <b>Ruim</b> | <b>Acertos (%)</b> |
|------------------|------------|------------------|-------------|--------------------|
| <b>Bom</b>       | 546        | 47               | 0           | 92,07%             |
| <b>Aceitável</b> | 28         | 504              | 63          | 84,71%             |
| <b>Ruim</b>      | 1          | 35               | 576         | 94,12%             |

Fonte: autoria própria.

### 5.3.2 AVALIAÇÃO DA CLASSIFICAÇÃO

Os resultados obtidos através da aplicação do método de classificação proposto foram confrontados com outros trabalhos da literatura que se propõem a abordar o mesmo problema. Dentre as diversas referências citadas durante a revisão bibliográfica, os métodos apresentados por Alves (2018) e Yang *et al.* (2018), foram os que obtiveram os melhores resultados no âmbito de utilização de RNA para classificar imagens de hidrofobicidade em isoladores e, portanto, foram estes métodos os que foram considerados nesta análise comparativa.

É necessário ressaltar, no entanto, que o trabalho desenvolvido por Kokalis *et al.* (2020) apresentou resultados melhores que ambas as referências supracitadas, superando inclusive a metodologia proposta no presente trabalho. Porém, a classificação realizada faz uso de Redes Neurais Convolucionais, que, conforme relatado pelos autores, possui uma demanda computacional muito grande, acima da requerida pelos demais métodos apresentados nesta pesquisa. Dessa forma, é necessário um *hardware* muito mais robusto para sua implementação, o que inviabilizaria seu uso em dispositivos móveis. Além do exposto, esse tipo de rede necessita de um número de amostras consideravelmente maior na etapa de treinamento, visto que no trabalho de Kokalis *et al.* (2020) foram utilizadas 2.800 amostras no treinamento, enquanto esta pesquisa utilizou apenas 840 amostras nesta etapa. Isso pode ser atribuído ao fato de que as RNC utilizadas não realizaram a extração de características previamente determinadas, sendo portanto necessário um grande número de amostras para que a rede pudesse adequar-se às regularidades estatísticas de cada classe durante o treinamento. Em contrapartida, determinar características de interesse previamente e expor esse conhecimento à rede, reduz consideravelmente o número de amostras necessárias para modelar o fenômeno e, por conseguinte, para a etapa de treinamento.

Desse modo, seguindo o que fora expresso nos objetivos deste trabalho no tocante a desenvolver uma metodologia de classificação com baixa demanda computacional, visando posterior adaptação dos algoritmos para dispositivos portáteis, o método apresentado por Kokalis *et al.* (2020) não será levado em consideração nesta comparação.

No que tange à taxa de acerto das rotinas analisadas, o método proposto foi superior aos outros dois, atingindo uma taxa de acerto de 78,58% na média de 10 treinamentos e classificações e um desvio padrão de aproximadamente 2,04% neste cenário, seguido pelo método proposto por Alves (2018) com uma taxa de acerto média igual a 75,83% e desvio padrão de 1,46% para o mesmo número de treinamentos e classificações. Por fim, o método de Yang *et al.* (2018) apresentou a menor taxa de acerto média sob as mesmas condições que os anteriores, atingindo 74,66% de acerto e desvio padrão de 2,89% nas classificações realizadas (ALVES, 2018; YANG, BI, *et al.*, 2018).

O tempo de processamento computacional necessário para gerar as matrizes de dados utilizadas nas etapas de treinamento, teste e validação de cada uma das RNA também foi analisado. Para tal foi utilizado um mesmo computador, conforme descrito na metodologia, para realizar todas as análises e, desse modo, estimar de modo mais isonômico a demanda computacional de cada método. Os resultados agrupados na Tabela 9 deixam claro a baixa demanda computacional requerida pelo método proposto na geração do vetor de frequência, sendo necessário apenas 7,77 segundos para processar todas as 1200 amostras do banco de imagens. Seguindo a mesma linha, os métodos de Alves (2018) e Yang *et al.* (2018) necessitaram, respectivamente, de 26,40 e 28,61 segundos para extrair seus parâmetros e gerar a matriz de dados utilizada nas etapas seguintes da classificação (ALVES, 2018; YANG, BI, *et al.*, 2018).

Tabela 9 - Tempo de processamento de 1200 amostras para geração das entradas para RNA.

| <b>Método</b>             | <b>Tempo de Processamento (s)</b> |
|---------------------------|-----------------------------------|
| Alves (2018)              | 26,40                             |
| Yang <i>et al.</i> (2018) | 28,61                             |
| Método Proposto           | 7,77                              |

Fonte: autoria própria.

Por fim, a Tabela 10 e a Tabela 11 representam o somatório das 10 MC provenientes dos treinamentos e classificações realizados seguindo os métodos propostos por Alves (2018) e Yang *et al.* (2018), respectivamente. Observando a Tabela 10, é visível o melhor desempenho do método de Alves (2018) ao classificar as amostras pertencentes à classe HC1, porém, o desempenho foi inferior na classificação dos demais níveis, sobretudo no que tange à classe

HC5, onde 104 amostras foram classificadas erroneamente no nível HC6, num universo de 297 amostras ao longo das 10 repetições (ALVES, 2018; YANG, BI, *et al.*, 2018).

Tabela 10 - Representação das 10 MC – Método de Alves (2018).

|     | HC1 | HC2 | HC3 | HC4 | HC5 | HC6 | Acertos (%) |
|-----|-----|-----|-----|-----|-----|-----|-------------|
| HC1 | 291 | 4   | 1   | 0   | 0   | 0   | 98,31       |
| HC2 | 6   | 253 | 35  | 12  | 0   | 0   | 82,68       |
| HC3 | 0   | 44  | 211 | 25  | 9   | 1   | 72,76       |
| HC4 | 0   | 10  | 40  | 213 | 27  | 23  | 68,05       |
| HC5 | 0   | 0   | 3   | 28  | 162 | 104 | 54,55       |
| HC6 | 0   | 0   | 3   | 8   | 52  | 235 | 78,86       |

Fonte: autoria própria.

Já os resultados da classificação do método desenvolvido por Yang *et al.* (2018), demonstrados na Tabela 11, permitem concluir que, de forma similar aos resultados da implementação de Alves (2018), o método em questão atingiu uma taxa de acertos satisfatória para a classe HC1. Mas essa taxa declinou consideravelmente nos níveis superiores. Ao ponto de mais da metade das amostras da classe HC5 ser classificada de forma incorreta (ALVES, 2018; YANG, BI, *et al.*, 2018).

Tabela 11 - Representação das 10 MC – Método de Yang *et al.* (2018).

|     | HC1 | HC2 | HC3 | HC4 | HC5 | HC6 | Acertos (%) |
|-----|-----|-----|-----|-----|-----|-----|-------------|
| HC1 | 302 | 6   | 0   | 0   | 0   | 0   | 98,05       |
| HC2 | 7   | 250 | 35  | 6   | 0   | 1   | 83,61       |
| HC3 | 0   | 42  | 206 | 35  | 6   | 4   | 70,31       |
| HC4 | 0   | 6   | 42  | 189 | 17  | 25  | 67,74       |
| HC5 | 0   | 1   | 4   | 38  | 137 | 127 | 44,63       |
| HC6 | 1   | 0   | 1   | 10  | 42  | 260 | 82,80       |

Fonte: autoria própria.

Ademais, tal qual o método proposto, as rotinas de Alves (2018) e Yang *et al.* (2018) também foram avaliadas na classificação do estado da hidrofobicidade de superfície em níveis arbitrários, conforme resultados apresentados através da Tabela 12 e da Tabela 13. Nesse cenário, o procedimento de Alves (2018) obteve uma taxa de acerto média de aproximadamente 87,67% ao longo de 10 classificações e treinamentos independentes, com um desvio padrão de aproximadamente 1,88%. Ao passo que a rotina de Yang *et al.* (2018) atingiu uma taxa média de acerto de 87,06% e um desvio padrão de 3,98% no mesmo cenário.

Tabela 12 - Representação das 10 MC do método de Alves (2018) sobre o grupo de teste considerando níveis arbitrários.

|                  | <b>Bom</b> | <b>Aceitável</b> | <b>Ruim</b> | <b>Acertos (%)</b> |
|------------------|------------|------------------|-------------|--------------------|
| <b>Bom</b>       | 572        | 55               | 0           | 91,23%             |
| <b>Aceitável</b> | 52         | 445              | 60          | 79,89%             |
| <b>Ruim</b>      | 0          | 50               | 566         | 91,88%             |

Fonte: autoria própria.

Tabela 13 - Representação das 10 MC do método de Yang *et al.* (2018) sobre o grupo de teste considerando níveis arbitrários.

|                  | <b>Bom</b> | <b>Aceitável</b> | <b>Ruim</b> | <b>Acertos (%)</b> |
|------------------|------------|------------------|-------------|--------------------|
| <b>Bom</b>       | 548        | 55               | 0           | 90,88%             |
| <b>Aceitável</b> | 41         | 469              | 82          | 79,22%             |
| <b>Ruim</b>      | 0          | 54               | 551         | 91,07%             |

Fonte: autoria própria.

Posto isto, é possível afirmar que a metodologia proposta no presente trabalho obteve resultados superiores aos demais métodos analisados. Tais resultados compreendem, além do tempo de processamento computacional bastante inferior, uma taxa de acerto média superior e valores de dispersão pequenos considerando os cenários de classificação tanto nas classes padronizadas de acordo com o STRI, quanto em classes arbitrárias.

## 5.4 AVALIAÇÃO DA METODOLOGIA EM CASO REAL

A metodologia desenvolvida foi aplicada na avaliação da hidrofobicidade de superfície de uma coluna isolante desenergizada que se encontra instalada na subestação da Termelétrica Porto de Sergipe I, de propriedade das Centrais Elétricas de Sergipe (CELSE). Trata-se de uma subestação classe 500 kV, localizada a aproximadamente 1,5 km da linha d'água da costa marítima sergipana, no município da Barra dos Coqueiros.

Foram capturadas imagens do equipamento a partir de vários ângulos diferentes, segundo o método de pulverização recomendado pelo STRI. Amostras das imagens capturadas, que possuem uma resolução de  $3024 \times 4032$ , e podem ser vistas na Figura 45.

Figura 45 - Fotos capturadas de coluna isolante em campo.



(a)



(b)



(c)




(d)

Fonte: autoria própria.

Na sequência, foi recortada de cada imagem uma área de aproximadamente  $512 \times 512$  *pixels* que representasse o estado da hidrofobicidade do isolamento para ser utilizada no processo de classificação. Desta forma, cada amostra apresenta apenas gotas e fundo, e são descartadas informações geométricas do equipamento. As imagens recortadas podem ser vistas na Figura 46.


Figura 46 - Amostras da hidrofobicidade de superfície da coluna isolante.



Fonte: autoria própria.

As amostras de hidrofobicidade de superfície foram então segmentadas de acordo com o método proposto. O resultado pode ser visto na Figura 47, em que é perceptível que o algoritmo desenvolvido foi capaz de segmentar imagens provenientes de um ambiente de campo com sucesso.

Figura 47 - Amostras de hidrofobicidade de superfície da coluna isolante após segmentação.



Fonte: autoria própria.

Analisando as amostras de forma subjetiva, conforme dita o método do STRI, é possível perceber que, ao comparar as amostras (a) e (d), que são visualmente próximas uma da outra, seria sensato classificar a amostra (d) como pertencente ao nível HC1, visto que a mesma é predominantemente populada por pequenas gotas circulares e uniformes em sua maioria, espaçadas umas das outras. Já a amostra (a) possui gotas maiores, quando comparadas à amostra (d), porém mais próximas umas das outras e com formato ainda circular, mas nem sempre. Logo, uma classificação adequada para a amostra (a) seria HC2.

No tocante à amostra (b), é visível que o tamanho das gotas é relativamente maior quando comparado às demais, além de estar presente no canto superior esquerdo um canal por onde a água escorreu sobre a superfície, características adequadas para a classe HC4. Por fim,

a amostra (c) possui gotas grandes, quando comparada às amostras (a) e (d), mas não tão volumosas quanto as da amostra (b). O formato das gotas já não é mais tão uniforme ou circular e não há sinais de canais de água, nem a formação de áreas cobertas, logo uma classe apropriada para essa amostra seria a HC3. É preciso observar também que, mesmo todas as amostras sendo provenientes de um mesmo equipamento, foram constatadas áreas com níveis de hidrofobicidade diferentes. Isso pode ser atribuído ao fato de o envelhecimento da superfície não ser uniforme ao longo do comprimento do isolador e, portanto, podem surgir áreas com níveis de hidrofobicidade diferentes devido à exposição constante ao sol de uma porção em particular da isolação, ou ao vento mais pronunciado em uma determinada direção ao longo do ano, aliada à deposição de poluição. Este último sendo fator crítico para o caso analisado devido à proximidade da subestação à costa marítima que causa uma forte presença de deposição salina sobre os equipamentos.

No mais, considerando que o método pretende avaliar o estado do isolamento do equipamento e, considerando ainda que a norma IEC TS 62073:2016 não deixa claro qual a classe de hidrofobicidade definitiva quando o isolamento de um mesmo equipamento apresenta áreas com níveis de hidrofobicidade distintos, optou-se por adotar como nível determinante do estado do isolamento aquele de menor hidrofobicidade. Visto que, a existência de áreas do isolamento com hidrofobicidade inferior ao restante do isolamento irá ocasionar um maior depósito de água naquela região em particular que, por sua vez, irá intensificar a corrente de fuga de superfície.

Na sequência, após a segmentação, a imagem foi classificada através da rede neural artificial treinada para reconhecer os vetores de características baseadas na TRF unidimensional das linhas e colunas. A rede classificou as amostras da Figura 47 com a confiabilidade demonstrada na Tabela 14. Desse modo, percebe-se que a rede classificou as amostras (a) e (c) como pertencentes à classe HC3 com uma confiança de 91,86% e 95,36%, respectivamente. Enquanto para a amostra (b) foi atribuída a classe HC4 com uma confiança de 62,42%. Já a amostra (d) foi classificada como pertencente ao nível HC1 com uma confiança de 85,18%. Salienta-se ainda que, apesar de a imagem (d) estar desfocada, o método de segmentação proposto foi capaz de conservar as principais características da imagem e a rotina de classificação conseguiu indicar a classe com uma boa confiabilidade.

Assim, comparando a análise subjetiva das amostras com a classificação realizada pela RNA utilizando o método desenvolvido neste trabalho, a rede foi capaz de acertar a classificação de 3 dentre quatro amostras. No mais, o erro na classificação da amostra (a) pode ser considerado conservador, visto que a rede apontou para uma classe adjacente e com nível

de hidrofobicidade inferior à classe considerada correta. Caso a rede indicasse uma classe com hidrofobicidade superior à classificação subjetiva, implicaria em um falso negativo, que é um erro operacionalmente mais grave. Outra possibilidade ainda é que a classificação subjetiva esteja incorreta e, portanto, a rede teria acertado a classificação das quatro amostras. De todo modo, do ponto de vista operacional, a norma IEC TS 62073:2016 permite a divergência na classificação de uma classe de hidrofobicidade para mais ou para menos.

Tabela 14 - Confiabilidade da RNA na classificação das amostras nos 6 níveis de hidrofobicidade.

|                       | <b>Amostra (a)</b> | <b>Amostra (b)</b> | <b>Amostra (c)</b> | <b>Amostra (d)</b> |
|-----------------------|--------------------|--------------------|--------------------|--------------------|
| <b>HC1</b>            | 2,79%              | 0,01%              | 0,01%              | 85,18%             |
| <b>HC2</b>            | 4,44%              | 0,03%              | 0,82%              | 8,89%              |
| <b>HC3</b>            | 91,86%             | 10,35%             | 95,36%             | 4,18%              |
| <b>HC4</b>            | 0,67%              | 62,42%             | 3,40%              | 1,69%              |
| <b>HC5</b>            | 0,23%              | 25,22%             | 0,40%              | 0,06%              |
| <b>HC6</b>            | 0,00%              | 1,96%              | 0,01%              | 0,00%              |
| <b>CS<sup>2</sup></b> | HC2                | HC4                | HC3                | HC1                |

Fonte: autoria própria.

Levando em consideração ainda a avaliação do estado da superfície nos níveis “bom”, “aceitável” ou “ruim”, os vetores característicos foram propagados através da RNA e os resultados da avaliação estão detalhados na Tabela 15. É possível perceber, portanto, que para 3 dentre as quatro amostras, a rede classificou o estado da hidrofobicidade de superfície como “aceitável” com uma confiabilidade superior a 94% e classificou o estado da amostra (d), definida anteriormente como pertencente à classe HC1, como “bom” com uma confiabilidade superior a 99%. No mais, conforme definido previamente, o estado da hidrofobicidade considerado determinante será aquele de menor hidrofobicidade, portanto, pode-se afirmar que a hidrofobicidade de superfície do equipamento analisado é aceitável, do ponto de vista operacional.

Tabela 15 - Confiabilidade da RNA na classificação das amostras nos três níveis operacionais.

|                  | <b>Amostra (a)</b> | <b>Amostra (b)</b> | <b>Amostra (c)</b> | <b>Amostra (d)</b> |
|------------------|--------------------|--------------------|--------------------|--------------------|
| <b>Bom</b>       | 4,41%              | 0,03%              | 0,51%              | 99,28%             |
| <b>Aceitável</b> | 94,87%             | 94,11%             | 99,08%             | 0,70%              |
| <b>Ruim</b>      | 0,72%              | 5,86%              | 0,42%              | 0,02%              |

Fonte: autoria própria.

<sup>2</sup> CS – Classificação Subjetiva de acordo com o método do STRI.

## 5.5 ACHADOS PÓS-DEFESA

Após a defesa do presente trabalho, realizada no dia 29 de agosto de 2022, fruto dos comentários e considerações apresentadas pela banca avaliadora, surgiram achados relevantes no âmbito da pesquisa. O mais proeminente destes achados, refere-se à influência da rotina de pré-processamento e segmentação na classificação das amostras utilizando o classificador proposto.

Seguindo essa linha de investigação, foi realizada a extração de características de frequência através da TDF unidimensional, conforme descrito nas seções anteriores, sobre as amostras em tons de cinza originais, sem a aplicação de qualquer forma de segmentação ou pré-processamento, exceto a conversão do espaço RGB para tons de cinza. Desse modo, obteve-se uma taxa de acerto do classificador superior à encontrada utilizando-se as rotinas de pré-processamento, cerca de 83% com desvio padrão de aproximadamente 3,19%, conforme explicitado através da Tabela 16.

Tabela 16 - Representação das 10 MC – Método proposto sem pré-processamento.

|     | HC1 | HC2 | HC3 | HC4 | HC5 | HC6 | Acertos (%) |
|-----|-----|-----|-----|-----|-----|-----|-------------|
| HC1 | 298 | 3   | 0   | 0   | 1   | 0   | 98,68       |
| HC2 | 11  | 260 | 40  | 4   | 0   | 0   | 82,54       |
| HC3 | 0   | 26  | 225 | 27  | 9   | 1   | 78,13       |
| HC4 | 0   | 6   | 33  | 249 | 14  | 0   | 82,45       |
| HC5 | 0   | 1   | 1   | 20  | 211 | 62  | 71,53       |
| HC6 | 0   | 0   | 0   | 5   | 42  | 251 | 84,23       |


Fonte: autoria própria.

Quando comparado aos resultados obtidos sobre a classificação das amostras submetidas à rotina de pré-processamento, conforme apresentado anteriormente na Tabela 7, é possível perceber que a classificação realizada sobre as amostras originais obteve uma taxa de acerto superior em todos os níveis superiores ao HC2. A diferença acentua-se, principalmente, nos níveis HC5 e HC6, onde a classificação das amostras originais obteve taxa de acertos superiores a 71% e a 84%, respectivamente. Em contrapartida, a classificação das amostras pré-processadas obteve taxas de acerto próximas a 58%, para classe HC5, e 76% para a classe HC6. Apontando, portanto, uma melhora significativa nas taxas de acerto para as classes mais altas, ao se aplicar o método de classificação diretamente sobre as amostras em tons de cinza.

Essa melhora na classificação pode ser justificada ao analisar os gráficos da Figura 48 e da Figura 49, que representam a média dos vetores de características de 50 amostras de cada classe selecionadas de forma aleatória. É possível perceber, portanto, que a magnitude do sinal

na Figura 48, apesar de ser inicialmente maior em comparação à Figura 49, decai rapidamente, de modo que na faixa de frequências superiores a 80 u.a. a magnitude é mantida quase que constante.


Figura 48 - Média dos vetores de características de 50 amostras de cada classes submetidas a pré-processamento.



Fonte: autoria própria.

Já através da análise do gráfico na Figura 49, percebe-se que apesar da magnitude inicial dos vetores de características ser menor que no caso anterior, existe uma maior distribuição do espectro ao longo de todo intervalo. Este fenômeno pode ser atribuído à maior quantidade de informações disponíveis nas imagens originais, visto que os valores dos pixels estão entre 0 e 255 e não apenas limitados a um extremo no outro, como no caso anterior, o que realçaria as diferenças entre as classes e, por conseguinte, auxiliaria a rede neural no processo de classificação.


Figura 49 - Média dos vetores de características de 50 amostras originais de cada classes.



Fonte: autoria própria.

Ademais, o fluxograma da Figura 50 apresenta a nova metodologia proposta frente aos achados descritos nesta seção. O que torna, portanto, o método desenvolvido mais compacto, com reduzido esforço computacional e mais robusto quando comparado tanto à abordagem anterior, quanto às demais abordagens da literatura apresentadas previamente. Visto que, a dispensa de um método de segmentação aliada à possibilidade de classificação de amostras obtidas sob condições de iluminação uniforme e não-uniforme agregam grande vantagem à metodologia apresentada, sobretudo da ótica da implementação em dispositivos móveis e portáteis, que possuem capacidade de processamento reduzida.

Figura 50 - Fluxograma da metodologia desenvolvida desconsiderando a etapa de pré-processamento.



Fonte: autoria própria.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi desenvolvida e aplicada uma metodologia para segmentação, extração de características e classificação de imagens de hidrofobicidade de superfície de isoladores poliméricos.

Desse modo, foi desenvolvida uma metodologia capaz de segmentar imagens contendo padrões de hidrofobicidade em condições de iluminação adversas e realizar sua posterior classificação em níveis de hidrofobicidade padronizados. Para isso, foi construída uma base de dados estruturada com diversos níveis de hidrofobicidade sob condições de iluminação equilibradas e adversas, sobre a qual os métodos desenvolvidos foram testados e validados. Também foram desenvolvidas rotinas capazes de extrair parâmetros e características das amostras da base de dados no domínio da frequência que foram posteriormente utilizadas como atributos para classificação automática das amostras nas classes de hidrofobicidade, conforme definido pelo STRI.

A rotina de processamento digital de imagem desenvolvida com o objetivo de segmentar as amostras de hidrofobicidade de superfície obteve êxito na tarefa de compensar o efeito de iluminação adversa e desequilibrada, comumente presente em imagens capturadas em ambientes abertos. Sendo evidenciado através do resultado da segmentação de imagens contaminadas por gradiente de iluminação que, quando submetidas à rotina proposta, puderam ser separadas entre fundo e objetos de modo que a forma e tamanho das regiões de interesse foi preservada. O método foi comparado com outra abordagem da literatura, onde ficou evidente que a rotina proposta foi capaz de segmentar de forma satisfatória as amostras de HC mais baixos, enquanto o outro método obteve resultados melhores nos HC intermediários. Apesar de não obter uma segmentação perfeita de amostras da classe HC6, o método proposto foi capaz de reter uma quantidade maior de informação durante o processo de segmentação, quando comparado aos resultados obtidos na aplicação do outro método proposto na literatura. No entanto a segmentação de amostras de nível HC6 se mostrou desafiadora, visto que essa classe

é caracterizada por grandes regiões de tons uniformes, bordas fracas entre objeto e fundo e contraste muito baixo.

Na análise das características do domínio da frequência extraídos das amostras, ficou claro que a utilização da Transformada Rápida de Fourier unidimensional nas linhas e nas colunas obteve uma melhor representatividade do fenômeno quando comparada à utilização das diagonais do 1º e 2º quadrantes da TRF bidimensional. Esse fato ficou evidente devido à maior taxa de acerto da rede neural na classificação das imagens do banco usando o vetor de características proveniente da TRF unidimensional e pode ser atribuído à porção do espectro bidimensional selecionada ser incapaz de reter a informação característica do fenômeno, mais precisamente, da simetria, ou a falta dela, dos objetos da imagem. A avaliação de quais porções do espectro bidimensional que poderiam resultar em uma melhora na classificação das amostras não foi aprofundada neste trabalho, mas é um tópico relevante que pode ser abordado em trabalhos futuros.

No tangente à classificação da base de imagens produzida, o método proposto foi comparado a outras duas abordagens propostas na literatura, tendo obtido resultados ligeiramente superiores aos demais, por volta de 78,58%, com um desvio padrão de 2,04%, na média de 10 treinamentos e classificações, seguido por uma taxa de acerto de 75,83% e desvio padrão de 1,46% no método proposto por Alves (2018) e 74,66% de taxa de acerto com desvio de 2,89% nos testes realizados com a abordagem proposta por Yang *et al.* (2018). Note-se que, apesar dos trabalhos dos outros autores apresentarem resultados superiores em suas respectivas publicações, entre 85 e 98%, os resultados coletados nessa pesquisa estão bastante abaixo do esperado. Isso pode ser atribuído ao fato de que a base de dados construída neste trabalho possui imagens com iluminação uniforme e não-uniforme, além de não ter sido utilizado corante no líquido de aspersão, o que pode tornar essa base mais difícil de classificar que as bases originais em que esses métodos foram testados. No entanto, como as três abordagens foram avaliadas sob as imagens já segmentadas, após a correção da iluminação e do gradiente de fundo, a isonomia do estudo foi preservada.

Foi verificada também a viabilidade do método ao classificar a hidrofobicidade de superfície do isolador em 3 classes arbitrárias, que agrupando dois níveis de hidrofobicidade em cada uma, com a finalidade de oferecer ao operador uma informação mais objetiva da condição geral do isolamento. Nesse cenário, os níveis HC1 e HC2 corresponderiam a um isolamento em boas condições, já os níveis HC3 e 4 seriam característicos de um isolamento em condições aceitáveis e os níveis HC5 e 6 seriam atribuídos a isolamentos em condição ruim. Assim, o método proposto obteve uma taxa de acerto de 90,3% e um desvio padrão de 2,29%

na média de 10 treinamentos, ao classificar as amostras em “Bom”, “Aceitável” ou “Ruim”. A mesma análise foi aplicada aos métodos propostos por Alves (2018) e Yang *et al.* (2018), obtendo uma taxa de acerto média de aproximadamente 87,67% ao longo de 10 classificações e treinamentos independentes, com um desvio padrão de aproximadamente 1,88% para o primeiro caso. Ao passo que a rotina de Yang *et al.* (2018) atingiu um taxa média de acerto de 87,06% e um desvio padrão de 3,98% no mesmo cenário.

No mais, a metodologia proposta foi avaliada na segmentação e classificação de imagens de uma coluna isolante colhida no ambiente de uma subestação de 500 kV localizada a menos de 1,5 km da linha d’água da costa marítima. A rotina proposta foi capaz de segmentar as imagens de forma apropriada e classificar 3 dentre 4 amostras nas classes de hidrofobicidade corretas. Também foi analisada a classificação nas três classes simplificadas: “Bom”; “Aceitável” e “Ruim”. Em que todas as 4 amostras foram classificadas corretamente, sendo 3 amostras apontadas como em condições aceitáveis e a quarta amostra em boas condições.

Por fim, fruto dos comentários e considerações apresentadas pela banca avaliadora no momento da defesa deste trabalho, surgiram achados relevantes no âmbito da pesquisa. Destacando-se, portanto, a avaliação da técnica de classificação desenvolvida aplicada somente às imagens originais, omitindo-se as etapas de pré-processamento e segmentação. Na ocasião, observou-se uma taxa de acerto de cerca de 83% com desvio padrão de aproximadamente 3,19%, melhorando significativamente a taxa de acerto na classificação das amostras dos HC5 e 6 quando comparada ao resultado da classificação das amostras que passaram pelo processo de segmentação. Este achado torna o método proposto independente de uma etapa de segmentação e, portanto, contribui para torná-lo mais simples, reduzindo a carga computacional, facilitando sua implementação futura em dispositivos móveis de reduzida capacidade de processamento.

No tocante aos trabalhos futuros, sugere-se:

- Desenvolver um banco de dados de hidrofobicidade de isoladores de campo sujeitos à degradação natural;
- Avaliação de outras porções do espectro da transformada discreta de Fourier em duas dimensões que possam ser utilizadas na classificação;
- Testar a robustez do método de classificação proposto utilizando uma base de imagens que utilize corante na captura, facilitando o processo de segmentação;

- Associar a medição de hidrofobicidade a outras técnicas de monitoramento, tais como a medição de radiação infravermelha, radiação ultravioleta, poluição e corrente de fuga;
- Testar o desempenho do método proposto em um banco classificado previamente por profissionais experientes no método de classificação segundo o STRI;
- Desenvolver um sistema otimizado e automatizado para classificação da hidrofobicidade em isoladores em campo capaz de ser embarcado em dispositivo móvel do tipo *smartphone* ou *tablet*, podendo capturar e processar a imagem de forma rápida e eficiente. Este ponto já em andamento, encontrando-se a ferramenta, no momento da apresentação deste trabalho, já em processo de solicitação de registro de *software*.

## PUBLICAÇÕES

Durante a elaboração desta dissertação foi publicado o seguinte artigo científico:

- MACEDO, M. S.; FERREIRA, T. V.; DOS SANTOS, A. C. **Image Segmentation Method for Unbalanced Background in Water Droplets Based on Discrete Cosine Transform and Morphological Processing**. In 2021 Electrical Insulation Conference (EIC 2021). Virtual Event: [s.n.]. 2021.

## REFERÊNCIAS

- ALVES, L. N. T. *et al.* **Electrical Insulators Hydrophobicity Classification using Digital Image Processing**. 20th Int. Symp. on High Voltage Engineering. Buenos Aires: [s.n.]. 2017.
- ALVES, L. N. T. **Classificação da Hidrofobicidade em Isoladores Elétricos Utilizando Processamento Digital de Imagem, Modelo Probabilístico e RNA**. Dissertação. Universidade Federal de Campina Grande. Campina Grande. 2018.
- AMIN, M.; AKBAR, M.; AMIN, S. Hydrophobicity of silicone rubber used for outdoor insulation (an overview). **Rev. Adv. Mater. Sci.**, v. 16, p. 10–26, 2007.
- BAPTISTELLA, M. **O uso de redes neurais e regressão linear múltipla na engenharia de avaliações: determinação dos valores venais de imóveis urbanos**. Dissertação. Universidade Federal do Paraná. Curitiba. 2005.
- BERG, M.; THOTTAPPILLIL, R.; SCUKA, V. Hydrophobicity Estimation of HV Polymeric Insulating Materials. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 8, n. 6, p. 1098-1107, Dez. 2001.
- BRADLEY, D.; ROTH, GERHARD. Adaptive Thresholding using the Integral Image. **Journal of Graphics Tools**, v. 12, n. 2, p. 13-21, Jan. 2007.
- CHAGAS, T. S. A. **Identificação de Distúrbios em Sistemas de Distribuição Exclusivamente Baseada nos Sinais de Corrente**. Dissertação. Universidade Federal de Sergipe. São Cristóvão. 2020.
- CHEN, L. C.; CHIEN, C. H.; NGUYEN, X. L. An effective image segmentation method for noisy low-contrast unbalanced background in Mura defects using balanced discrete-cosine-transfer (BDCT). **Precision Engineering**, v. 37, n. 2, p. 336-344, 2013.
- CHEN, L. C.; KUO, C. C. Automatic TFT-LCD mura defect inspection using discrete cosine transform-based background filtering and 'just noticeable difference' quantification strategies. **Measurement Science and Technology**, v. 19, n. 1, p. 10, 2008.
- CHEN, X. *et al.* **On-line Estimating the Level of Hydrophobicity of Composite Insulators Using the Digital Images**. Electrical Insulation Conference and Electrical Manufacturing Expo. Indianapolis: IEEE. 2005. p. 216-221.
- DAVSON, H.; PERKINS, E. S. human eye | Britannica. **Encyclopedia Britannica**, 2021. Disponível em: <https://www.britannica.com/science/human-eye>. Acesso em: 08 Agosto 2022.
- DONG, Z. *et al.* Hydrophobicity classification of polymeric insulators based on embedded methods. **Materials Research**, v. 18, n. 1, p. 127–137, 2015.
- ESQUEF, I. A.; ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. **Processamento Digital de Imagens**. Centro Brasileiro de Pesquisas Físicas. Rio de Janeiro, p. 12. 2003.
- FERREIRA, T. V. **Estudo do Trilhamento de Núcleo em Isoladores Poliméricos**. Dissertação de Mestrado. Universidade Federal de Campina Grande. Campina Grande. 2007.
- FERREIRA, T. V. **Estimação Inteligente da Poluição de Isolamentos Elétricos Baseada nos VECSE do Ruído Ultrassônico**. Tese de Doutorado. Universidade Federal de Campina Grande. Campina Grande. 2011.

- FERREIRA, T. V.; GERMANO, A. D.; DA COSTA, E. G. Ultrasound and Artificial Intelligence Applied to the Pollution Estimation in Insulations. **IEEE Transactions on Power Delivery**, v. 27, n. 2, p. 583-589, Abr. 2012.
- FUKUSHIMA, K. Visual Feature Extraction by a Multilayered Network of Analog Threshold Elements. **IEEE Transactions on Systems Science and Cybernetics**, v. 5, n. 4, p. 322-333, Out. 1969.
- GODOY, J. **Estudo de um novo compósito madeira-resina poliuretana para o desenvolvimento de um isolador híbrido**. Dissertação. Universidade de São Paulo. São Carlos. 2007.
- GONZALEZ, R. C.; WOOD, R. C. **Processamento Digital de Imagens**. 3ª. ed. São Paulo: Pearson Prentice Hall, 2010.
- GORUR, R. S.; CHERNEY, E. A.; BURNHAM, J. T. **Outdoor Insulators**. 1ª. ed. Phoenix: Ravi S. Gorur, Inc., 1999.
- GUBANSKI, S. M. *et al.* Diagnostic Methods for Outdoor Polymeric Insulators. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 15, n. 5, p. 1065-1080, Out. 2007.
- HAYKIN, S. **Redes Neurais - Princípios e Prática**. 2ª. ed. Porto Alegre: Bookman, 2001.
- HAYKIN, S.; VAN VEEN, B. **Signals and Systems**. 2ª. ed. United States of America: John Wiley & Sons, Inc., 2003.
- IEC. **IEC TS 62073: Guidance on the measurement of wettability of insulator surface**. [S.l.]. 2016.
- IRUANSI, U.; TAPAMO, J. R.; DAVIDSON, I. E. **An active contour approach to water droplets segmentation from insulators**. 2016 IEEE International Conference on Industrial Technology (ICIT). Taipei: [s.n.]. 2016.
- JÄHNE, B. **Digital Image Processing: Concepts, algorithms and scientific applications**. 3ª. ed. Nova York: Springer-Verlag Berlin Heidelberg, 1995.
- JARRAR, I.; ASSALEH, K.; EL-HAG, A. H. Using a Pattern Recognition-Based Technique to Assess the Hydrophobicity Class of Silicone Rubber Materials. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 21, n. 6, p. 2611-2618, Dez. 2014.
- JAYABAL, R.; VIJAYAREKHA, K.; KUMAR, S. R. Design of ANFIS for Hydrophobicity Classification of Polymeric Insulators with Two-Stage Feature Reduction Technique and Its Field Deployment. **Energies**, v. 11, n. 12: 3391, 2018.
- JIA, Z.; GUAN, Z. **The Discharge along Hydrophobic and Hydrophilic Surfaces**. 2002 IEEE International Symposium on Electrical Insulation. Boston, MA: IEEE. 2002. p. 280-284.
- KHALAYLI, L. *et al.* **Automatic Inspection of Outdoor Insulators using Image Processing and Intelligent Techniques**. 2013 Electrical Insulation Conference. Ottawa: IEEE. 2013. p. 206-209.
- KIM, S. H.; CHERNEY, E. A. Effects of filler level in RTV silicone rubber coatings used in HV insulators. **IEEE Transactions on Electrical Insulation**, v. 27, n. 6, p. 1065-1072, Dez. 1992.
- KOKALIS, C. C. A. *et al.* Hydrophobicity classification of composite insulators based on convolutional neural networks. **Engineering Applications of Artificial Intelligence**, v. 91, p. 103613, 2020.

- LAW, K. Y. Definitions for Hydrophilicity, Hydrophobicity, and Superhydrophobicity: Getting the Basics Right. **The Journal of Physical Chemistry Letters**, v. 5, n. 4, p. 686-688, Feb. 2014.
- LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. **Quarterly of Applied Mathematics**, v. 2, n. 2, p. 164-168, 1944.
- LIANG, C.; YANG, W.; LIAO, Q. **Water droplets segmentation for hydrophobicity classification**. 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Kyoto: [s.n.]. 2012.
- LIDDELL, H. G. *et al.* **A Greek-English Lexicon**. 9<sup>a</sup>. ed. USA: Oxford University Press, 1996.
- LIPPMANN, R. P. An Introduction to Computing with Neural Nets. **IEEE ASSP Magazine**, v. 4, n. 2, p. 4-22, Abr. 1987.
- M MADE-IN-CHINA. GD-710 Composite Insulator Hydrophobic Properties Test Set - China Insulator Hydrophobic Properties Test Set, Insulator Hydrophobic Properties Test | Made-in-China.com. **Made-in-China.com - Manufacturers, Suppliers & Products in China**, 2022. Disponível em: <https://m.made-in-china.com/product/GD-710-Composite-Insulator-Hydrophobic-Properties-Test-Set-908544315.htm>. Acesso em: 18 setembro 2022.
- MACEDO, M. S.; FERREIRA, T. V.; DOS SANTOS, A. C. **Image Segmentation Method for Unbalanced Background in Water Droplets Based on Discrete Cosine Transform and Morphological Processing**. 2021 Electrical Insulation Conference (EIC 2021). Virtual Event: [s.n.]. 2021.
- MARQUARDT, D. W. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. **Journal of the Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431-441, 1963.
- MCCULLOCH, W.; PITTS, W. A Logical Calculus of Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.
- NAIR, V.; HINTON, G. E. **Rectified Linear Units Improve Restricted Boltzmann Machines**. 27th International Conference on Machine Learning (ICML). Haifa: [s.n.]. 2010. p. 807-814.
- OBDRZÁLEK, S.; MATAS, J. **Image retrieval using local compact DCT-based representation**. 25th Pattern Recognition Symposium (DAGM 2003). Berlin: [s.n.]. 2003. p. 490-497.
- OTSU, N. A Threshold Selection Method from Gray-Level Histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62-66, 1979.
- PIZER, S. M. *et al.* Adaptive Histogram Equalization and Its Variations. **Computer Vision, Graphics, and Image Processing**, v. 39, p. 355-368, 1987.
- ROCHA, E. O. **Análise das Inspeções de três linhas de transmissão 500 kVac: Um estudo de caso com foco em custos de manutenção e perda de receita**. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná. Medianeira. 2014.
- RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel Distributed Processing**: exploration in the microstructure of cognition. Cambridge: MIT Press, 1986.
- SEDIVER. **Sediver® toughened glass insulators for HVAC applications**. Catálogo do Fabricante. USA. 2020.

SILVA, I. N. *et al.* **Artificial Neural Networks - A Practical Course**. 1<sup>a</sup>. ed. [S.l.]: Springer Cham, 2017.

STRANG, G. Wavelets. **American Scientist**, v. 82, n. 3, p. 250-255, Mai.-Jun. 1994.

STRI. **Hydrophobicity Classification Guide - STRI Guide 92/1**. [S.l.]. 1992.

SUN, Q. *et al.* Estimation of the Hydrophobicity of a Composite Insulator Based on an Improved Probabilistic Neural Network. **Energies**, v. 11, n. 9: 2459, 2018.

THOMAZINI, D. **Classificação da Hidrofobicidade em Isoladores Elétricos Poliméricos de Alta Tensão**. Tese de Doutorado. Universidade de São Paulo. São Carlos. 2009.

THOMAZINI, D.; GELFUSO, M. V.; ALTAFIM, R. A. C. **Analysis of entropy and fractal dimension to classify the hydrophobicity in polymeric insulators**. 2008 International Symposium on Electrical Insulating Materials (ISEIM 2008). Mie: [s.n.]. 2008.

THOMAZINI, D.; GELFUSO, M. V.; ALTAFIM, R. A. C. Hydrophobicity classification of polymeric materials based on fractal dimension. **Materials Research**, v. 11, n. 4, p. 415-419, 2008.

THOMAZINI, D.; GELFUSO, M. V.; ALTAFIM, R. A. C. Classification of polymers insulators hydrophobicity based on digital image processing. **Materials Research**, v. 15, n. 3, p. 365-371, 2012.

TYAGI, V. **Understanding Digital Image Processing**. 1<sup>a</sup>. ed. Boca Raton: CRC Press, 2018.

WANG, Q. *et al.* **The Study of the Improved Multilayer Perceptron Algorithm on Hydrophobicity Detection Research of Composite Insulator Bushing**. 2016 6th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC). Hangzhou: IEEE. 2016. p. 438-441.

YANG, L. *et al.* A Recognition Method of the Hydrophobicity Class of Composite Insulators Based on Features Optimization and Experimental Verification. **Energies**, v. 11, n. 4: 765, 2018.


ZUIDERVELD, K. Contrast Limited Adaptive Histogram Equalization. In: HECKBERT, P. S. **Graphic Gems IV**. San Diego: Academic Press Professional, 1994. p. 474-485.

## APÊNDICE A – GUIA PARA CLASSIFICAÇÃO DO BANCO DE IMAGENS DE HIDROFOBICIDADE

O documento apresentado nesta seção foi enviado por e-mail aos alunos e voluntários que realizaram a pré-classificação do banco de imagens gerado neste trabalho. Junto a este documento, foi enviado também o acesso a uma pasta na nuvem contendo as imagens a serem classificadas, um formulário para registro que consistia de uma planilha do GSheets, além de material contendo exemplos de classificação, com o intuito de instruí-los no procedimento de acesso às amostras e na classificação.

### Guia para classificação do Banco de Imagens de Hidrofobicidade


Cada avaliador deverá abrir a planilha do GSheets (Google Planilhas) referente à sua parcela de classificação, a mesma será compartilhada por e-mail. A planilha é organizada conforme demonstrado abaixo:



Favor atentar-se se o nome que aparece no documento, no canto superior esquerdo, é o seu, para evitar que se classifique a parcela de outro avaliador. Nas primeiras células, um painel mostra permanentemente as seis classes que deverão ser utilizadas como parâmetro para classificação. Na parte inferior, na coluna A, estão os nomes de cada arquivo que o avaliador deverá classificar. Na coluna B, o avaliador deverá entrar com o número da classe à qual ele acredita pertencer a imagem especificada na coluna A.

As imagens que deverão ser classificadas encontram-se em uma pasta compartilhada com o nome de cada avaliador. Caso os arquivos não estejam organizados em ordem alfabética, organize-os para que a ordem coincida com a exibida na planilha.

Abra o primeiro arquivo e divida a tela entre a exibição da imagem e a planilha, conforme demonstrado na imagem a seguir:



Confira se o nome do arquivo exibido no visualizador de imagens coincide com o nome do arquivo na primeira linha da coluna A, no caso do exemplo, “Img (1).tif”. A seguir, basta comparar a imagem do banco com as imagens de referência da planilha e digitar na coluna B o valor da classe que o avaliador acredita pertencer a imagem exibida. Para esse exemplo, será a classe “1”. Portanto, basta digitar o número, conforme imagem abaixo:

|    |             |                                                                                    |                                                                                     |
|----|-------------|------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| 13 |             |  |  |
| 14 |             | HC 4                                                                               | HC 5                                                                                |
| 15 | IMAGEM      | CLASSE (1, 2, 3, 4, 5 ou 6)                                                        |                                                                                     |
| 16 | Img (1).tif |                                                                                    | 1                                                                                   |
| 17 | Img (2).tif |                                                                                    |                                                                                     |
| 18 | Img (3).tif |                                                                                    |                                                                                     |
| 19 | Img (4).tif |                                                                                    |                                                                                     |

Após finalizar, as alterações serão salvas automaticamente, caso haja acesso à internet.

Em caso de dúvida sobre a classificação, consultar o documento “STRI Classification Example.pdf” que estará dentro de cada pasta.

Muito obrigado pela colaboração de todos!!!

## APÊNDICE B – EXEMPLOS DE CLASSIFICAÇÃO STRI

O documento apresentado nesta seção foi enviado por e-mail aos alunos e voluntários que realizaram a pré-classificação do banco de imagens gerado neste trabalho. Junto a este documento, foi enviado também o acesso a uma pasta na nuvem contendo as imagens a serem classificadas, um formulário para registro que consistia de uma planilha do GSheets, além de material explicativo detalhando como fazer o acesso à pasta e como realizar o preenchimento do formulário, com o intuito de instruí-los no procedimento de acesso às amostras e na classificação.

### Exemplo de Classificação STRI

#### Hydrophobicity Class 1 - HC1





Imagem de Referência



Apenas gotas discretas, perfeitamente circulares em sua maioria e espaçadas entre si. Sem formação de regiões molhadas.

HC2





Imagem de Referência



Apenas gotas discretas, circulares ou com formado semicircular, porém sempre com bordas bem definidas e espaçadas entre si. Sem formação de regiões molhadas.

HC3







Imagem de Referência



Apenas gotas discretas, podem ser circulares ou não, em sua maioria as bordas são mais tênues e as gotas mais próximas entre si. Sem formação de regiões molhadas.

HC4





Imagem de Referência



Ambas, gotas e regiões molhadas são admitidas, as gotas apresentam-se bem próximas umas das outras e, juntas, gotas e áreas molhadas cobrem menos de 90% da área total.

HC5







Imagem de Referência



Muitas áreas molhadas presentes, poucas gotas, a soma das áreas molhadas cobrem menos de 90% da área de testes.

HC6






Imagem de Referência



Apenas áreas molhadas presentes, com pouquíssimas áreas secas, sendo que a área molhada total é superior a 90% da área testada.