



Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

LIDJA NAYARA TAVARES ALVES

CLASSIFICAÇÃO DA HIDROFOBICIDADE EM ISOLADORES ELÉTRICOS
EMPREGANDO O GUIA STRI E PROCESSAMENTO DIGITAL DE
IMAGEM

Campina Grande, Paraíba.
Julho de 2018



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

Classificação da Hidrofobicidade em Isoladores Elétricos Empregando o Guia STRI e Processamento Digital de Imagem

Lidja Nayara Tavares Alves

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia Elétrica.

Área de Concentração: Processamento de Energia

Prof. Edson Guedes da Costa
Prof. Tarso Vilela Ferreira
Orientadores

Campina Grande – PB
Julho – 2018

A474c

Alves, Lidja Nayara Tavares.

Classificação da hidrofobicidade em isoladores elétricos empregando o guia STRI e processamento digital de imagem / Lidja Nayara Tavares Alves. - Campina Grande, 2018.

88 f. : il. color.

Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2018.

"Orientação: Prof. Dr. Edson Guedes da Costa, Prof. Dr. Tarso Vilela Ferreira".

Referências.

1. Hidrofobicidade. 2. Isoladores. 3. Processamento Digital de Imagens. 4. Revestimento Polimérico. 5. Função de Densidade de Probabilidade. 6. Rede Neural Artificial. 7. STRI. I. Costa, Edson Guedes da. II. Ferreira, Tarso Vilela. III. Título.

CDU 621.315.61(043)

**"CLASSIFICAÇÃO DA HIDROFOBICIDADE EM ISOLADORES ELÉTRICOS
EMPREGANDO GUIADO STRI E PROCESSAMENTO DIGITAL DE IMAGEM"**

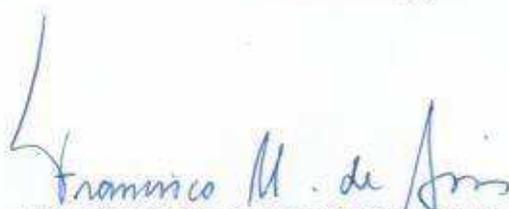
LIDJA NAYARA TAVARES ALVES

DISSERTAÇÃO APROVADA EM 01/08/2018



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

**TARSO VILELA FERREIRA, D.Sc., UFS
Orientador(a)**



**FRANCISCO MARCOS DE ASSIS, Dr., UFCG
Examinador(a)**



**ANDRÉ DANTAS GERMANO, Dr., UFCG
Examinador(a)**

CAMPINA GRANDE - PB

Dedico aos meus pais, Marcos Alves e Arizonete Alves.

AGRADECIMENTOS

Agradeço a Deus, por cada etapa vencida para chegar até aqui, nas quais Ele sempre esteve ao meu lado. Agradeço a Nossa Senhora, minha mãezinha, por todas as vezes que me colocou em seu colo e intercedeu por mim.

Aos meus pais, Marcos e Arizonete, por todo o esforço realizado na minha educação, pelos valores morais, pelo apoio e amor que sempre me dão. Simplesmente agradeço por ter pais incríveis.

Agradeço à minha irmã, Gabriella Alves por ser um exemplo de determinação e coragem.

Agradeço aos meus orientadores, Professor Edson Guedes e Professor Tarso Vilela, por todos os ensinamentos, pela paciência e por acreditarem no meu potencial.

Agradeço a Antonio Neto por todo apoio e ensinamento dado durante os últimos anos. Por ser um exemplo de foco, coragem e força.

Agradeço a todos os meus familiares, pelo carinho, estímulo e incentivo.

Agradeço a Raphael Borges por toda a ajuda durante a realização do ensaio em laboratório. Agradeço a Arthur Francisco por toda paciência e ensinamentos durante a execução probabilística desta dissertação. Agradeço a Reginaldo Grimaldi e Luiz Felipe Carneiro, alunos da UFS que colaboraram imensamente na realização do banco de dados deste trabalho.

Agradeço a todas as pessoas que se disponibilizaram a classificar imagens hidrofóbicas, sendo primordiais na execução da classificação automática da hidrofobicidade.

Agradeço aos mestres e funcionários do DEE-UFCG, dos quais levarei lições para a vida inteira, não apenas enquanto profissional, mas também como ser humano.

Aos técnicos do LAT por todo o suporte para a realização do ensaio. Em especial a Higor Rocha, por toda a assistência durante o mestrado.

Por fim, aos amigos que tanto compartilharam as diversas situações em minha vida ao longo dos anos.

RESUMO

O guia STRI (*Swedish Transmission Research Institute*) de hidrofobicidade classifica as superfícies de isoladores de acordo com o ângulo de contato e/ou a quantidade de superfície molhada com água de forma subjetiva (método de pulverização). Neste trabalho é proposta uma ferramenta para o monitoramento e classificação automática da hidrofobicidade dos isoladores poliméricos. Algoritmos computacionais foram desenvolvidos para segmentação e classificação de imagens hidrofóbicas utilizando Processamento Digital de Imagem (PDI), Função de Densidade de Probabilidade (FDP) e Rede Neural Artificial (RNA). A hidrofobicidade foi determinada utilizando parâmetros das imagens hidrofóbicas obtidas por meio do método de pulverização. Os parâmetros de classificação utilizados foram: quantidade de regiões molhadas; área individual máxima; área total das regiões molhadas; distância média e máxima entre as regiões molhadas; maior fator de forma; e excentricidade mínima e máxima. A partir dos resultados obtidos foi observada uma relação matemática entre alguns parâmetros e a hidrofobicidade, sendo possível definir a hidrofobicidade com um conjunto mínimo de parâmetros. A análise e classificação da hidrofobicidade foi realizada por meio da FDP e RNA. O desempenho foi avaliado em um conjunto de dados com mais de 450 imagens e obteve-se uma taxa de acerto de aproximadamente 87% com a RNA e de 80% por meio da análise de limiar proveniente da FDP.

Palavras-chave: Hidrofobicidade, isoladores, processamento digital de imagens, revestimento polimérico, função de densidade de probabilidade, rede neural artificial, STRI.

ABSTRACT

The Swedish Transmission Research Institute (STRI) guide classifies the surfaces of insulators according to the contact angle and / or amount of wetted surface with water subjectively (spray method). In this work a tool is proposed for the automatic monitoring and classification of the hydrophobicity of polymeric insulators. Computational algorithms for segmentation and classification of hydrophobic images using Digital Image Processing (DIP), Probabilistic Density Function (PDF) and Artificial Neural Network (ANN) were developed. Hydrophobicity was determined using parameters of the hydrophobic images obtained by means of the spray method. The classification parameters used were: quantity of wet regions; maximum individual area; total area of wet regions; average and maximum distance between wet regions; greater form factor; and minimum and maximum eccentricity. From the obtained results a mathematical relationship between some parameters and the hydrophobicity was observed, being possible to define the hydrophobicity with a minimum set of parameters. The analysis and classification of hydrophobicity was performed using PDF and ANN. The performance was evaluated in a dataset with more than 450 images and obtained an accuracy rate of approximately 87% with ANN and of 80% by means of threshold analysis from the PDF.

Keywords: Hydrophobicity, insulators, digital image processing, probability density function, artificial neural network, STRI.

LISTA DE ILUSTRAÇÕES

Figura 1. Os de isoladores para linhas de transmissão de energia: (a) isolador de vidro; (b) isolador de porcelana (c) isolador de compósito	17
Figura 2. Exemplos típicos de superfícies com HC 1-6 exposto no guia STRI	21
Figura 3. Etapas de um sistema de PDI e ADI	23
Figura 4. Representação de uma imagem digital bidimensional	25
Figura 5. Modelo de neurônio natural e artificial	32
Figura 6. Modelo artificial de neurônio biológico	33
Figura 7. Ilustração do hiperplano (aqui, uma reta) como fronteira de decisão para um problema de classificação linear de padrões bidimensional de duas classes.....	34
Figura 8. Arquitetura de uma rede MLP	35
Figura 9. Fotografia da placa com superfície polimérica.....	42
Figura 10. Sistema de iluminação com a amostra polimérica	43
Figura 11. Classificação HC1 (a) sem o corante e (b) com o corante.....	44
Figura 12. Modelo de planilha para classificação subjetiva em grupo	46
Figura 13. Fluxograma das rotinas do algoritmo.....	47
Figura 14. Diagrama de Dispersão do Número de Regiões Molhadas – HC1 - HC6.....	49
Figura 15. Diagrama de Dispersão da Área Máxima das Regiões Molhadas– HC1 - HC6	50
Figura 16. Diagrama de Dispersão da Área Total Molhada – HC1 - HC6	50
Figura 17. Diagrama de Dispersão da Distância Média entre as Regiões Molhadas – HC1 - HC6.....	50
Figura 18. Diagrama de Dispersão da Distância Máxima entre as Regiões Molhadas – HC1 - HC6.....	51
Figura 19. Gráfico de Dispersão do Fator de Forma Circular da Área Máxima – HC1 - HC6	51
Figura 20. Diagrama de Dispersão da Excentricidade Mínima – HC1 - HC6	51
Figura 21. Gráfico de Dispersão da Excentricidade Máxima – HC1 - HC6	52
Figura 22. Demonstração do limiar entre os níveis HC	55
Figura 23. Processamento de limiarização	57
Figura 24. Processamento da uniformização até a imagem final	57
Figura 25. Fluxograma do processamento de imagens para extração dos parâmetros – HC1	58
Figura 26. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC1	61
Figura 27. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC2	61
Figura 28. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC3	62
Figura 29. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC4	62
Figura 30. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC5	63
Figura 31. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC6	63
Figura 32. FDP Gama dos seis níveis de hidrofobicidade	67
Figura 33. FDA e complementar da FDA para os pares HC: (a) FDA da classe HC1 com complementar da FDA da classe HC2; (b) FDA da classe HC2 com complementar da	

FDA da classe HC3; (c) FDA da classe HC3 com complementar da FDA da classe HC4; (d) FDA da classe HC4 com complementar da FDA da classe HC5; (e) FDA da classe HC5 com complementar da FDA da classe HC6	67
Figura 34 Estrutura da RNA.....	71
Figura 35 Curva de Aprendizado para RNA com 12 neurônios.....	73
Figura 36. Curva de Aprendizado para RNA com 12 neurônios – 4 parâmetros de entrada.....	75

LISTA DE TABELAS

Quadro 1. Critérios para Classificação de Hidrofobicidade (HC).....	22
Tabela 2. Apresentação dos parâmetros de classificação e tomada de decisão artificial utilizadas.....	40
Tabela 3. Matriz de Correlação Linear	59
Tabela 4. Testes F para avaliar a inclusão de cada interação de 1ª ordem no modelo normal linear.....	60
Tabela 5. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC1.....	64
Tabela 6. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC2.....	64
Tabela 7. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC3.....	64
Tabela 8. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC4.....	64
Tabela 9. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC5.....	65
Tabela 10. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC6.....	65
Tabela 11. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC1.....	65
Tabela 12. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC2.....	65
Tabela 13. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC3.....	66
Tabela 14. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC4.....	66
Tabela 15. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC5.....	66
Tabela 16. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC6.....	66
Tabela 17. Taxa de acerto média das 10 MCs – RNA com 6, 9 e 12 neurônios na camada oculta	71
Tabela 18. Representação das 10 MCs – RNA com 6 neurônios na camada oculta e 68 amostras de teste	71
Tabela 19. Representação das 10 MCs – RNA com 9 neurônios na camada oculta e 68 amostras de teste	72
Tabela 20. Representação das 10 MCs – RNA com 12 neurônios na camada oculta e 68 amostras de teste	72
Tabela 21. Representação das 10 MCs – RNA com 6 neurônios na camada oculta e 68 amostras de teste	74

Tabela 22. Representação das 10 MCs – RNA com 9 neurônios na camada oculta e 68 amostras de teste	74
Tabela 23. Representação das 10 MCs – RNA com 12 neurônios na camada oculta e 68 amostras de teste	74

LISTA DE ABREVIATURAS

ADI	Análise Digital de Imagem
DSP	Digital Signal Processor
EPDM	Ethylene Propylene Diene Monomer (Monômero de Etileno Dieno Propileno)
FC	Fator Circular
FDA	Função de Distribuição Acumulada
FDP	Função de Densidade de Probabilidade
HC	Hydrophobicity Classification
IA	Inteligência Artificial
IEC	International Electrotechnical Commission
MLP	Multilayer Perceptron
MSE	Mean Squared Error
PDI	Processamento Digital de Imagem
RGB	Red Green Blue
RNA	Rede Neural Artificial
RTV	Room Temperature Vulcanization (Vulcanização à Temperatura Ambiente)
STRI	Swedish Transmission Research Institute
UV	Ultravioleta
WTH	White Top-Hat

SUMÁRIO

1	Introdução	14
1.1	Objetivos	16
1.2	Organização do Texto	16
2	Fundamentação Teórica.....	17
2.1	Isoladores	17
2.2	Isoladores e Hidrofobicidade no Setor Elétrico.....	18
2.3	Hidrofobicidade	19
2.4	Classificação da Hidrofobicidade	19
2.4.1	Método de Pulverização	20
2.5	Processamento Digital de Imagens.....	22
2.5.1	Imagem Digital	24
2.5.2	Segmentação	25
2.5.2.1	Limiarização.....	26
2.5.2.2	Detecção de Bordas	27
2.5.2.3	Segmentação Orientada a Regiões.....	27
2.5.3	Filtro Morfológico.....	27
2.6	Modelos Probabilístico	28
2.6.1	Distribuição Gama.....	28
2.6.2	Distribuição Normal.....	29
2.6.3	Distribuição Weibull	29
2.6.4	Teste de Aderência Qui-quadrado.....	30
2.7	Redes Neurais Artificiais	30
2.7.1	Neurônio Artificial	32
2.7.2	Rede <i>Perceptron</i> de Única Camada	34
2.7.3	Rede <i>Perceptron</i> de Múltiplas Camadas	34
3	Revisão Bibliográfica	37
4	Metodologia	42
4.1	Placas de Testes.....	42
4.2	Ensaio de Hidrofobicidade	43
4.2.1	Arranjo.....	43
4.2.2	Método de Pulverização	44
4.3	Banco de Imagens e Pré-Classificação das Imagens	45
4.4	Procedimento Computacional	47
4.4.1	Rotina de Limiarização.....	47

4.4.2	Rotina de Uniformização	48
4.4.3	Rotina de Binarização.....	48
4.4.4	Rotina de Rotulação e Extração de Parâmetros	48
4.5	Análise e Classificação dos Dados	49
4.5.1	Análise Linear – Método <i>Stepwise</i>	52
4.5.2	Análise Probabilística e Classificação.....	54
5	Resultados	56
5.1	Processamento Digital da Imagem	56
5.2	Análises e Classificação.....	59
5.2.1	Análise Linear	59
5.2.2	Análise Probabilística.....	60
5.2.3	Rede Neural Artificial com Oito Parâmetros de Entrada	70
5.2.4	Rede Neural Artificial com Parâmetros do Método <i>Stepwise</i>	73
6	Conclusão.....	77
7	Trabalhos Futuro	79
	Publicações.....	80
	Referências	81
	Apêndice A.....	86

1 INTRODUÇÃO

A transmissão de energia elétrica é, na grande maioria dos casos, realizada por meio de condutores metálicos que são suspensos em torres e conectados mediante o uso de isoladores elétricos, que devem possuir boas propriedades dielétricas e mecânicas ao longo da vida útil. As propriedades dielétricas devem garantir perdas baixas e isolamento elétrico entre a torre e os condutores energizados, enquanto as propriedades mecânicas, devem prover a sustentação mecânica dos condutores, em condições normais e anormais do sistema. Estas propriedades influenciam diretamente na confiabilidade do sistema elétrico.

Os isoladores aplicados ao sistema elétricos são cerâmicos (vidro e porcelana) e os poliméricos. Isoladores constituídos de materiais poliméricos vêm sendo amplamente utilizados no sistema elétrico por possuírem diversas vantagens, como por exemplo o melhor desempenho sob poluição, proporcionado devido à sua maior hidrofobicidade. Suas características hidrofóbicas evitam a formação de películas de água na superfície do isolador, retardando os efeitos das descargas superficiais quando inseridos em ambientes contendo alto nível de umidade e poluição. Todavia, apresentam a desvantagem de serem facilmente suscetíveis ao envelhecimento causado por fatores ambientais, tais como poluição, radiação ultravioleta (UV) e radiação infravermelho (IV), os quais degradam sua superfície, reduzindo sua hidrofobicidade.

Estudos mostram que as superfícies de isoladores de borracha de silicone e EPDM perdem sua hidrofobicidade inicial, tornando-se hidrofílicos, quando expostos a arcos de banda seca (BLACKMORE & BIRTWHISTLE, 1997; ALMIRALL, 2013). No entanto, a borracha de silicone pode restabelecer sua hidrofobicidade devido à migração de grupos hidrofóbicos para a superfície dos isoladores. A capacidade da borracha de silicone de restabelecer sua hidrofobicidade está diretamente ligada ao desempenho elétrico dos isoladores.

A depender das condições ambientais e do tempo de exposição, o efeito da poluição acentua a incidência de falhas nos isoladores. É sabido ainda que a deposição de partículas de poluição, entre outros efeitos: altera o campo elétrico ao longo do isolador; aumenta a corrente de fuga e conseqüentemente a elevação das perdas; promove a

formação de descargas internas e superficiais; satura a capacidade de restauração da hidrofobicidade; e pode promover o trilhamento e as fissuras nas saias e no revestimento do núcleo dos isoladores. Associados à presença de umidade, os efeitos são agravados.

Grande parte dos problemas detectados em isolamentos, como exposição do núcleo, descargas elétricas superficiais, trilhamento e as fissuras, acontece em decorrência da perda de hidrofobicidade. A identificação precoce da perda de hidrofobicidade pode evitar a ocorrência dos problemas, o que viabiliza seu uso como um parâmetro de monitoramento. A hidrofobicidade pode ser classificada utilizando Processamento Digital de Imagens (PDI), tomando como referência o guia do STRI (*Swedish Transmission Research Institute*) e o uso de inteligência artificial (ALVES, 2016).

O método proposto pelo guia do STRI permite a classificação da hidrofobicidade em laboratório a partir de procedimentos práticos e requer equipamentos de uso relativamente comum. Embora os resultados obtidos em laboratório tenham se mostrado satisfatórios, ainda não se dispõe de uma técnica totalmente aceita e aplicada pelas empresas do setor elétrico. Dois dos principais pontos de divergência na técnica são o elevado grau de subjetividade e a necessidade de retirada do isolador para realização do teste. O emprego do PDI, associado a técnicas de auxílio à tomada de decisão, pode reduzir o impacto destes pontos de divergência.

Por processamento digital de imagem (PDI) entende-se a manipulação de uma imagem por computador de modo que a entrada e a saída do processo sejam imagens. O objetivo de se usar essa técnica é melhorar o aspecto visual de certas características estruturais para o analista humano e fornecer outros subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a outros processamentos (SPRING, 1996). A função primordial do PDI é fornecer ferramentas para facilitar a identificação e a extração da informação contida nas imagens, para posterior interpretação. A interpretação dos dados pode ser realizada por diversas técnicas probabilísticas e da Inteligência Artificial (IA) disponíveis, dentre elas, as funções de densidade de probabilidade (FDP) e as Redes Neurais Artificiais (RNA).

Portanto, neste trabalho é apresentada uma ferramenta para o aprimoramento do método proposto pelo guia do STRI. No aprimoramento foram utilizadas técnicas de análise de imagens e classificação da hidrofobicidade por Processamento Digital de Imagem (PDI), Modelos Probabilísticos e Inteligência Artificial.

1.1 OBJETIVOS

O objetivo geral deste trabalho é estudar, desenvolver e propor ferramentas de classificação da hidrofobicidade de isoladores elétricos poliméricos de alta tensão, baseadas em processamento digital de imagens, para tanto foram aplicados modelos probabilísticos e inteligência artificial.

Para alcançar o objetivo principal foram estabelecidos os seguintes objetivos específicos:

- Avaliar a aplicabilidade da classificação da hidrofobicidade e do guia STRI;
- Constituir um banco de dados estruturado com diversas classes de hidrofobicidade classificadas por meio da metodologia subjetiva e do PDI;
- Desenvolver rotinas computacionais específicas para extração de parâmetros a partir das imagens do banco de dados;
- Desenvolver uma metodologia de tomada de decisão a partir de modelos de distribuição de probabilidade e RNA;
- Desenvolver uma ferramenta de diagnóstico automático da hidrofobicidade.

1.2 ORGANIZAÇÃO DO TEXTO

No Capítulo 2 são apresentados os fundamentos teóricos sobre isoladores elétricos, hidrofobicidade, técnicas de processamento digital de imagens, modelo de distribuição de probabilidade e por fim, redes neurais artificiais. No Capítulo 3 é exposta a revisão bibliográfica sobre pesquisas relacionadas à classificação da hidrofobicidade, por meio de técnicas de processamento digital de imagem e com referência ao método de pulverização presente no guia STRI. No Capítulo 4 é descrita a metodologia proposta, desde o arranjo para produção do banco de imagens até a classificação via RNA. No Capítulo 5 são apresentados e discutidos os resultados obtidos. No Capítulo 6 são apresentadas as conclusões e os potenciais trabalhos futuros para dar continuidade à pesquisa nesta área de estudo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ISOLADORES

Os isoladores elétricos, em geral, são utilizados no sistema elétrico de potência com a finalidade de realizar o isolamento elétrico entre cabos energizados e sua estrutura de suporte. Além de necessitar ser um excelente isolante, os isoladores elétricos devem prover a sustentação mecânica dos cabos entre duas estruturas.

Um isolador elétrico ideal comporta-se como um isolante sem perdas, garantindo uma isolação perfeita. Entretanto, em termos práticos, através do isolador circula uma parcela de corrente resistiva que é responsável por perdas de potência ativa, o que é indesejável considerando a finalidade do equipamento (BOGORODITSKY *et al.*, 1979).

Atualmente existem isoladores cerâmicos (porcelana ou vidro) e compósitos (ou poliméricos), que podem apresentar diferentes formatos e dimensões, de acordo com as tensões nominais das linhas de transmissão e distribuição nos quais são empregados. Os isoladores cerâmicos são empregados pelo setor elétrico há mais de um século, enquanto os compósitos começaram a ser utilizados no decênio de 1940 em ambientes fechados. Entretanto, apenas no início do decênio de 1980 surgiu a primeira versão comercial de isoladores poliméricos para linha de transmissão (HALL, 1993; MACKEV & SHAH, 1997). Na Figura 1 são mostradas fotos de isoladores de três tipos: vidro, porcelana e compósito.

Figura 1. Os de isoladores para linhas de transmissão de energia: (a) isolador de vidro; (b) isolador de porcelana (c) isolador de compósito.



Fonte: Adaptado de Silva, 2009.

A porcelana e o vidro são materiais inorgânicos bastante utilizados ao longo dos anos e conhecidos por serem resistentes à degradação natural, inertes para a maioria dos compostos químicos e possuem elevada resistência ao calor resultante de arcos elétricos durante serviço. No entanto, devido à elevada energia superficial, estes isoladores apresentam alto nível de molhabilidade, de maneira que a umidade tende a se espalhar ao longo da superfície ao invés de formar gotas isoladas, favorecendo o desenvolvimento de correntes de fuga. Além disso, são materiais densos e frágeis ao impacto, necessitando de estruturas mais reforçadas para comportá-los e estão sujeitos ao vandalismo (KIM *et al.*, 1992; GORUR *et al.*, 1999).

Os isoladores a base de polímeros são constituídos de materiais orgânicos, principalmente hidrocarbonetos. Estes possuem melhores características hidrofóbicas, são leves, menores, e possuem custos associados reduzidos quando comparados aos de porcelana e de vidro. No entanto, estão mais propensos à deterioração decorrente do aquecimento ocasionado por descargas elétricas, reações químicas e intempéries, podendo resultar em mudanças nas características elétricas e mecânicas irreversíveis ao longo do tempo (GORUR *et al.*, 1999).

2.2 ISOLADORES E HIDROFOBICIDADE NO SETOR ELÉTRICO

Nos últimos anos houve uma crescente demanda no consumo de energia elétrica, sucedendo a ampliação do sistema de geração, transmissão e distribuição de energia elétrica mundial. Em função do maior número de linhas de fornecimento de energia, a possibilidade da interrupção no sistema elétrico se torna cada vez maior, o que faz com que as companhias de energia elétrica busquem medidas para reduzir as interrupções do sistema elétrico. Um dos fatores que provocam a interrupção no fornecimento de energia elétrica está relacionado às falhas no isolamento elétrico, as descargas disruptivas. O desempenho dos isoladores elétricos é de fundamental importância em termos de qualidade do serviço, segurança e confiabilidade do sistema (GODOY, 2007; NERI *et al.*, 2005).

Com o passar do tempo algumas soluções vêm sendo adotadas para minimizar a ocorrência das descargas disruptivas. Neste contexto, a solução frequentemente aplicada é a inspeção e lavagem periódica dos isoladores para retirada dos depósitos de poluição de sua superfície. Além da inspeção e da lavagem periódica dos isoladores, estudos sobre

revestimentos superficiais, *design* das peças, composições químicas dos isoladores e diferentes geometrias disponíveis têm sido realizados com o propósito de avaliar e melhorar o desempenho dos isoladores (NOBREGA, 2016).

A fim de proporcionar maior resistência ao surgimento das descargas disruptivas os materiais poliméricos também têm sido utilizados no isolamento elétrico. Suas características hidrofóbicas evitam a formação de películas de água na superfície do isolador, fazendo com que a água permaneça em gotas separadas, umas das outras, por áreas secas (LIEBERMANN, 2002). Todavia os materiais poliméricos apresentam a desvantagem de serem facilmente suscetíveis ao envelhecimento por irradiação UV, a qual degrada sua superfície, reduzindo sua hidrofobicidade.

2.3 HIDROFOBICIDADE

A hidrofobicidade é uma propriedade físico-química utilizada em diferentes áreas da química, medicina e farmacologia. É um indicador importante do transporte e permeabilidade por meio de membranas, interações com receptores biológicos e enzimas, toxicidade e potencial biológico (LYMAN, 1990). Superfície hidrofóbica quando molhada, a água tende a formar gotas discretas, não se espalhando pela superfície. Superfície hidrofílica quando molhada, a água não é repelida pela superfície sendo formado um filme que a recobre (JIZ, 2002). No caso dos equipamentos elétricos, deseja-se uma superfície hidrofóbica, para que a água não seja um caminho de baixa resistência elétrica que provoque a ocorrência de descargas disruptivas.

A hidrofobicidade dos polímeros confere aos isoladores elétricos maiores níveis de suportabilidade elétrica. Assim podem ser produzidos dispositivos mais compactos e mais baratos, ao contrário de isolantes confeccionados com materiais hidrofílicos como vidro ou porcelana. Segundo o guia STRI, guia de classificação de hidrofobicidade em isoladores elétricos, pode ser observada a diferença de 30% na tensão de *flashover* sob chuva e 60% sob névoa limpa em isoladores de mesma geometria, diferindo apenas no material polimérico de recobrimento (THOMAZINI, 2009).

2.4 CLASSIFICAÇÃO DA HIDROFOBICIDADE

Segundo a norma internacional IEC 62073 TS Ed. 1.0 (guia para medida da molhabilidade da superfície de isoladores elétricos) existem três métodos para medição da hidrofobicidade, diferindo na exatidão, simplicidade, tamanho da área de superfície e aplicabilidade, são descritos neste padrão e são como se segue:

- O método de ângulo de contato;
- O método da tensão superficial;
- O método de pulverização.

Os três métodos são adequados para medição da molhabilidade em laboratório. Em campo, há dificuldades de se utilizar o método de ângulo de contato, enquanto que, os métodos de tensão superficial e pulverização são os mais indicados.

Devido ao método de pulverização possuir menor dificuldade de execução, muitas pesquisas na área de hidrofobicidade em isoladores elétricos utilizam a classificação da STRI como referência em seus estudos. Esta classificação é feita em sete divisões (HC1-HC7), onde HC1 corresponde à completa hidrofobicidade, ou seja, a superfície não é molhada pela água, e HC7 corresponde à completa hidrofiliabilidade, ou seja, a superfície é totalmente molhada pela água.

2.4.1 MÉTODO DE PULVERIZAÇÃO

O método de pulverização se baseia na resposta de molhabilidade que uma superfície irá proporcionar após exposição a uma fina névoa de água por um período curto, e então, a hidrofobicidade após a exposição à névoa é avaliada.

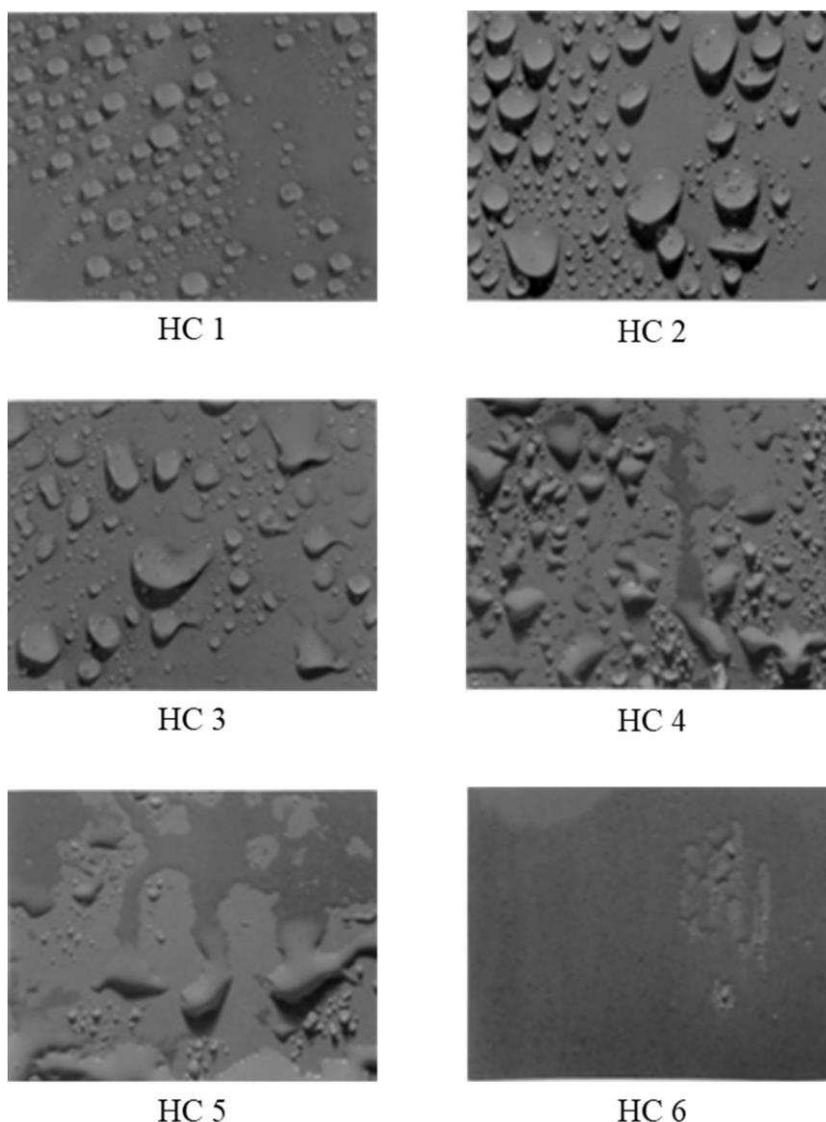
O único equipamento de teste necessário para a realização do ensaio da classificação da hidrofobicidade corresponde a um frasco de pulverização de líquidos (borrifador), o qual pode produzir uma fina névoa de água destilada.

A norma IEC 62073 e o guia STRI descrevem que a área de ensaio deve ser preferencialmente de 50 cm² a 100 cm². Caso esta exigência não possa ser cumprida, o descumprimento deve ser descrito no relatório de medição. A superfície deve ser exposta à névoa por um período de 20 s a 30 s, sendo a névoa aplicada a uma distância de 25 cm ± 10 cm. A quantidade de água pulverizada durante 20 s a 30 s, deve estar entre 10 ml e 30 ml. As medidas da molhabilidade devem ser executadas dentro de 10 s após a pulverização ter sido completada

A aparência da superfície do isolador após a exposição da névoa deve ser identificada como uma das sete classes de hidrofobicidade (HC1-HC7) contida no guia STRI. Na Figura 2 são mostradas imagens das classes de hidrofobicidade (HC1 a HC6). A classe HC7 não é disposta no guia STRI, mas corresponde a superfície completamente recoberta por uma película de água. Os critérios para as diferentes classes são dados no Quadro 1.

Segundo o guia STRI a metodologia fornece valores discretos para o estado de molhagem das superfícies dos isoladores, sendo de verificação rápida e fácil nos isoladores em campo, porém depende da avaliação subjetiva do operador.

Figura 2. Exemplos típicos de superfícies com HC 1-6 exposto no guia STRI



Fonte: Adaptado do guia STRI, 1992.

Quadro 1. Critérios para Classificação de Hidrofobicidade (HC).

HC	Descrição
1	Formação de gotas discretas. $\theta_r \approx 80^\circ$ ou maior para a maioria das gotas.
2	Formação de gotas discretas. $50 < \theta_r < 80^\circ$ para a maioria das gotas.
3	Formação de gotas discretas. $20 < \theta_r < 50^\circ$ para a maioria das gotas. Normalmente não apresentam mais o formato circular.
4	Formação de gotas discretas e traços de água. Áreas completamente molhadas $< 2\text{cm}^2$. Área total molhada $< 90\%$ da área testada.
5	Algumas áreas completamente molhadas $> 2\text{cm}^2$, recobrindo $< 90\%$ da área testada.
6	Áreas molhadas recobrem $> 90\%$ da área testada, ou seja, pequenas áreas não molhadas são observadas.
7	Filme de água contínuo sobre toda a área testada.

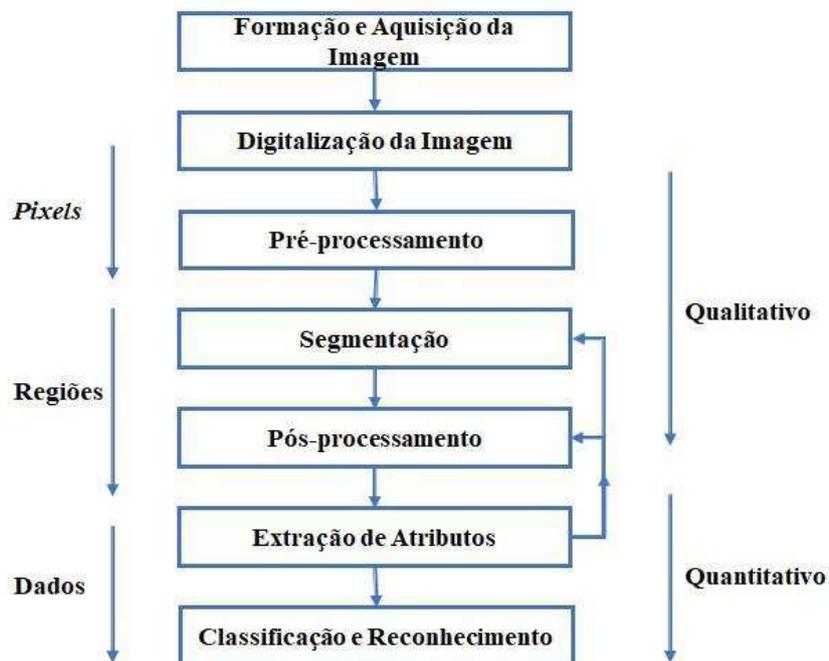
Fonte: Adaptado do guia STRI, 1992.

2.5 PROCESSAMENTO DIGITAL DE IMAGENS

O processamento de imagens tem como funções facilitar a visualização da imagem ou adequá-la para análises quantitativas por meio de correções de defeitos ou realces das regiões de interesse nas imagens; e a extração e tratamento de dados quantitativos, feitos pelo próprio computador (GOMES, 2001). Conforme as diferentes funções citadas, o processamento de imagens pode ser entendido como o conjunto de duas técnicas, a saber: (a) Processamento Digital de Imagens (PDI), que consiste no preparo da imagem para posteriores análises, em que são realizadas operações matemáticas que alteram os valores dos pixels; e (b) Análise Digital de Imagens (ADI), que compreende a análise quantitativa do processo a partir da qual as regiões, partículas e objetos identificados na imagem são medidos.

Conforme Esquef e Albuquerque (2003), o processamento de imagens digitais passa por várias etapas, as quais diferem um pouco para cada grupo de estudo, essas etapas consistem em formação e aquisição da imagem, digitalização, pré-processamento, segmentação, pós-processamento, extração de atributos e classificação e reconhecimento. Na Figura 3 pode-se ser visualizado o fluxograma contendo todas as etapas e algumas características de cada fase do processamento.

Figura 3. Etapas de um sistema de PDI e ADI.



Fonte: Adaptado de Esquef e Albuquerque, 2003.

As etapas de segmentação, pré-processamento e pós-processamento fazem parte do PDI, enquanto as etapas de extração de atributos e reconhecimento de padrões e classificação fazem parte da ADI. Vale ressaltar que a sequência é adaptativa para o problema envolvido, ou seja, não há a obrigação de todas as etapas serem realizadas e, além disso, o fluxograma poderá retroceder a qualquer outra etapa, caso o resultado obtido não seja satisfatório.

A formação e aquisição da imagem é a etapa onde é feita sua captura, ou seja, a aquisição dos dados referentes à imagem. Posteriormente é realizada a digitalização, onde os dados da imagem serão convertidos em sinais elétricos inteligíveis ao computador.

No pré-processamento, são feitas alterações em atributos da imagem como contraste, e ainda podem ter alguns filtros, que usam máscaras específicas para alteração de valores dos *pixels* da matriz que representa a imagem digital.

A segmentação acontece quando são particionadas, ou separadas, partes ou objetos constituintes da imagem que terão alguma utilidade. Os objetos a serem destacados da imagem são grupos de *pixels* com determinadas características próprias.

No pós-processamento são corrigidos eventuais defeitos da segmentação. Para tal, utilizam-se normalmente filtros matemáticos chamados de morfológicos que realizam uma análise quantitativa dos *pixels* da imagem.

Para a etapa da extração de atributos, são extraídas as informações úteis da imagem processada. Em tal etapa, acontece a chamada rotulação. Após a segmentação, obtém-se uma imagem onde as regiões correspondentes aos “objetos” estão separadas daquelas correspondentes ao “fundo” da imagem. Neste ponto do sistema de processamento, as regiões de interesse estão agrupadas por *pixels* que se tocam. O próximo passo é dar um rótulo (*label*) para cada um desses grupos de *pixels*. O processo de segmentação separa as regiões pertencentes às células daquelas pertencentes às regiões entre células (fundo), criando um delimitador entre elas. A etapa de rotulação cria um endereço que identifica cada uma dessas regiões para que os processos seguintes de tratamento da informação sejam concentrados em cada uma das regiões que receberam um rótulo (SILVA, 2009).

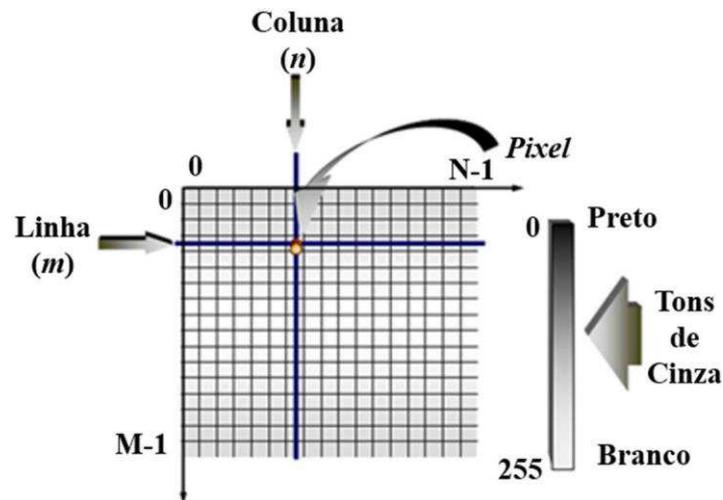
2.5.1 IMAGEM DIGITAL

Uma imagem de um objeto real é, em princípio, contínua tanto na sua variação espacial como nos níveis de cinza. Visando o seu processamento computacional a imagem deve ser digitalizada, ou seja, discretizada tanto no espaço quanto na amplitude. A digitalização das coordenadas espaciais é chamada amostragem da imagem e a digitalização da amplitude é chamada de quantização dos níveis de cinza (BRITO & CARVALHO, 1998).

Uma imagem monocromática é uma função bidimensional contínua $f(x,y)$, na qual x e y são coordenadas espaciais e o valor de f em qualquer ponto (x,y) é proporcional à intensidade luminosa (brilho ou nível de cinza) no ponto considerado (QUEIROZ & GOMES, 2001). Como os computadores não são capazes de processar imagens contínuas, mas apenas matrizes de números digitais, é necessário representar imagens como arranjos bidimensionais de pontos.

Cada ponto na grade bidimensional que representa a imagem digital é denominado elemento de imagem ou *pixel*. Na Figura 4, apresenta-se a notação matricial usual para a localização de um *pixel* no arranjo de *pixels* de uma imagem bidimensional. O primeiro índice denota a posição da linha, m , na qual o *pixel* se encontra, enquanto o segundo, n , denota a posição da coluna. Observa-se o sentido de leitura (varredura) e a convenção usualmente adotada na representação espacial de uma imagem digital.

Figura 4. Representação de uma imagem digital bidimensional.



Fonte: Adaptado de Queiroz e Gomes, 2001.

A intensidade luminosa no ponto (x,y) pode ser decomposta em: (i) componente de iluminação, $i(x,y)$, associada à quantidade de luz incidente sobre o ponto (x,y) ; e a componente de refletância, $r(x,y)$, associada à quantidade de luz refletida pelo ponto (x,y) (GONZALEZ, 2002). O produto de $i(x,y)$ e $r(x,y)$ resulta em:

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

em que $0 < i(x,y) < \infty$ e $0 < r(x,y) < 1$. Sendo que, $i(x,y)$ depende das características da fonte de iluminação, enquanto $r(x,y)$ depende das características das superfícies dos objetos.

Em uma imagem digital colorida no sistema *RGB* (*Red, Green, Blue*), um *pixel* pode ser visto como um vetor cujas componentes representam as intensidades de vermelho, verde e azul de sua cor. A imagem colorida pode ser vista como a composição de três imagens monocromáticas, conforme (2).

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

2.5.2 SEGMENTAÇÃO

O processo de segmentação tem por objetivo particionar a imagem de modo que seja possível explicitar suas regiões de interesse, agrupando seus *pixels* de forma que eles se destaquem dos demais.

As dificuldades inerentes ao processo de segmentação automática de imagens existem e por isso deve-se considerar que as fronteiras ou bordas das regiões possam não ser muito nítidas e são muitas vezes irregulares e imprecisas. Na segmentação em larga escala, especialmente por processos automáticos, existe uma grande necessidade de controlar o ambiente de captura. Ambientes bem controlados, com grandes contrastes, tendem a facilitar a interpretação de imagens. Ambientes externos, em geral, apresentam mais dificuldades, pois estão sujeitos à variação de iluminação. Além disso, a existência de sombras ou movimento muda os aspectos da região e tende a dar uma falsa impressão acerca da região a ser segmentada (MELO, 2005).

Existem inúmeras maneiras de segmentar uma imagem, sendo que cada técnica é escolhida de acordo com o problema a ser resolvido. A segmentação pode ser baseada nas discontinuidades ou nas similaridades dos diferentes aspectos da imagem, em limites ou bordas e em áreas ou regiões. Dentre as diversas técnicas de segmentação de imagem destaca-se a limiarização, a detecção de bordas e a segmentação orientada a regiões.

2.5.2.1 LIMIAZIZAÇÃO

A limiarização é uma abordagem para a segmentação fundamentada na análise da similaridade de níveis de cinza, de modo a extrair objetos de interesse mediante a definição de um limiar T que separa os agrupamentos de níveis de cinza da imagem.

Essa operação é relevante quando a imagem apresenta duas classes: o fundo e o objeto. Se a intensidade dos valores dos *pixels* do objeto encontra-se em um intervalo diferente do fundo, uma imagem binária pode ser obtida por meio de uma operação de limiarização (*thresholding*) que agrupa os pontos do primeiro intervalo com o valor 1 e os demais com valor 0, assim, os *pixels* que possuem valores maiores que um determinado tom é considerado objeto e os *pixels* que possuem valores menores que este tom é considerado fundo (AURA CONCI & LETA, 2008)

Há diversas variantes de limiarização. A mais simples delas é a técnica do particionamento do histograma da imagem por um limiar único T . A segmentação se dá varrendo-se a imagem, *pixel a pixel*, e rotulando-se cada *pixel* como sendo do objeto ou do fundo, em função da relação entre o valor do *pixel* e o valor do limiar. O sucesso do método depende inteiramente de quão bem definidas estão os valores de intensidade dos *pixels* no histograma da imagem a ser segmentada (QUEIROZ & GOMES, 2001).

2.5.2.2 DETECÇÃO DE BORDAS

A detecção de bordas possibilita a análise de discontinuidades nos níveis de cinza de uma imagem. As bordas na imagem de interesse caracterizam os contornos dos objetos nela presentes, sendo bastante úteis para a segmentação e identificação de objetos na cena.

O processo de detecção de bordas consiste na verificação da variação dos valores de luminosidade de uma imagem visando localizar e realçar os pixels de borda, por meio da ampliação do contraste entre esta e o fundo. Um procedimento básico utilizado na detecção de bordas é a diferenciação da imagem. Sua utilização, entretanto, causa a detecção de bordas relevantes e irrelevantes.

2.5.2.3 SEGMENTAÇÃO ORIENTADA A REGIÕES

A segmentação orientada a regiões se fundamenta na similaridade dos níveis de cinza da imagem. O crescimento de regiões é um procedimento que agrupa *pixels* ou sub-regiões de uma imagem em regiões maiores. A variante mais simples da segmentação orientada a regiões é a agregação de *pixels*, que se fundamenta na definição de uma semente, conjunto de pontos similares em valor de cinza, a partir do qual crescem as regiões anexando a cada ponto semente os *pixels* que apresentem propriedades similares (nível de cinza, textura ou cor).

2.5.3 FILTRO MORFOLÓGICO

O modelo morfológico para a análise de imagens fundamenta-se na extração de informações a partir de transformações morfológicas, nos conceitos da álgebra booleana e na teoria dos conjuntos e reticulados. O princípio de morfologia digital se embasa no fato de que a imagem é um conjunto de pontos elementares (*pixels* ou *voxels*) que formam subconjuntos elementares bidimensionais ou tridimensionais. Os subconjuntos e a inter-relação entre eles formam estruturalmente a morfologia da imagem (QUEIROZ & GOMES, 2001).

A técnica da morfologia matemática dispõe de duas operações básicas: a erosão e a dilatação. A operação de erosão permite separar objetos que se tocam, enquanto a operação de dilatação permite preencher furos no interior de um objeto ou mesmo ligá-los. Como as duas operações são interativas, é possível realizar uma sequência de N

operações de erosão e dilatação sucessivas ou mesmo alternadas. A operação de abertura, uma erosão seguida de uma dilatação, permite eliminar pequenas partículas na imagem e suavizar o contorno dos objetos. Inversamente, a operação de fechamento, uma dilatação seguida de uma erosão, permite fechar canais estreitos que separam objetos, ou suprimir os pequenos furos no seu interior.

2.6 MODELOS PROBABILÍSTICO

Os modelos podem ser considerados como uma representação da realidade em estudo, servindo para simplificar, descrever e interpretar aquilo que se está estudando. Destarte, um modelo probabilístico é uma representação matemática deduzida de um conjunto de premissas com o duplo propósito de estudar os resultados de um experimento aleatório e prever o seu comportamento futuro, quando este se realiza sob as mesmas condições, dadas inicialmente (CORDEIRO, 2005). Permite conhecer a distribuição de probabilidades que toma a variável aleatória, por meio de suas funções de probabilidade, densidade, distribuição e geração de momentos, além dos parâmetros de tendência, variabilidade, assimetria e curtose.

Segundo Catalunha *et al.* (2002), o uso de funções densidade de probabilidade está diretamente ligado à natureza dos dados a que elas se relacionam. Algumas têm boa capacidade de estimação para pequeno número de dados, outras requerem grande série de observações. Desde que respeitado o aspecto da representatividade dos dados, as estimativas dos seus parâmetros para uma determinada região podem ser estabelecidas como de uso geral, sem prejuízo da precisão na estimação da probabilidade.

As distribuições de probabilidade contínuas são bastante utilizadas em diversos trabalhos probabilísticos, devido ao ajustamento de suas variáveis, que pode até não ser perfeito, mas descrevem bem uma situação real, fornecendo respostas às hipóteses que podem ter sido levantadas na pesquisa. Nas subseções a seguir são apresentadas algumas das distribuições e o teste de aderência utilizados neste trabalho.

2.6.1 DISTRIBUIÇÃO GAMA

Uma variável aleatória x tem distribuição Gama quando sua função densidade de probabilidade para $x > 0$ é dada por:

$$f(x) = \frac{x^{\alpha-1} \exp(-x/\beta)}{\beta^\alpha \Gamma(\alpha)}, \quad (3)$$

sendo que $\alpha > 0$ é um parâmetro de forma, $\beta > 0$ é um parâmetro de escala e $\Gamma(\cdot)$ indica a função matemática gama, definida por:

$$\Gamma(\alpha) = \int_0^{\infty} x^{\alpha-1} \exp(-x) dx. \quad (4)$$

Devido a sua versatilidade, a gama é uma das distribuições mais utilizadas na estatística. Dependendo dos valores dos parâmetros esse modelo recebe nomes especiais. Para $\alpha = 1$, tem-se a distribuição exponencial. Caso $\alpha = n/2$ com n inteiro positivo e $\beta = 1/2$, tem-se o importante modelo qui-quadrado, com n graus de liberdade. Quando $\alpha = n$ com n inteiro positivo, a distribuição gama reduz-se ao modelo Erlang de ordem n (RODRIGUES, 2012).

2.6.2 DISTRIBUIÇÃO NORMAL

Uma variável aleatória contínua x tem distribuição Normal quando sua função densidade de probabilidade é dada por:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{1}{2\sigma^2} \left(\frac{x-\mu}{\sigma}\right)^2\right], \quad -\infty < x < +\infty \quad (5)$$

sendo μ a média e o σ desvio padrão da variável aleatória.

A média refere-se ao centro da distribuição e o desvio padrão ao espalhamento (ou achatamento) da curva. A distribuição Normal é simétrica em torno da média o que implica que a média, a mediana e a moda são todas coincidentes.

2.6.3 DISTRIBUIÇÃO WEIBULL

Uma variável aleatória x tem distribuição Weibull quando sua função densidade de probabilidade para $x > 0$ é dada por:

$$f(x) = \frac{\alpha \beta^\alpha x^{\alpha-1}}{\Gamma(\alpha)} \exp\left(-\beta x^\alpha\right), \quad (6)$$

sendo que $\alpha > 0$ é um parâmetro de forma e $\beta > 0$ é um parâmetro de escala.

A distribuição Weibull reduz-se a exponencial quando $\alpha = 1$ e quando $\alpha = 2$ é denominada distribuição Rayleigh (RODRIGUES, 2012).

2.6.4 TESTE DE ADERÊNCIA QUI-QUADRADO

O teste de aderência Qui-quadrado (χ^2) foi desenvolvido por Karl Pearson e completado por Ronald Fisher no início do século XX (STIGLER, 2011). O teste de aderência Qui-quadrado serve para testar a hipótese que as observações seguem uma determinada distribuição, discreta ou contínua, com ou sem parâmetros conhecidos. A hipótese de nulidade admite que a distribuição seja a especificada (Gama, Weibull, etc.), com os seus parâmetros estimados com base nos dados amostrais.

A hipótese é testada fazendo-se a comparação entre as frequências observadas e as frequências teóricas, em cada classe de frequência da amostra, com a variável aleatória do χ^2 e χ^2_{cr} (crítico), dada por Campos (1983) citado por Catalunha et al. (2002):

$$\chi^2 = \sum_{i=1}^k \frac{(F_{oi} - F_{ei})^2}{F_{ei}}, \quad (7)$$

em que k representa o número de classes; F_{oi} representa a frequência observada; e F_{ei} representa a frequência esperada, de acordo com a distribuição que está sendo testada.

O valor da estatística de teste é sempre positivo ou nulo. Caso seja nulo, significa que existe um ajuste perfeito. Analogamente, quanto maior o valor de χ^2 , maior será a sua diferença e menos a distribuição escolhida se adéqua à nossa amostra. Neste caso, deve ser estabelecer um limite de χ^2 para que seja possível afirmar que a distribuição escolhida se adéqua ou não à amostra. Os valores críticos do χ^2 para alguns níveis de significância são descritos por tabelas próprias.

2.7 REDES NEURAIIS ARTIFICIAIS

Dentre os mais antigos desejos do ser humano está o de reproduzir a funcionalidade do cérebro humano em uma máquina artificial. O cérebro, no seu contato com o mundo exterior, via órgãos sensoriais, procura realizar conexões entre os neurônios, com vistas a processar e selecionar as informações mais relevantes para o aprendizado humano. Este conhecimento é gerado por meio de um mecanismo de correção de erros, onde, a partir de experiências passadas, a ação humana vai sendo ou não modificada.

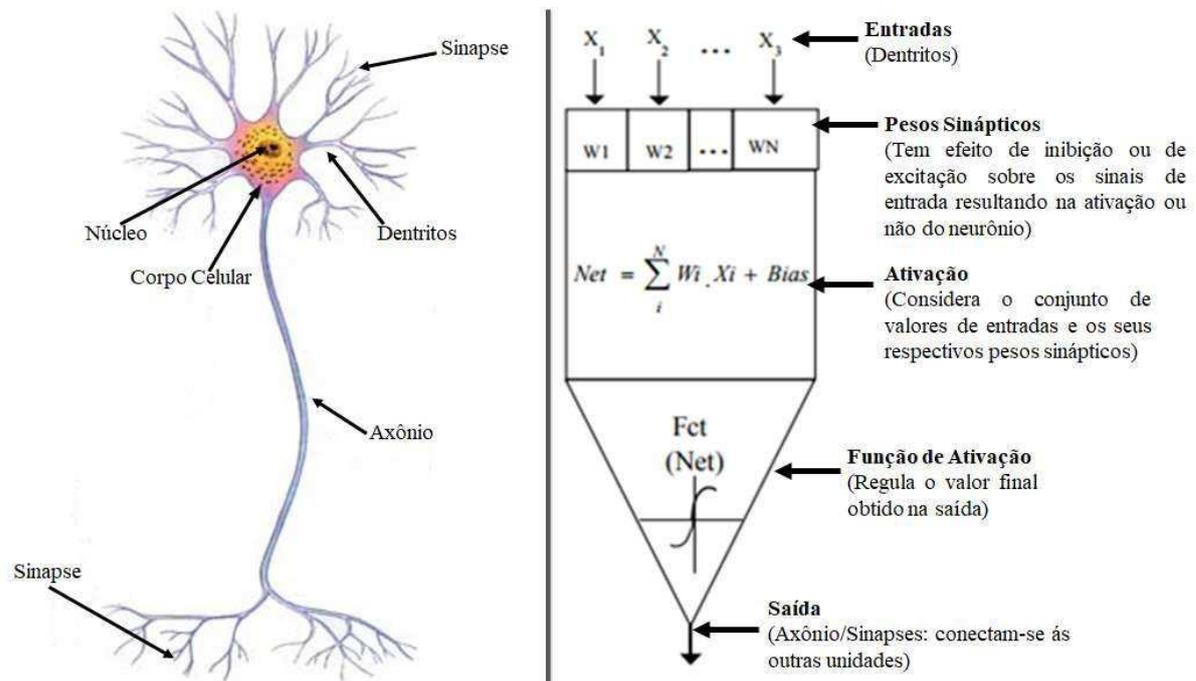
As Redes Neurais Artificiais (RNA), dentro deste mesmo princípio, procuram reproduzir a plasticidade cerebral, por meio da aplicação de algoritmos que, dentro do ambiente de um neurocomputador, visam aproximar funções e classificar padrões de comportamento dos dados (SILVA, 2002). As redes têm capacidade computacional adquirida por meio de aprendizado e generalização (VALENÇA, 2009).

Segundo Osório (1999),

“...as Redes Neurais Artificiais são sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não-lineares)”.

Tais unidades são dispostas em uma ou mais camadas e interligadas por muitas conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. A Figura 5 apresenta a relação entre os neurônios naturais e o modelo de neurônio artificial.

Figura 5. Modelo de neurônio natural e artificial



Fonte: Adaptado de Osório, 1999.

Dentre as características inerentes às redes neurais artificiais, a principal é a capacidade de se adaptar a novas situações. Tal capacidade é alcançada a partir de um estágio de aprendizado (treinamento), onde o conhecimento sobre a aplicação é passado mediante exemplos (SILVA, 2005). Outra característica importante é a generalização, quando se avaliam com sucesso outros padrões similares, mas não necessariamente idênticos aos utilizados durante o aprendizado (HAYKIN, 2001).

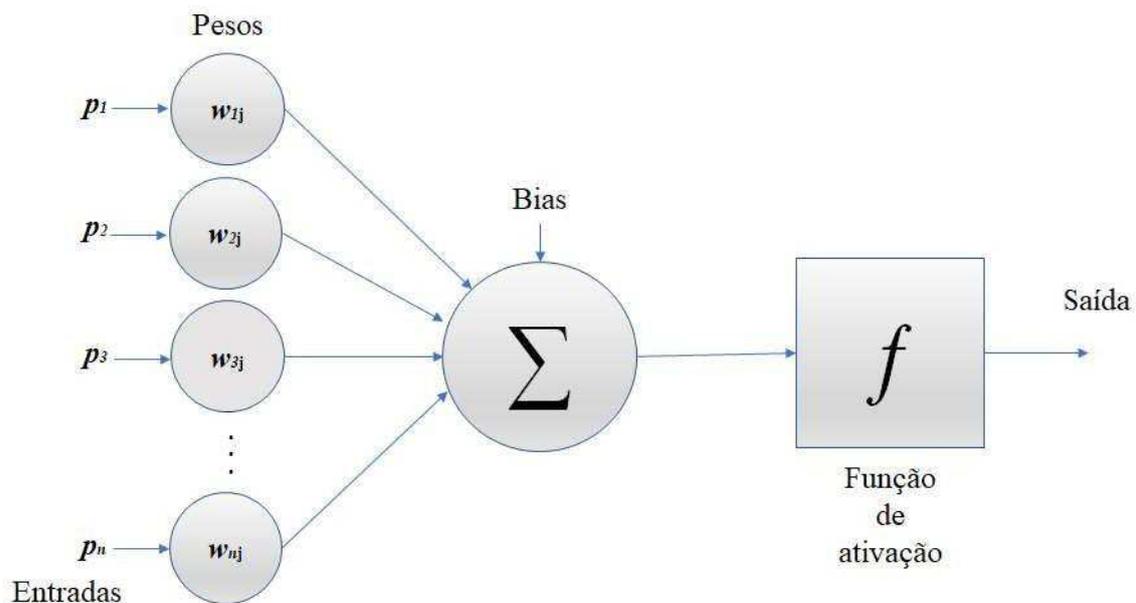
Diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado. Aprendizado supervisionado envolve a modificação dos pesos sinápticos da rede pela aplicação de um conjunto de dados de treinamento (composto por entradas e suas respectivas saídas desejadas). 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 interna para codificar as características da entrada e, desta maneira, de criar automaticamente as classes (HAYKIN, 2001).

2.7.1 NEURÔNIO ARTIFICIAL

Os neurônios artificiais podem ser entendidos como unidades de processamento. O seu funcionamento consiste em receber os sinais que são apresentados nas entradas e multiplicá-los pelos seus respectivos pesos sinápticos, determinando o nível de influência de cada sinal na saída do sistema. Os resultados obtidos serão a soma ponderada de suas entradas.

O modelo artificial de neurônio é mostrado na Figura 6, sendo uma generalização do modelo de McCulloch e Pitts (1943). Esse modelo inclui um sinal adicional bias (b) que favorece ou limita a possibilidade de ativação do neurônio. O processo sináptico é representado pelos pesos (ω) que amplificam cada um dos sinais recebidos. A chamada função de ativação (f) modela a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural (HAYKIN, 2001).

Figura 6. Modelo artificial de neurônio biológico.



Fonte: Adaptado de Haykin, 2001.

Usualmente, três tipos de funções de ativação são utilizadas em redes neurais, segundo Haykin (2001) e Fausett (1994): função de limiar, função de limiar por partes e função sigmóide. A função sigmóide, cujo gráfico tem forma de S, é a mais empregada na construção de redes neurais artificiais pois apresenta diversas características favoráveis, como o fato de ser função semi-linear, contínua, simétrica, derivável em toda sua extensão, crescente e limitada por assíntotas horizontais (REINKE, 2008).

2.7.2 REDE *PERCEPTRON* DE ÚNICA CAMADA

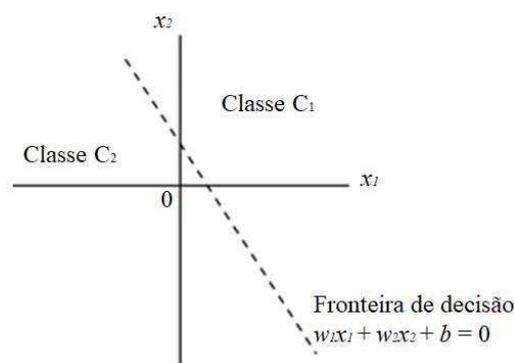
O *perceptron* de única camada comporta-se como um classificador de padrões, dividindo o espaço de entrada em regiões distintas para cada uma das classes existentes. Inicialmente, a saída da rede é aleatória, mas, pelo ajuste gradual dos pesos, o *perceptron* é treinado para fornecer saídas de acordo com os dados do conjunto de treinamento.

O *perceptron* é constituído por uma combinação linear das entradas x_1, x_2, \dots, x_n aplicada aos seus pesos sinapses w_1, w_2, \dots, w_n , e um bias b que é incorporado externamente. Quando o resultado desta operação é positivo, o neurônio produz uma saída +1, quando e negativo, a saída é -1, conforme a equação:

$$y = \begin{cases} 1 & \text{se } \sum_{i=1}^n w_i x_i + b > 0 \\ -1 & \text{se } \sum_{i=1}^n w_i x_i + b < 0 \end{cases} \quad (2)$$

O objetivo da rede é classificar corretamente o conjunto de estímulos aplicados externamente x_1, x_2, \dots, x_n em uma de duas classes C_1 ou C_2 . A regra de decisão para classificação é atribuir o ponto representado pelas entradas x_1, x_2, \dots, x_n à classe C_1 , se a saída do *perceptron* for +1, e à classe C_2 se ela for -1. As classes apresentadas ao *perceptron* necessitam ser linearmente separáveis, resultando em um hiperplano como o ilustrado na Figura 7.

Figura 7. Ilustração do hiperplano (aqui, uma reta) como fronteira de decisão para um problema de classificação linear de padrões bidimensional de duas classes.



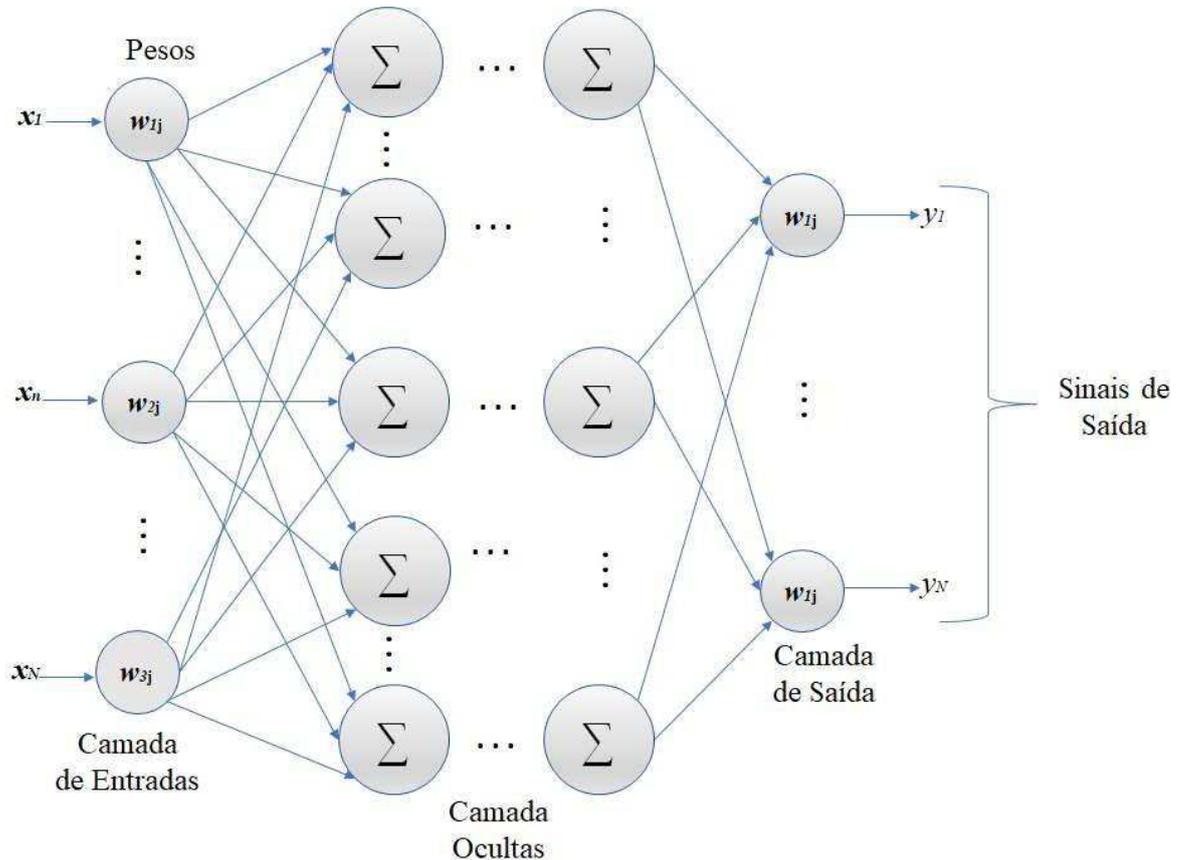
Fonte: Adaptado de Haykin, 2001.

2.7.3 REDE *PERCEPTRON* DE MÚLTIPLAS CAMADAS

O *perceptron* de múltiplas camadas, ou redes MLP (*Multilayer Perceptron*) se distingue pela presença de uma ou mais camadas ocultas (ou intermediárias), cujos nós computacionais são chamados de neurônios ocultos ou unidades ocultas. A função dos

neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira útil. Adicionando-se uma ou mais camadas ocultas, torna-se a rede capaz de extrair estatísticas de ordem elevada. A arquitetura da rede MLP pode ser visualizada conforme a Figura 8.

Figura 8.Arquitetura de uma rede MLP.



Fonte: Adaptado de Ferreira, 2011.

Os MLP vêm sendo utilizados para solução de diversos tipos de problemas. O treinamento destas redes é do tipo supervisionado e o algoritmo mais empregado é o de retropropagação do erro baseado na regra de aprendizagem por correção de erro (HAYKIN, 2001).

O treinamento da rede MLP é o processo que vai fazer com que um conjunto de pesos, determinados inicialmente de maneira aleatória, seja modificado por meio de um algoritmo, de modo que ao final do processo o conjunto de pesos obtido seja útil à solução de um determinado problema. O treinamento se inicia com a introdução de um conjunto de dados na entrada da rede, para os quais se espera que a saída atribua um valor que já é previamente conhecido (treinamento supervisionado). Posteriormente compara-se o sinal de saída com o sinal desejado e, mediante a comparação entre ambos, é feito um ajuste

dos pesos de todas as camadas da rede com o objetivo de levar o conjunto de pesos a propiciar na saída um valor próximo ao desejado (SANTOS FILHO, 2006).

Segundo Braga, Carvalho e Ludermir (2003), o algoritmo de retropropagação ou *back-propagation* é um algoritmo supervisionado que utiliza pares (entrada, saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Estas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* utiliza a saída da rede para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

O algoritmo *back-propagation* possui variações como o *quick-backpropagation* e *LevenbergMarquardt* que apresentam um melhor aprendizado em menos tempo. Enquanto o algoritmo *back-propagation* padrão utiliza o método do gradiente decrescente como método de aproximação do mínimo da função erro, o algoritmo de *Levenberg-Marquardt* utiliza uma aproximação pelo método de Newton. Esta aproximação é obtida a partir da modificação do método de Gauss-Newton (BAPTISTELLA, 2005).

A vantagem de utilização uma rede neural para realizar o reconhecimento e classificação de padrões consiste em que a rede pode construir fronteiras não lineares entre as diferentes classes de um grupo de entrada e apresentar um método prático para resolver problemas complexos e que necessitem de diagnósticos precisos.

Neste capítulo foi apresentada uma fundamentação teórica sobre isoladores elétricos, hidrofobicidade, processamento digital de imagens, modelos probabilísticos e rede neural artificial. No próximo capítulo será realizado um levantamento bibliográfico a respeito dos principais estudos relacionados ao tema proposto.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo são apresentadas as pesquisas que tratam do processamento digital de imagem utilizado para a análise e classificação dos níveis de hidrofobicidade das imagens, tomando como referência o guia STRI.

Alguns estudos relatam métodos de determinação do nível de hidrofobicidade utilizando análise de imagens obtidas com o molhamento de isoladores elétricos. Os métodos mais utilizados para classificar a hidrofobicidade são pela análise da morfologia matemática e do fator de forma circular (f_c). O fator de forma circular é dado por:

$$f_c = \frac{4a}{p^2} \quad (3)$$

em que a representa a área da região molhada e p representa o perímetro da região molhada.

Nos últimos anos estes métodos foram complementados por medidas das propriedades dielétricas ou energia de superfície. A seguir serão apresentados alguns trabalhos que se propuseram a classificar hidrofobicidade empregando STRI e PDI.

Berg *et al.* (2001) propuseram uma metodologia para classificar a hidrofobicidade de isolantes de borracha de silicone por meio da análise de imagens digitais. Na metodologia proposta, os autores analisaram os histogramas, utilizaram a técnica de segmentação por convolução e o desvio padrão devido às diferenças entre os níveis de cinza das imagens. Os métodos empregados foram: entropia escalonada, fração de pequenas diferenças, entropia normalizada e média das entropias normalizadas para superfícies de 10° e 35°. No estudo pode ser observado que a inclinação do isolador não interfere na análise da textura considerando os métodos analisados, sendo um importante indicativo que o uso do processamento digital de imagens pode ser empregado para análise da hidrofobicidade.

Chen *et al.* (2005) realizaram uma estimativa on-line da hidrofobicidade de isoladores poliméricos usando as imagens digitais feitas em isoladores em campo. Para identificar os níveis de hidrofobicidade de um isolador, com base nas imagens digitais feitas em isoladores em campo, foram estudados quatro algoritmos para análises de imagem. Os algoritmos são, individualmente, fundamentados: na média de entropias normalizadas otimizada; no método de ponto de semente; na análise de magnitude

frequente; e no fator de forma circular otimizado. Os resultados do estudo indicaram que o método do fator de forma otimizado apresentou os melhores resultados para estimar a hidrofobicidade de isoladores poliméricos em serviço. Usando o mapa de relacionamento k-HC e a relação Fc-HC do método de fator de forma circular otimizado, foram estabelecidos padrões de classificação e, como resultado, foi obtido uma taxa de acerto de 97%.

Thomazini *et al.* (2008) desenvolveram uma metodologia para relacionar a classificação de hidrofobicidade de acordo com STRI com base no processamento digital de imagem. Amostras das texturas de imagem foram produzidas por pulverização de soluções de água com álcool isopropílico em superfícies de polímero. Para evitar o gradiente de iluminação das imagens fotografadas em condições naturais, foram testados diferentes procedimentos como equalização de histograma, filtro *White Top-Hate* detecção de bordas por meio do operador Sobel. Ao usar a dimensão fractal para analisar as texturas das imagens de superfície molhada poliméricas, foi possível determinar uma função matemática que pode classificar a hidrofobicidade das superfícies poliméricas por meio de análises de imagens digitais.

Aperfeiçoando a pesquisa, Thomazini (2009), desenvolveu uma metodologia baseada em processamento digital de imagens para a classificação da hidrofobicidade em isoladores poliméricos de alta tensão. Na metodologia proposta, a hidrofobicidade foi determinada utilizando a análise da textura de imagens obtidas para materiais de isoladores elétricos poliméricos. As análises da textura foram avaliadas com base nos métodos de morfologia matemática (definir o tamanho dos elementos presente na imagem), de dimensão fractal, de entropia, de energia, de variância e de homogeneidade. Foram emuladas imagens da textura das superfícies dos isoladores utilizando uma placa de silicone e soluções de álcool isopropílico e água destilada em proporções que variaram de 0 até 100% em volume de álcool. Na tentativa de analisar as imagens independentes do padrão de iluminação, inerente às condições ambientais, foi aplicado a equalização de histograma (EQU) e/ou implementado um filtro do tipo *White Top-Hat* (WTH). Na classificação das texturas das imagens por meio dos métodos descritores de textura, os valores obtidos com a entropia apresentaram menor dispersão dentre os resultados, apresentando-se como uma metodologia apropriada para a classificação da hidrofobicidade. A partir dos resultados obtidos foi possível obter uma relação

matemática entre os métodos aplicados e as imagens, sendo possível definir a hidrofobicidade.

Khalayli *et al.* (2013) desenvolveram um sistema para a automação do sistema de classificação de hidrofobicidade proposto pelo guia STRI. O isolamento foi emulado por meio de uma placa quadrada revestida por uma camada de borracha de silicone RTV. As condições do isolamento externo foram determinadas a partir do processamento digital de imagens para extração das características de texturas das imagens, via matriz de co-ocorrência de bordas. A classificação da hidrofobicidade foi realizada para três níveis de hidrofobicidade por meio de um classificador polinomial, do qual, seu desempenho foi avaliado em um conjunto de dados de mais de 350 imagens obtendo uma taxa de acerto maior que 97%.

Dong *et al.* (2015) desenvolveram um sistema embarcado para identificação da hidrofobicidade de materiais isolantes. O método proposto pelo STRI foi aplicado em placas circulares, revestidas de borracha de silicone, com diferentes níveis de hidrofobicidade. As imagens obtidas foram processadas digitalmente para segmentação e extração dos seguintes parâmetros: número das gotas, área, perímetro e centroide da gota. A partir dos parâmetros foram analisados a cobertura molhada da amostra, a uniformidade de distribuição das gotículas, a uniformidade das áreas cobertas com água e o fator de forma circular de todas as gotículas. A classificação da hidrofobicidade foi baseada na árvore de decisão MultiBoost. Os autores concluíram que os procedimentos podem ser aplicados na plataforma DSP (*Digital Signal Processor*) e que podem ser obtidos resultados satisfatórios.

Wang *et al.* (2016) desenvolveram um sistema de monitoramento para buchas de transformadores objetivando avaliar o nível de poluição de buchas poliméricas por meio da análise da hidrofobicidade. As imagens foram tratadas com técnicas de processamento digital de imagens, da qual foram extraídos quatro parâmetros: maior área molhada; cobertura da água; a maior excentricidade, e o maior fator de forma circular. A classificação foi realizada via rede neural artificial e a mesma obteve 97% de acerto. Os autores concluíram que o método proporcionou alta exatidão e pode ser utilizado para auxiliar na identificação do grau de poluição em buchas poliméricas.

Alves (2016) propôs uma ferramenta computacional para auxiliar na tomada de decisão e na classificação da hidrofobicidade em isoladores elétricos de alta tensão com revestimento polimérico. Um algoritmo foi desenvolvido para extração de parâmetros

numéricos de imagens obtidas por meio do método proposto pelo STRI. O método de pulverização foi realizado em isolador elétrico de vidro revestido de um material polimérico. Os parâmetros avaliados foram: número de regiões molhadas, tamanho das regiões molhadas, tamanho das regiões secas e distribuição percentual das áreas. O processamento digital das imagens foi realizado conforme as seguintes etapas: liminarização, uniformização, binarização, rotulação e extração de atributos. A autora concluiu que os parâmetros avaliados contêm informações pertinentes à avaliação das imagens e permite auxiliar no desenvolvimento de um algoritmo eficiente para classificação da hidrofobicidade.

Na Tabela 2 pode ser visto de forma sumarizada os parâmetros de classificação e a tomada de decisão empregados na classificação dos níveis de hidrofobicidade referenciados no guia STRI. Também se encontra incluída na Tabela a contribuição deste trabalho.

Tabela 2. Apresentação dos parâmetros de classificação e tomada de decisão artificial utilizadas.

Pesquisadores	Métodos e Parâmetros de Classificação	Tomada de Decisão
Berg (2001)	Média das entropias normalizadas.	-----
Chen <i>et al.</i> (2005)	Média das entropias normalizadas otimizada; Método de ponto de semente; Magnitude frequente; e Fator de forma circular otimizado	Parametrização do fator de forma circular.
Thomazini <i>et al.</i> (2008)	Dimensão fractal.	Função matemática.
Thomazini. (2009)	Morfologia matemática; Dimensão fractal; Entropia; Energia superficial; Variância; e Homogeneidade.	Função matemática.
Khalayli <i>et al.</i> (2013)	Morfologia matemática.	Classificação Polinomial.
Dong <i>et al.</i> (2015)	Cobertura molhada da amostra; Distribuição das gotículas; Uniformidade das áreas cobertas com água; e Fator de forma circular.	Árvore de decisão <i>MultiBoost</i> .
Wang <i>et al.</i> (2016)	Maior área molhada; Cobertura da água; Maior excentricidade; e Maior fator de forma circular.	Rede Neural Artificial.
Alves (2016)	Número de regiões molhadas; Área das regiões molhadas; Área das regiões secas; e Distribuição percentual das áreas.	-----
Esta pesquisa	Número regiões molhadas; Maior área molhada; Área total molhada;	Modelo Probabilístico e Rede Neural Artificial.

Distância média e máxima entre as
regiões molhadas;
Maior fator de forma circular;
Excentricidade mínima e máxima.

Fonte: Autoria própria.

Neste capítulo foi apresentado o levantamento bibliográfico a respeito dos principais estudos relacionados ao tema proposto. No próximo capítulo será descrita a metodologia adotada nos procedimentos da pesquisa.

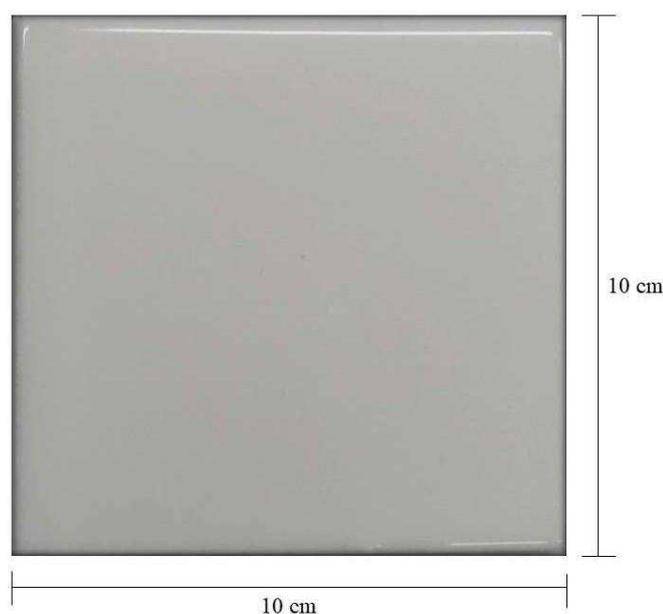
4 METODOLOGIA

A metodologia proposta para concretização da classificação da hidrofobicidade utilizando PDI será exposta nas seções subsequentes, enfatizando-se o material empregado e a montagem experimental, a elaboração de algoritmos compondo o procedimento computacional, a parametrização adotada para cada característica avaliada no contexto de hidrofobicidade, a análise e classificação da hidrofobicidade.

4.1 PLACAS DE TESTES

Com a finalidade de aplicar o algoritmo desenvolvido foram feitas fotografias de superfícies com diferentes graus de hidrofobicidade, baseadas na classificação da hidrofobicidade do guia STRI. Para tal, foram utilizadas placas quadradas de vidro temperado revestidas de borracha de silicone acrescida de microcargas de alumina tri-hidratada *Hydrogard-GP*, conforme Figura 9. As placas têm como objetivo emular a superfície do isolador polimérico e proporcionar a aquisição de um número significativo de imagens para o estudo do comportamento da hidrofobicidade.

Figura 9. Fotografia da placa com superfície polimérica.



Fonte: Autoria própria.

Como sugerido nos trabalhos de Bradwell (1984) e Ehsani *et al.* (2004), as superfícies das placas foram submetidas ao desgaste por imersão em água, para a obtenção do nível HC1 até o nível HC6.

4.2 ENSAIO DE HIDROFOBICIDADE

4.2.1 ARRANJO

Para realização dos ensaios de hidrofobicidade foi desenvolvido um arranjo fotográfico, que tem como objetivo proporcionar melhor contraste das gotas, eliminação das sombras e aquisição rápida das imagens.

O arranjo é composto basicamente por uma câmera fotográfica, amostras revestidas de material polimérico e um sistema de iluminação. A câmera fotográfica posicionada 90° em relação a amostra e com o *zoom* aplicado de 10 vezes, para todas as imagens. O sistema de iluminação é constituído por três lâmpadas fluorescente de 20 W e 1180 lm posicionadas a aproximadamente 120° uma da outra, no mesmo plano horizontal. Na Figura 10 pode ser observado o esquemático do sistema de iluminação.

Figura 10. Sistema de iluminação com a amostra polimérica.



Fonte: Autoria própria.

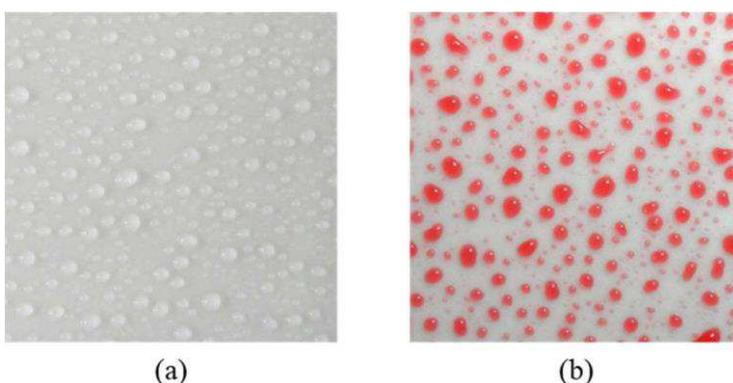
A intensidade luminosa do ambiente foi ajustada para ser menor que a intensidade da lâmpada, possibilitando que a gota de água depositada na superfície não reflita luz difusa, e, portanto, não comprometa a qualidade da medição. Ressalta-se que, devido ao curto tempo de exposição, não foi constatado influência da temperatura das lâmpadas na evaporação da água e na degradação do material.

4.2.2 MÉTODO DE PULVERIZAÇÃO

O método de pulverização baseia-se na resposta de molhagem da superfície do isolador após exposição a uma névoa fina de água por um curto período. O equipamento necessário para a realização do ensaio consiste em um dispositivo que pode produzir uma neblina fina, tal como um frasco de pulverização comum. O frasco de pulverização continha água destilada acrescido de corante artificial alimentício, da marca MIX.

O uso do corante visa proporcionar uma imagem final com tonalidades e contrastes bem definidos para melhor segmentação, sendo analisada a distribuição de todas as gotículas na superfície. O corante não influencia significativamente na classificação dos níveis de hidrofobicidade definidos no guia STRI. Como pode ser visto na Figura 11, a imagem com o corante obteve a mesma classificação HC1 da imagem sem o corante.

Figura 11. Classificação HC1 (a) sem o corante e (b) com o corante.



Fonte: Autoria própria.

A área da superfície polimérica empregado nos diferentes ensaios foi uma região quadrada padronizada em 16 cm², devido às delimitações físicas das aletas do isolador. A pulverização foi realizada duas vezes por segundo a uma distância aproximada de 25±10

cm. A quantidade de água pulverizada consistiu entre 12 ml e 20 ml. A aquisição das imagens foi realizada após 10s do término da pulverização.

O ensaio foi repetido até que se obtivesse uma quantidade significativa de imagens para cada nível de hidrofobicidade. Ao finalizar o ensaio de pulverização obteve-se o banco de dados para avaliação das imagens via PDI, posterior classificação subjetiva e treinamento da tomada de decisão artificial.

4.3 BANCO DE IMAGENS E PRÉ-CLASSIFICAÇÃO DAS IMAGENS

Vislumbrando a utilização de uma rede *perceptron* de múltiplas camadas MLP (*Multilayer Perceptron*), foi necessário a criação de um banco de imagens vasto para que a taxa de acerto da MLP seja confiável. Portanto, foram fotografadas 100 imagens para cada nível de hidrofobicidade pré-classificada.

O treinamento da MLP inicia com a introdução de um conjunto de dados na entrada da rede, para os quais se espera que a saída atribua um valor que já é previamente conhecido, ou seja, pré-classificado. Devido à classificação referente ao guia STRI ser subjetiva e, na tentativa que a rede não detenha totalmente a subjetividade de uma única pessoa, fez-se a opção de que cada imagem fosse classificada por pelo menos três pessoas. Em caso de divergência entre as três pessoas, professores cadastrados teriam maior peso de classificação. Definiu-se que a forma mais eficiente de atingir um grande número de pessoas dispostas a colaborar seria realizar uma pesquisa submetida por meio de correio eletrônico.

Uma primeira mensagem foi enviada para integrantes do corpo docente e discente dos cursos de engenharia elétrica de seis instituições de ensino superior. Nela, introduzia-se a pesquisa e se convidava o potencial voluntário a colaborar. Os interessados se manifestaram e foram cadastrados para o envio posterior do material a ser classificado.

Após o cadastramento das pessoas, que se disponibilizaram a colaborar com esta pesquisa, foram separadas 10 imagens, com níveis de HC1 a HC6, pré-classificadas para cada colaborador, de forma que ao menos dois colaboradores classificassem as mesmas imagens. Na Figura 12 pode ser visto o modelo de formulário que foi enviado para os colaboradores. No Apêndice A se encontra os dados de todos os colaboradores.

Em seguida, foram realizadas análises visuais das imagens padrão contidas no guia STRI e das imagens do banco de dados. Alguns parâmetros foram estabelecidos para fins de análise via PDI e subsequente classificação HC:

- a) Número de regiões molhadas (gotas ou pequenas poças);
- b) Área individual máxima das regiões molhadas;
- c) Área total das regiões molhadas;
- d) Distância média e máxima entre as regiões molhadas;
- e) Maior fator de forma (relação entre perímetro e área da região molhada);
- f) Excentricidade Mínima e Máxima.

4.4 PROCEDIMENTO COMPUTACIONAL

Com o objetivo de realizar o processamento das informações contidas nas imagens, no procedimento computacional foi desenvolvido o Algoritmo de Classificação de Hidrofobicidade. O algoritmo é composto por rotinas com fins específicos para o tratamento e segmentação das imagens matriciais, do qual, ao término, são obtidas imagens aptas a serem parametrizadas, objetivando agregar análises e conclusões. A estrutura do algoritmo pode ser vista na Figura 13 e o detalhamento de cada rotina é mostrado a seguir.

Figura 13. Fluxograma das rotinas do algoritmo.



Fonte: Autoria própria.

4.4.1 ROTINA DE LIMIAZIZAÇÃO

A Rotina de Limiarização efetua uma limiarização multiespectral. Nesta rotina, aplica-se um limiar T para cada banda ou componente de cor da imagem (RGB). O limiar

é definido por meio do histograma da superfície polimérica, áreas da sombra e das regiões molhadas. *Pixels* identificados na área da superfície polimérica e em áreas de sombra são representados com as cores verde e branca respectivamente. *Pixels* identificados como reflexo de luminosidade das regiões molhadas e que possuam proximidade com áreas da superfície do isolador e áreas de sombra são representados na cor vermelha. Os *pixels* identificados como regiões molhadas são representados na cor azul.

4.4.2 ROTINA DE UNIFORMIZAÇÃO

A rotina de uniformização consiste em transformar a imagem limiarizada em uma imagem com duas representações de cores, diferenciando a superfície polimérica e as sombras das regiões molhadas. Todos os *pixels* que pertencem às regiões molhadas passam a ser vermelhos.

4.4.3 ROTINA DE BINARIZAÇÃO

A Rotina de Binarização consiste em transformar a imagem colorida em preta e branca e posteriormente eliminar os ruídos presentes na imagem. A imagem binarizada proporciona o uso dos filtros morfológicos, que atuam na eliminação dos ruídos.

Almejando a eliminação dos ruídos aleatórios aplicou-se o filtro mediano. Este filtro gera uma nova imagem, realizando a média do conjunto de *pixels* no ambiente envolvente (vizinhos) correspondente ao *pixel* da imagem original.

Mesmo com a aplicação do filtro mediano existem regiões onde se faz necessário um preenchimento, devido à ocorrência de “buracos”. Um buraco é um conjunto de *pixels* de fundo que não pode ser alcançado mediante o preenchimento a partir do contorno da imagem; para tanto se usa um filtro baseado em reconstrução morfológica, um filtro de preenchimento.

4.4.4 ROTINA DE ROTULAÇÃO E EXTRAÇÃO DE PARÂMETROS

A rotulação é utilizada na segmentação para identificação e contagem de regiões ou objetos presentes em uma imagem. A cada região ou componente é atribuído um valor único, denominado rótulo (*label*). Para tanto deve ser realizada uma varredura da imagem buscando *pixels* de mesma cor e que sejam vizinhos, compondo uma área molhada.

Para determinação das regiões foi utilizado um padrão de conectividade 8, o qual estabelece que se os atributos de dois *pixels* p e q são iguais e se estão no conjunto de vizinhança de 8 *pixels*, os *pixels* p e q estão conectados. Após varrer toda a imagem é gerada uma nova imagem rotulada.

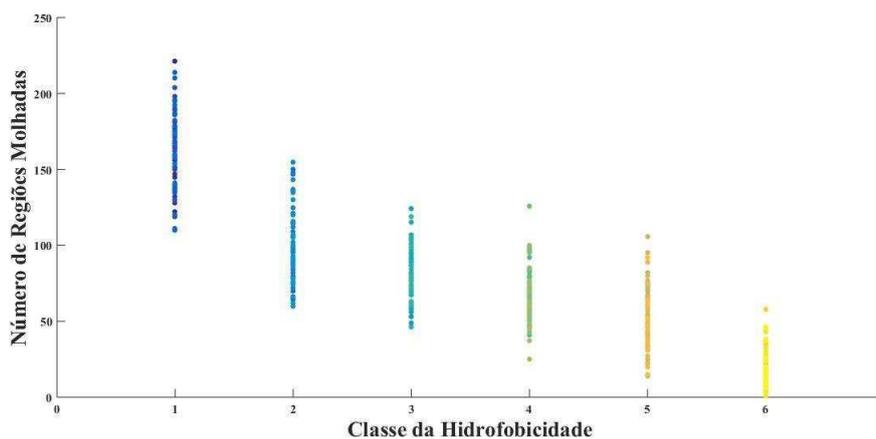
Ao término do processo de rotulação, a imagem está apta para a extração das informações de interesse deste trabalho

4.5 ANÁLISE E CLASSIFICAÇÃO DOS DADOS

A partir da classificação realizada pelo grupo de colaboradores e da extração dos parâmetros das imagens é possível realizar uma análise do comportamento da hidrofobicidade. Isto, visa estabelecer os parâmetros de maior influência na classificação da hidrofobicidade.

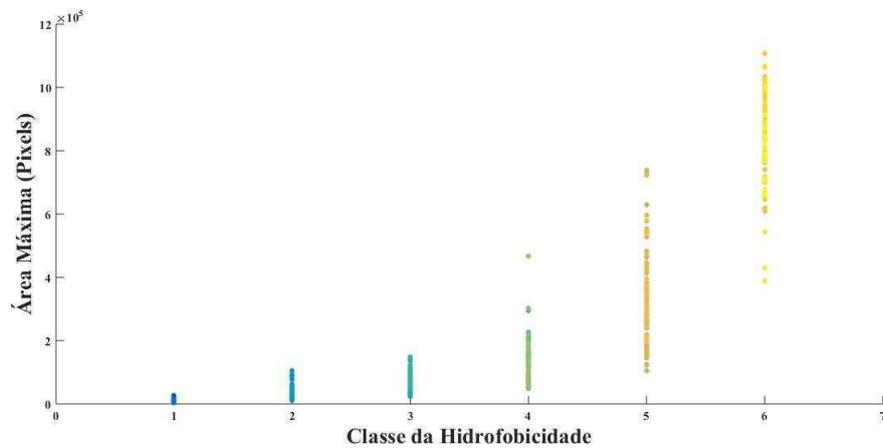
Este método é utilizado para examinar os dados no que se refere à ocorrência de tendências (lineares ou não), agrupamentos de uma ou mais variáveis, mudanças de espalhamento de uma variável em relação à outra e verificar a ocorrência dos valores discrepantes. Os diagramas de dispersão podem ser visualizados nas Figura 14 a Figura 21.

Figura 14. Diagrama de Dispersão do Número de Regiões Molhadas – HC1 - HC6.



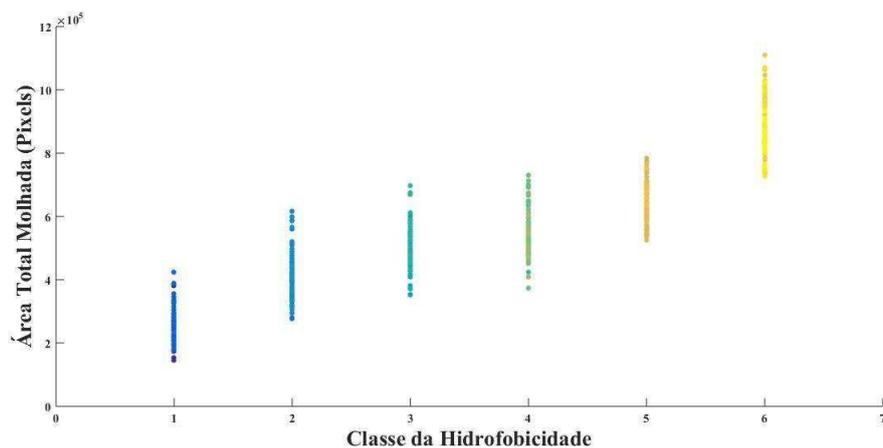
Fonte: Autoria própria.

Figura 15. Diagrama de Dispersão da Área Máxima das Regiões Molhadas– HC1 - HC6.



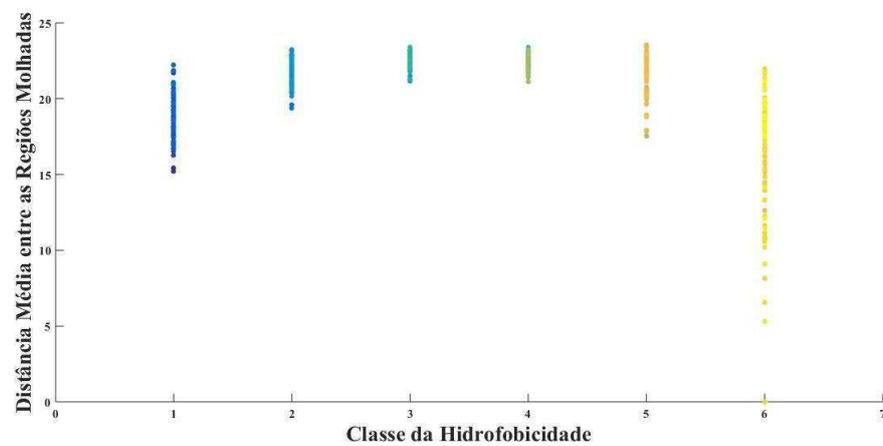
Fonte: Autoria própria.

Figura 16. Diagrama de Dispersão da Área Total Molhada – HC1 - HC6.



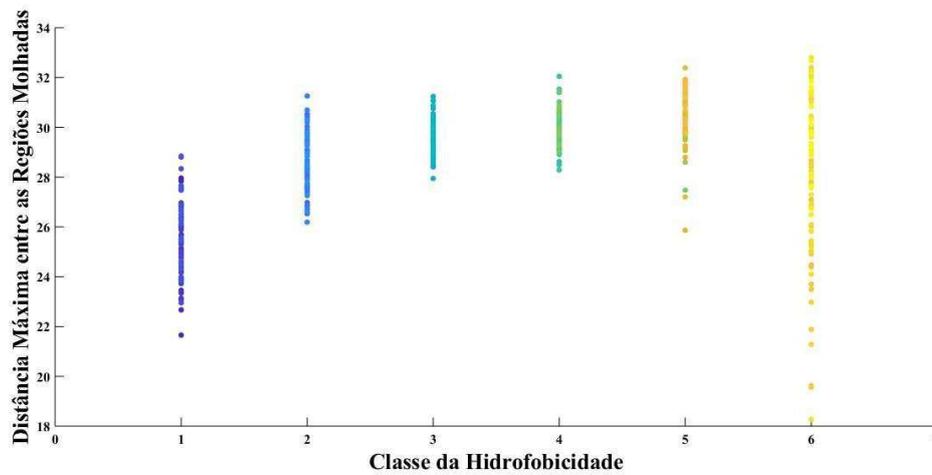
Fonte: Autoria própria.

Figura 17. Diagrama de Dispersão da Distância Média entre as Regiões Molhadas – HC1 - HC6.



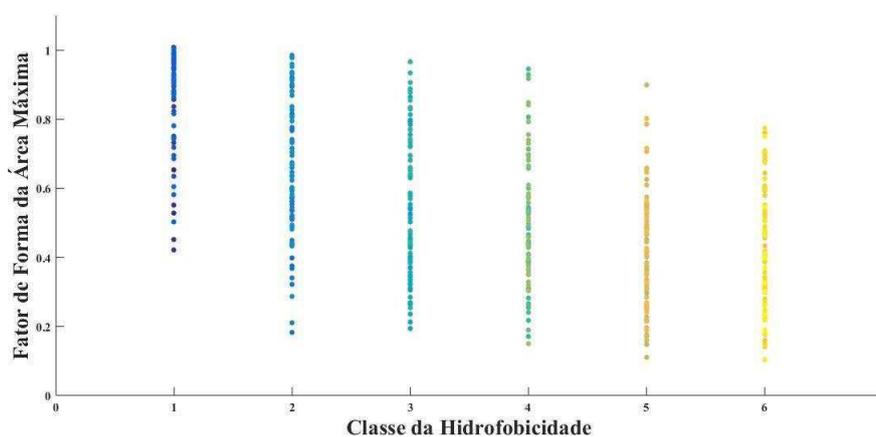
Fonte: Autoria própria.

Figura 18. Diagrama de Dispersão da Distância Máxima entre as Regiões Molhadas – HC1 - HC6.



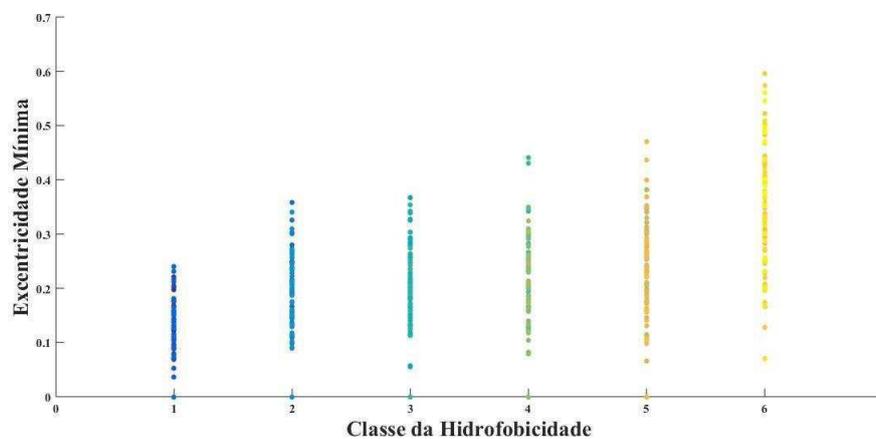
Fonte: Autoria própria.

Figura 19. Gráfico de Dispersão do Fator de Forma Circular da Área Máxima – HC1 - HC6.



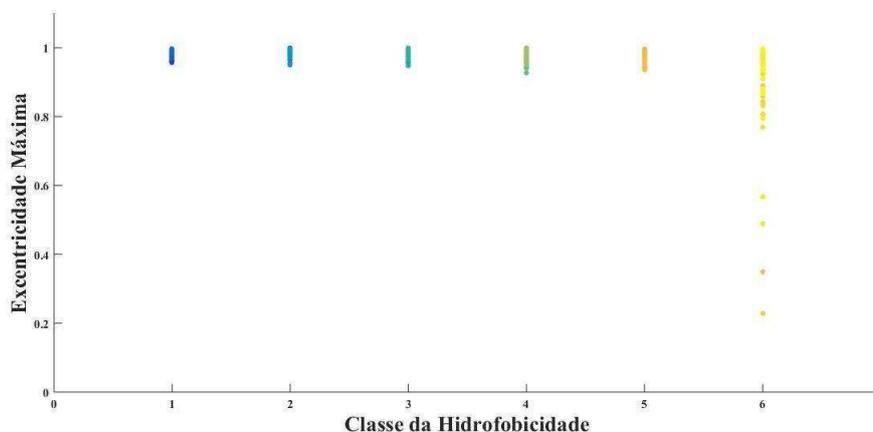
Fonte: Autoria própria.

Figura 20. Diagrama de Dispersão da Excentricidade Mínima – HC1 - HC6.



Fonte: Autoria própria.

Figura 21. Gráfico de Dispersão da Excentricidade Máxima – HC1 - HC6.



Fonte: Autoria própria.

Com o intuito de estabelecer o modelo para explicar o fenômeno, deve-se verificar qual tipo de curva e equação de um modelo matemático mais se aproxime dos pontos representados no diagrama de dispersão. Assim, analisando os diagramas acima, observa-se uma maior tendência linear para os parâmetros Área Máxima, Área Total e Número de Regiões com a Hidrofobicidade. O parâmetro da excentricidade não apresentou nenhum modelo de curva conhecido devido ao grande número de sobreposições de dados, não sendo perceptível uma divisão das classes.

Contudo, verifica-se que os pontos do diagrama de dispersão, não vão se ajustar perfeitamente a uma curva de modelo matemático. Haverá na maior parte dos pontos, uma distância entre os pontos do diagrama e a curva do modelo matemático. Isto acontece devido ao fato do fenômeno que está em estudo não ser um fenômeno matemático e sim um fenômeno que está sujeito a influências que acontecem ao acaso.

4.5.1 ANÁLISE LINEAR – MÉTODO *STEPWISE*

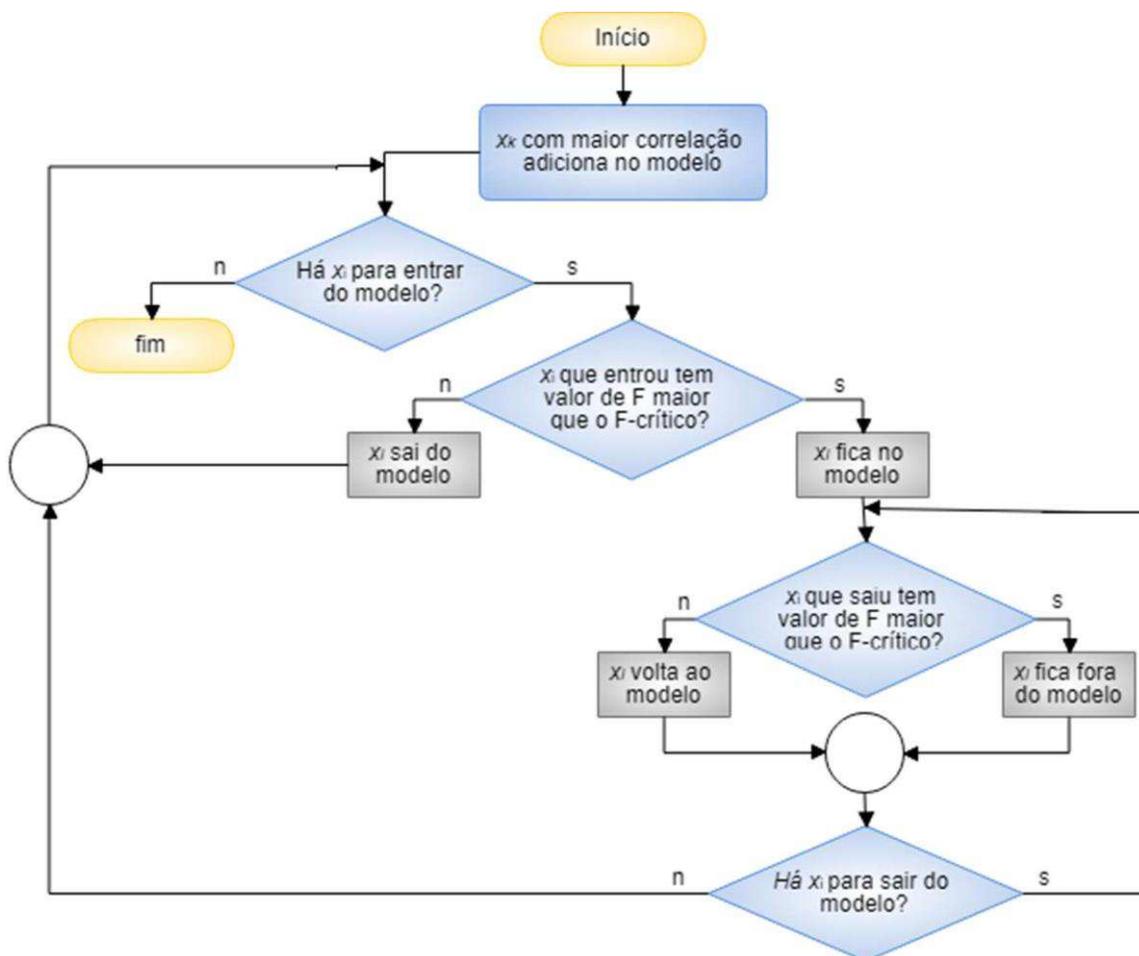
O método *Stepwise* foi utilizado para selecionar quais parâmetros tem maiores influências no conjunto de saída podendo, assim, diminuir o número de parâmetro a compor a tomada de decisão.

O procedimento padrão para seleção de parâmetros combina dois outros métodos, o *forward selection* e *backward elimination*. O algoritmo, progressivamente, adiciona novos parâmetros ao modelo, iniciando daquela com maior correlação com a resposta,

como no método *forward selection*, e incorpora um mecanismo de eliminação de variáveis igual ao método de *backward elimination*.

O método *forward selection* foi utilizado nesta dissertação. Consiste em um método iterativo que começa com um parâmetro de análise (x_i) e, progressivamente, adiciona mais parâmetros ao modelo de regressão até que um critério de parada seja satisfeito. O parâmetro inicial deve apresentar máxima correlação com a variável de resposta HC. A cada iteração, é construído um novo modelo e o efeito do parâmetro incluído é avaliado por um teste-F. O fluxograma do método pode ser visualizado na Figura 22.

Figura 22. Fluxograma do método *Stepwise*.



Fonte: Autoria própria.

O teste F é utilizado para testar se as variâncias de dois conjuntos de dados são iguais. A estatística é dada por:

$$F = \frac{s_1^2}{s_2^2} \quad (4)$$

em que s_1 e s_2 são os desvios padrão da amostra.

Quanto mais o valor de F se desvia de 1, maior a probabilidade de rejeitar a hipótese nula. Sob a hipótese nula, a estatística de teste F tem uma distribuição F com graus de liberdade do numerador iguais a $N_1 - 1$ e graus de liberdade do denominador igual a $N_2 - 1$, onde N_1 e N_2 são os tamanhos de amostra dos dois conjuntos de dados.

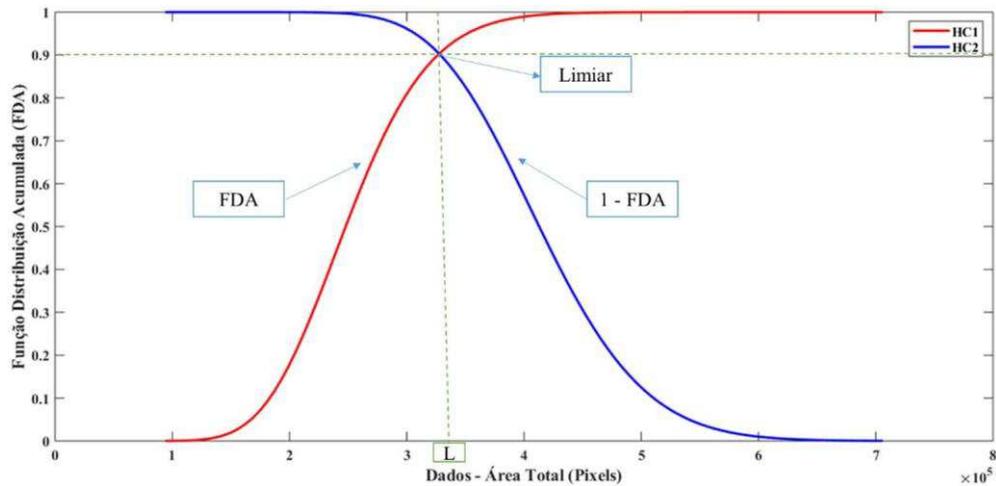
4.5.2 ANÁLISE PROBABILÍSTICA E CLASSIFICAÇÃO

A utilização de ferramentas estatísticas em busca do reconhecimento de padrões e explicação de fenômenos físicos possui grande aplicabilidade nas decisões de engenharia. Para uma avaliação estatística das características dos dados e futura classificação, foi implementada os modelos de distribuição Gama, Normal e Weibull, que teve como propósito, avaliar os limiares entre as classes HC. Esta análise também possibilita a redução de parâmetros de entrada, de forma que as entradas sejam parâmetros altamente significativos para a classificação da hidrofobicidade.

A utilização de funções de distribuição de probabilidade requer o uso de testes para provar a adaptação dos dados ou da série de dados às funções. Esses testes são conhecidos como testes de aderência e sua real função é verificar a forma de uma distribuição, por meio da análise da adequação dos dados à curva de um modelo de distribuição hipotética. Neste trabalho após a aplicação das distribuições de probabilidade, suas respectivas aderências foram testadas utilizando o teste Qui-quadrado ao nível de significância de 5%.

Uma vez que o modelo de estimativa de probabilidade da classe HC foi obtido, buscou-se os limiares das classes por meio da implementação do ponto de intercepção entre as FDA (Função de Densidade Acumulada) das classes HC. Optou-se por definir a FDA de uma classe HC e o complementar da FDA da classe HC vizinha, sendo o limiar o ponto de intercepção entre as FDA, conforme representado na Figura 23.

Figura 23. Demonstração do limiar entre os níveis HC.



Fonte: Autoria própria.

Neste trabalho, também são empregadas RNA do tipo MLP (*perceptrons* de múltipla camada). A implementação computacional das RNA é realizada utilizando um conjunto de ferramentas do software MATLAB®, chamado Neural Networks Toolbox, que permite a construção e treinamento de RNA.

Neste capítulo foi descrita a metodologia adotada para o ensaio de pulverização, banco de imagens, processamento via PDI, análises e classificação dos dados. No próximo capítulo serão apresentadas as análises e discussões dos resultados obtidos do PDI, da Modelagem Probabilística e da RNA.

5 RESULTADOS

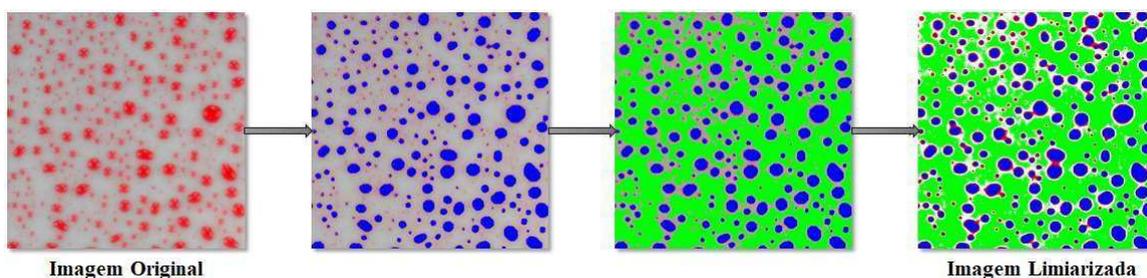
Nas seções subsequentes são apresentados os resultados e análises do Processamento Digital de Imagem, da Análise Linear, bem como a aplicação do Modelo Probabilístico e do sistema de RNA proposto para classificação da hidrofobicidade. Os resultados obtidos a partir dos modelos Probabilísticos e da RNA são avaliados utilizando diversos conjuntos de parâmetros, sendo apontado um conjunto mínimo de parâmetros que conduz a uma classificação satisfatória.

5.1 PROCESSAMENTO DIGITAL DA IMAGEM

O processamento digital de imagem deste trabalho inicialmente consistiu na operação de limiarização (segmentação), cujo objetivo principal foi salientar as regiões molhadas, possibilitando a identificação de todos os *pixels* que constituem esta fase. Para maior eficiência na segmentação foram realizadas algumas rotinas de processamento.

Na rotina de limiarização foram analisados os limiares da imagem. Traçados os limiares, os *pixels* identificados como regiões molhadas foram representados na cor azul e manteve-se os demais em sua coloração original. Posteriormente, a área identificada como superfície polimérica foi representada por *pixels* na cor verde. Entretanto, observou-se que existiam *pixels* que não eram identificados devido à luminosidade e ao contraste da imagem, para tanto, foram identificados os limiares intermediários. Os *pixels* identificados como reflexo de luminosidade das regiões molhadas e que possuam proximidade com áreas da superfície polimérica foram representados na cor vermelha. E os demais *pixels*, considerados como superfície polimérica, foram representados na cor branca. Na Figura 24 podem ser observados os resultados do processamento da rotina de limiarização para uma imagem classificada como HC1.

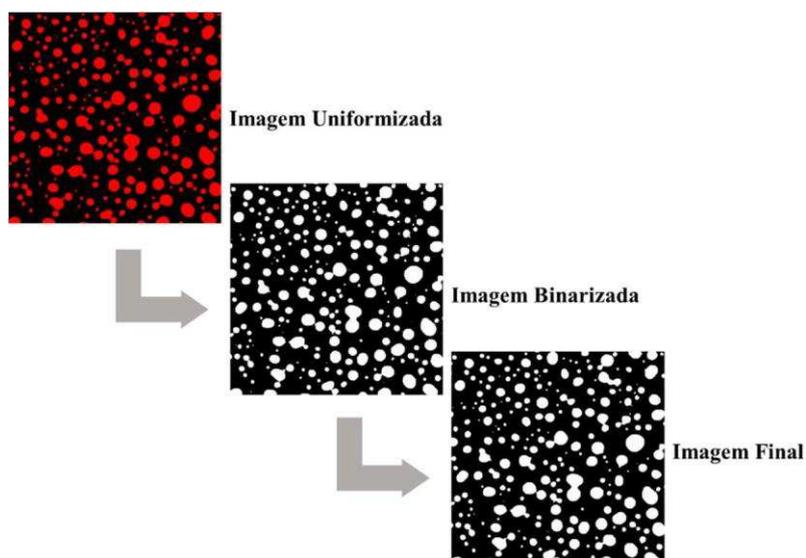
Figura 24. Processamento de limiarização.



Fonte: Autoria própria.

Após a rotina de limiarização utilizou-se a rotina de uniformização, de modo a ter uma representação com dois padrões de cores, preta e vermelha. Os *pixels* identificados como superfície polimérica foram representados na cor preta e os *pixels* identificados como regiões molhadas na cor vermelha. Objetivando a eliminação de alguns defeitos/ruídos presentes na imagem uniformizada foi realizada a rotina de binarização da imagem. A imagem binarizada possibilita operações de filtragem no domínio espacial, por meio do filtro mediano e do filtro de preenchimento. Como resultado desta rotina, na Figura 25 são apresentadas as imagens finais da rotina de uniformização, binarização e eliminação dos defeitos presentes na imagem para posterior rotulação.

Figura 25. Processamento da uniformização até a imagem final.



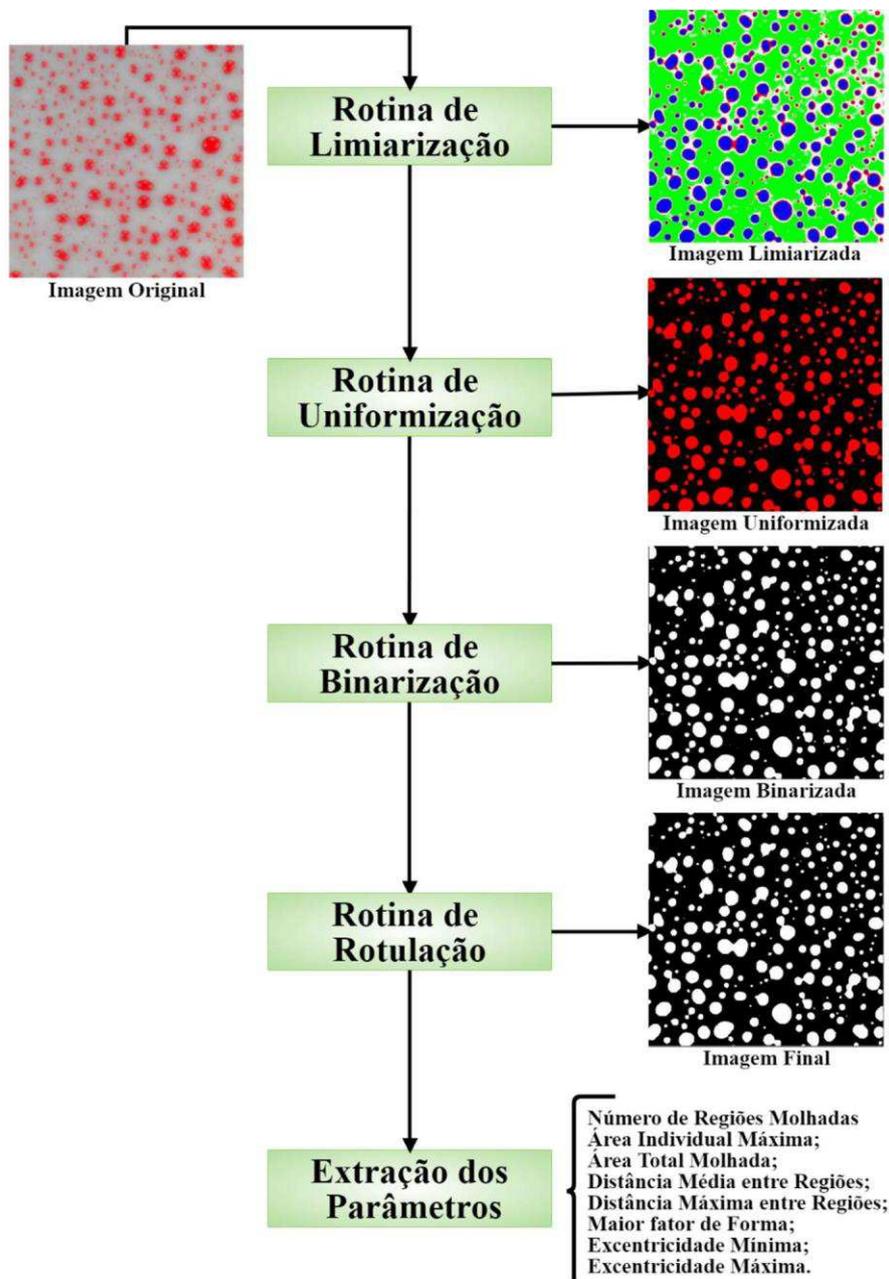
Fonte: Autoria própria.

Por último, aplicou-se a rotina de rotulação, a qual permitiu identificar e rotular as regiões molhadas possibilitando a extração dos parâmetros de interesse, dentre os quais: Número das Regiões Molhadas; Área Individual Máxima das Regiões; Área Total

Ocupada pelas Regiões; Distância Média e Máxima entre as Regiões Molhadas; Maior Fator de Forma e Excentricidade Mínima e Máxima.

De forma sumarizada, na Figura 26 podem ser vistas as imagens finais das rotinas do processamento realizado pelo algoritmo desenvolvido, aplicado a um caso de estudo com classificação HC1.

Figura 26. Fluxograma do processamento de imagens para extração dos parâmetros – HC1.



Fonte: Autoria própria.

5.2 ANÁLISES E CLASSIFICAÇÃO

5.2.1 ANÁLISE LINEAR

Objetivando uma análise linear, os parâmetros extraídos das imagens foram correlacionados de modo linear, entre si, para cada classe de hidrofobicidade. A correlação entre os parâmetros foi avaliada, analisando-se o coeficiente de correlação linear de Pearson. Os coeficientes de correlação podem ser visualizados na Tabela 3.

Tabela 3. Matriz de Correlação Linear.

	HC	Área Máxima	Área Total	Número Regiões	Fator de Forma	Exc. Máxima	Exc. Mínima	Distância Máxima	Distância Média
HC	1	0,8371	0,9167	-0,9024	-0,6194	-0,3195	0,5548	0,4195	-0,2123
Área Máxima	0,8371	1	0,8955	-0,7451	-0,4040	-0,4582	0,5884	0,0513	-0,6148
Área Total	0,9167	0,8955	1	-0,8637	-0,4819	-0,4038	0,5637	0,3191	-0,3429
Número Regiões	-0,9024	-0,7451	-0,8637	1	0,6498	0,3074	-0,6054	-0,4766	0,1230
Fator de Forma	-0,6194	-0,4040	-0,4819	0,6498	1	0,0756	-0,3995	-0,4672	-0,1819
Exc. Máxima	-0,3195	-0,4582	-0,4038	0,3074	0,0756	1	-0,2366	0,0963	0,3912
Exc. Mínima	0,5548	0,5884	0,5637	-0,6054	-0,3995	-0,2366	1	0,1306	-0,2819
Distância Máxima	0,4195	0,0513	0,3191	-0,4766	-0,4672	0,0963	0,1306	1	0,5020
Distância Média	-0,2123	-0,6148	-0,3429	0,1230	-0,1819	0,2819	-0,2819	0,5020	1

Fonte: Autoria própria.

A partir dos dados da Tabela 3, verificou-se que há correlação forte e positiva entre a Hidrofobicidade e os parâmetros de Área Máxima e Área Total, e correlação forte e negativa entre a Hidrofobicidade e Número de Regiões. O parâmetro Fator de Forma apresentou uma correlação moderada e negativa, os demais parâmetros apresentaram fraca correlação linear com a Hidrofobicidade.

Também se verificou a existência de uma correlação linear forte ou moderada somente entre algumas das variáveis em relação à Hidrofobicidade indicando que alguns parâmetros podiam não ser significativos na classificação com a hidrofobicidade. Portanto, utilizou-se o método *Stepwise* para selecionar quais parâmetros mais influenciam o conjunto de saída podendo, assim, diminuir o número de parâmetros a

compor a tomada de decisão. O método é realizado de forma iterativa, adicionando e removendo variáveis, a partir de um critério de seleção, neste trabalho utilizou-se o teste F como critério de seleção. Na Tabela 4 são apresentados os parâmetros adicionados e os respectivos valores da estatística F e Valor-p.

Tabela 4. Testes F para avaliar a inclusão de cada interação de 1ª ordem no modelo normal linear.

Parâmetros	Estatística F	Valor-p
Área Total	2457,355	3,580E-198
Número de Regiões	230,472	2,828E-43
Fator de Forma	56,127	2,994E-13
Área Máxima	8,3599	0,00399
Área Máxima : Número de Regiões	235,474	5,707E-44
Área Máxima : Área Total	30,821	4,562E-08
Área Total : Número de Regiões	55,908	3,355E-13
Área Máxima : Fator de Forma	10,739	0,001

Fonte: Autoria própria.

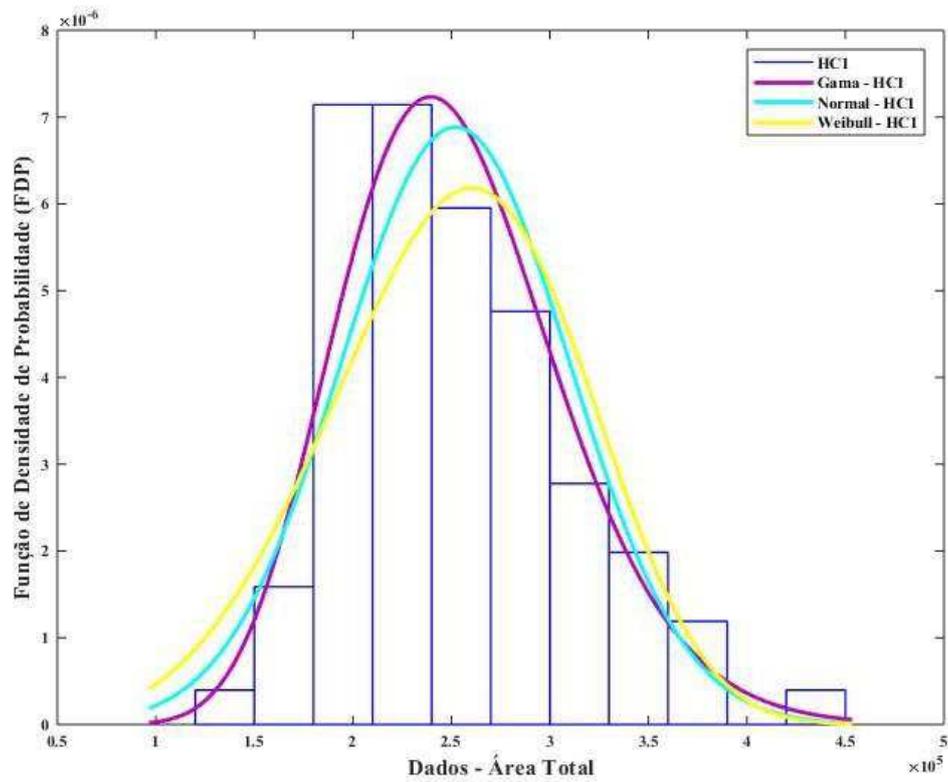
Ao se observar os dados contidos na Tabela 4, pode-se constatar que há parâmetros com grande significância na classificação da hidrofobicidade. Verificou-se quatro parâmetros que apresentaram ótima significância com o teste F e que possuem valores-p menores que 0,05 indicando que há diferenças significativas entre os parâmetros comparados. Destaca-se o parâmetro Área Total das Regiões Molhadas, o qual obteve-se para a estatística de teste um valor de $F=2457,355$ e um valor-p muito pequeno (menor que 0,05), indicando ser o ótimo parâmetro de classificação.

5.2.2 ANÁLISE PROBABILÍSTICA

Constatando-se que os dados têm um comportamento não linear, realizou-se uma análise probabilística dos dados considerando apenas um parâmetro de interesse, Área Total. Para tanto, o banco de dados foi constituído de 84 imagens para cada classe de hidrofobicidade (HC1 - HC6).

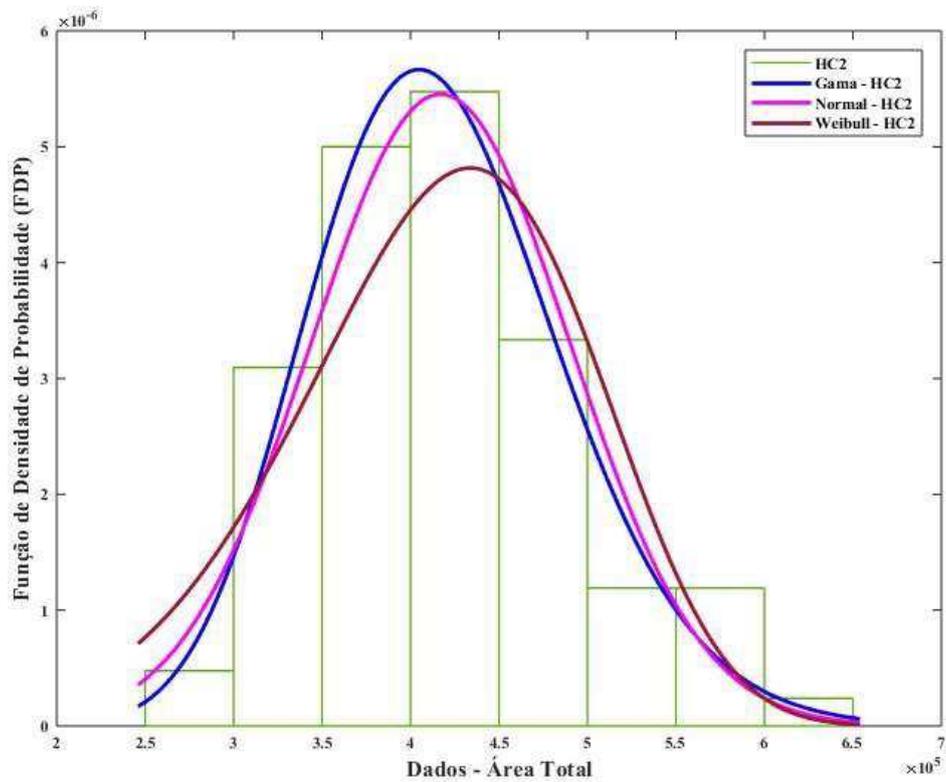
Por meio da análise de distribuição de frequência (histograma) ajustaram-se as funções de densidade de probabilidade (FDP) Gama, Normal e Weibull para as seis classes da hidrofobicidade. As FDP ajustadas para cada nível de hidrofobicidade podem ser visualizadas nas Figura 27 a Figura 32.

Figura 27. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC1.



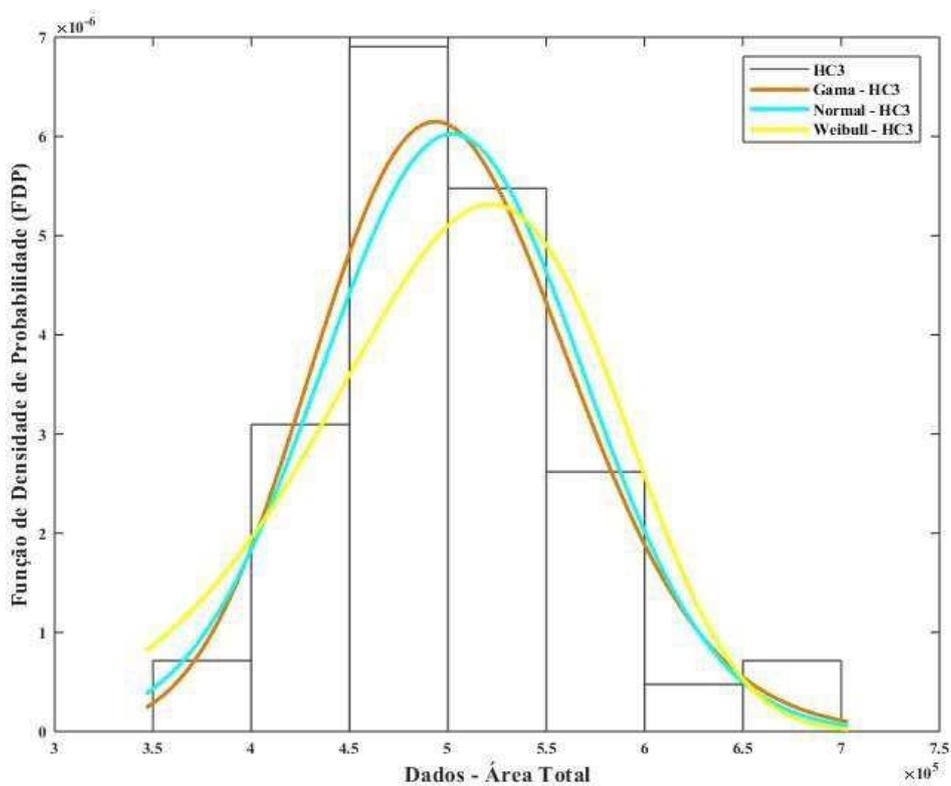
Fonte: Autoria própria.

Figura 28. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC2.



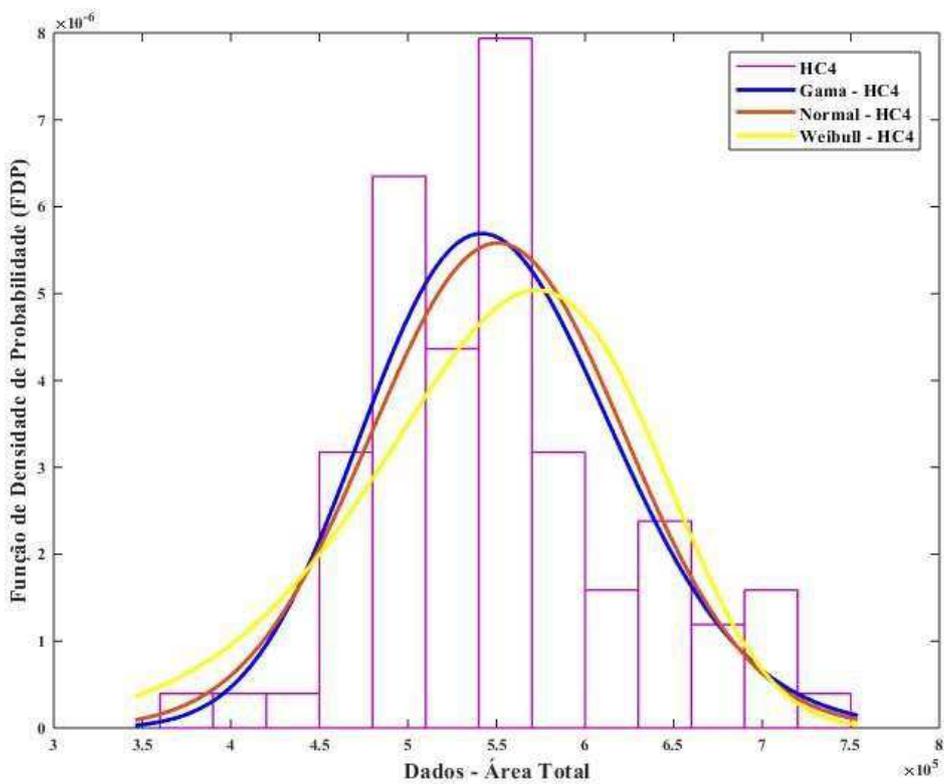
Fonte: Autoria própria.

Figura 29. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC3.



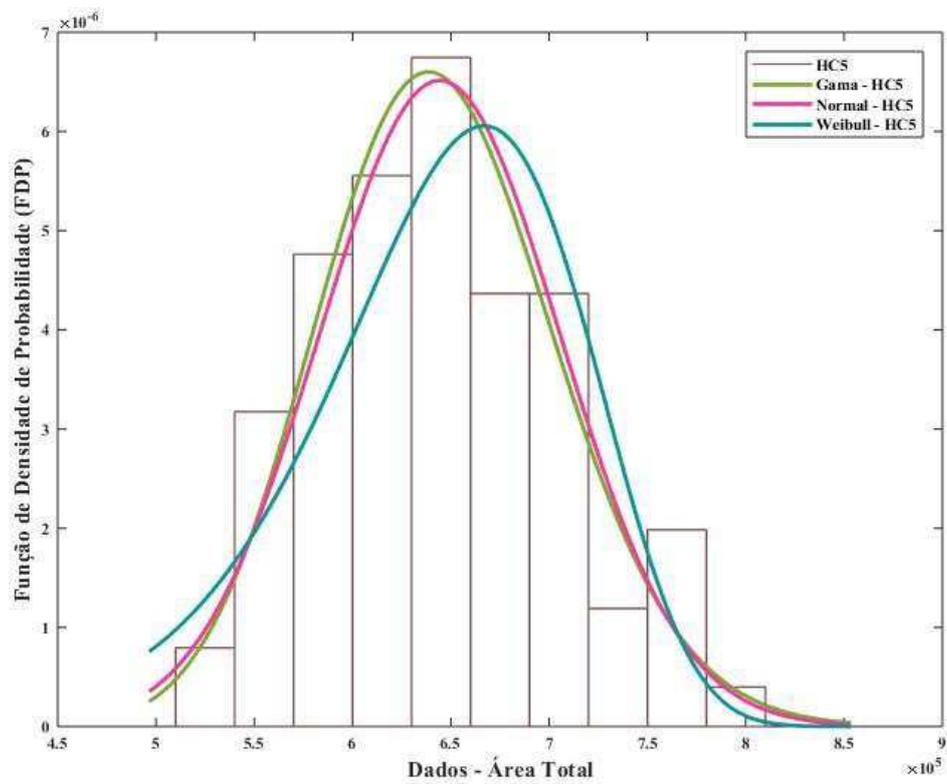
Fonte: Autoria própria.

Figura 30. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC4.



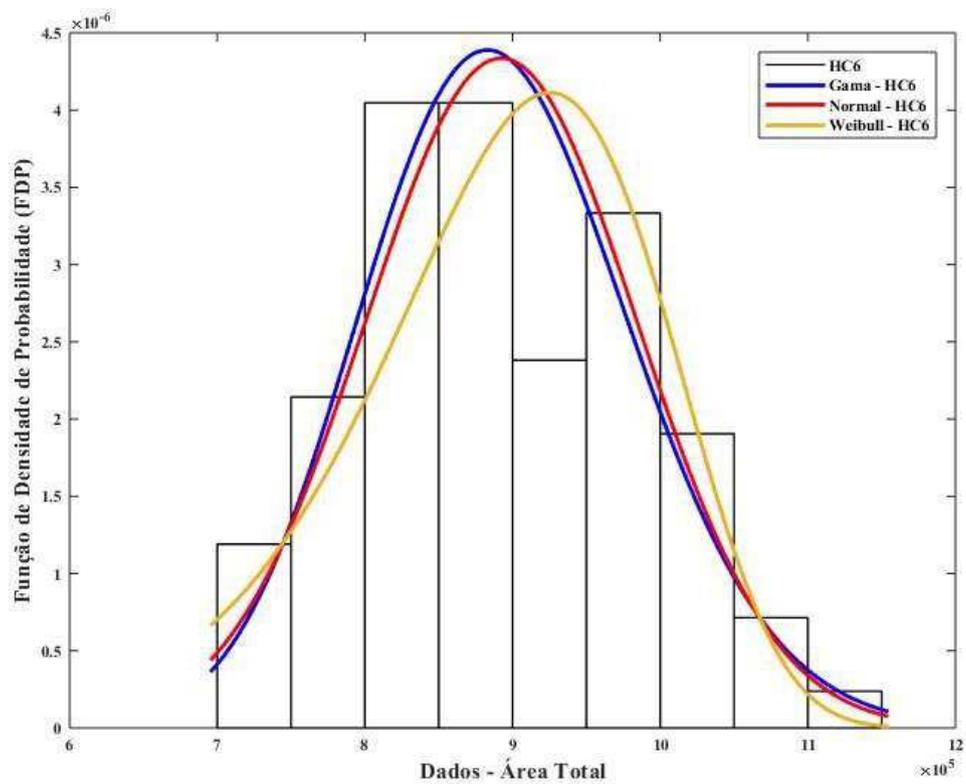
Fonte: Autoria própria.

Figura 31. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC5.



Fonte: Autoria própria.

Figura 32. Funções de densidade de probabilidades sobre o histograma de frequência para o nível HC6.



Fonte: Autoria própria.

Analisando os gráficos dos histogramas com as FDP observa-se visualmente a superioridade das distribuições Gama e Normal na representação aos dados observados. Verifica-se que todas as três FDP apresentaram comportamentos semelhantes com ligeira tendência em subestimar as amostras em todos os níveis de hidrofobicidade.

Nas Tabelas 5 a 10, abaixo, podem ser observadas as estimativas dos parâmetros encontrados nos ajustes das distribuições Gama, Normal e Weibull para cada nível de hidrofobicidade, calculadas utilizando o programa MATLAB®.

Tabela 5. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC1.

Modelo	Parâmetro			
	α	β	μ	σ
Gama	20,0277	1,2585e+04	-	-
Normal	-	-	2,5204e+05	5,7931e+04
Weibull	2,7524e+05	4,5053	-	-

Fonte: Autoria própria.

Tabela 6. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC2.

Modelo	Parâmetro			
	α	β	μ	σ
Gama	34,2459	1,2177e+04	-	-
Normal	-	-	4,1701e+05	7,3147e+04
Weibull	4,4827e+05	5,7773	-	-

Fonte: Autoria própria.

Tabela 7. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC3.

Modelo	Parâmetro			
	α	β	μ	σ
Gama	59,0829	8,4986e+03	-	-
Normal	-	-	5,0212e+05	6,6213e+04
Weibull	5,3153e+05	7,6113	-	-

Fonte: Autoria própria.

Tabela 8. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC4.

Modelo	Parâmetro			
	α	β	μ	σ
Gama	60,9015	9,0422e+03	-	-
Normal	-	-	5,5069e+05	7,1456e+04
Weibull	5,8261e+05	7,9168	-	-

Fonte: Autoria própria.

Tabela 9. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC5.

Modelo	Parâmetro			
	α	β	μ	σ
Gama	112,8862	5,7082e+03	-	-
Normal	-	-	6,4437e+05	6,1228e+04
Weibull	6,7258e+05	11,0283	-	-

Fonte: Autoria própria.

Tabela 10. Estimativas dos parâmetros das distribuições Gama, Normal e Weibull – Nível HC6.

Modelo	Parâmetro			
	α	β	μ	σ
Gama	95,5849	9,3357e+03	-	-
Normal	-	-	8,9235e+05	9,1991e+04
Weibull	9,3425e+05	10,3971	-	-

Fonte: Autoria própria.

A aderência das distribuições para análise dos dados foi realizada segundo o teste de Qui-quadrado (χ^2), como observado nas Tabela 11 a Tabela 16. O uso do teste Qui-quadrado pode ser considerado limitado, pois o teste é sensível à presença de classes com pequenos valores das frequências esperadas.

Tabela 11. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC1.

Modelo	Teste Qui-quadrado (χ^2)	p-valor
Gama	ns	0,3995
Normal	ns	0,0872
Weibull	*	0,0182

Fonte: Autoria própria.

Tabela 12. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC2.

Modelo	Teste Qui-quadrado (χ^2)	p-valor
Gama	ns	0,8088
Normal	ns	0,4062
Weibull	*	0,0399

Fonte: Autoria própria.

Tabela 13. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC3.

Modelo	Teste Qui-quadrado (χ^2)	p-valor
Gama	ns	0,3502
Normal	ns	0,3070
Weibull	*	0,0412

Fonte: Autoria própria.

Tabela 14. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC4.

Modelo	Teste Qui-quadrado (χ^2)	p-valor
Gama	ns	0,0624
Normal	*	0,0338
Weibull	*	8,3893e-04

Fonte: Autoria própria.

Tabela 15. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC5.

Modelo	Teste Qui-quadrado (χ^2)	p-valor
Gama	ns	0,9563
Normal	ns	0,9522
Weibull	ns	8,2722

Fonte: Autoria própria.

Tabela 16. Aderência das distribuições Gama, Normal e Weibull para o teste Qui-quadrado. Em que (*) - significativo e (ns) – não significativo, ao nível de 5% de probabilidade – Nível HC6.

Modelo	Teste Qui-quadrado (χ^2)	p-valor
Gama	ns	0,1919
Normal	ns	0,2675
Weibull	ns	0,1996

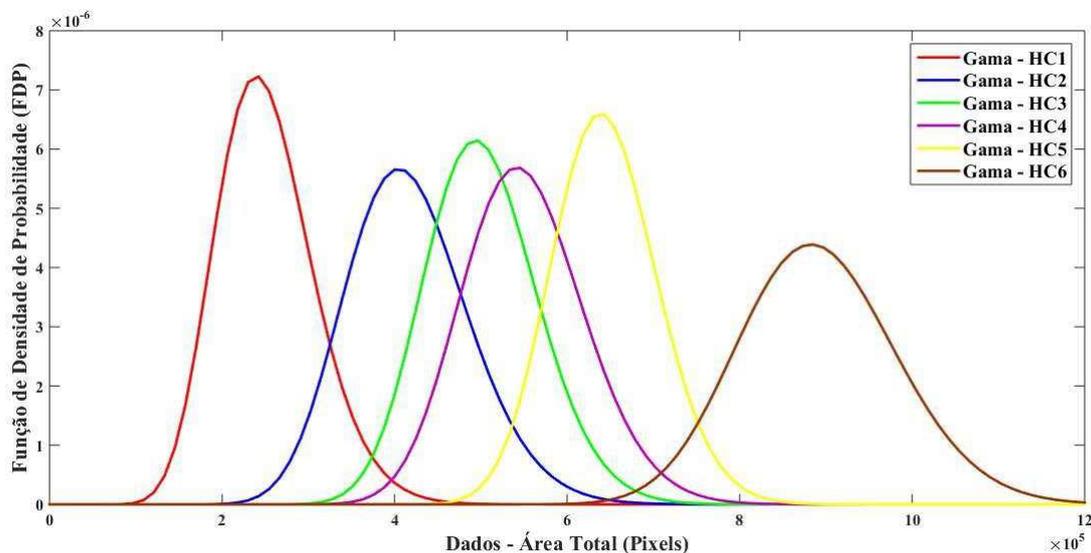
Fonte: Autoria própria.

A aderência da FDP Gama foi comprovada segundo o teste de Qui-quadrado, todos os p-valores foram superiores a 0,05 indicando que a FDP Gama foi a que melhor se adequou aos dados observados da Área Total das Regiões Molhadas, conforme observado nas Tabelas acima. Em particular, as FDP Normal e Weibull não obtiveram aderência em todas as classes de hidrofobicidade, por mais que tenham melhores aderências em determinadas classes HC.

Visando analisar possíveis sobreposições entre as funções de densidade, indicando possíveis erros na classificação HC, foram observados de forma conjunta a

FDP Gama das seis classes de hidrofobicidade. Conforme pode ser observado na Figura 33, todas as classes HC apresentaram áreas de interseção.

Figura 33. FDP Gama dos seis níveis de hidrofobicidade.



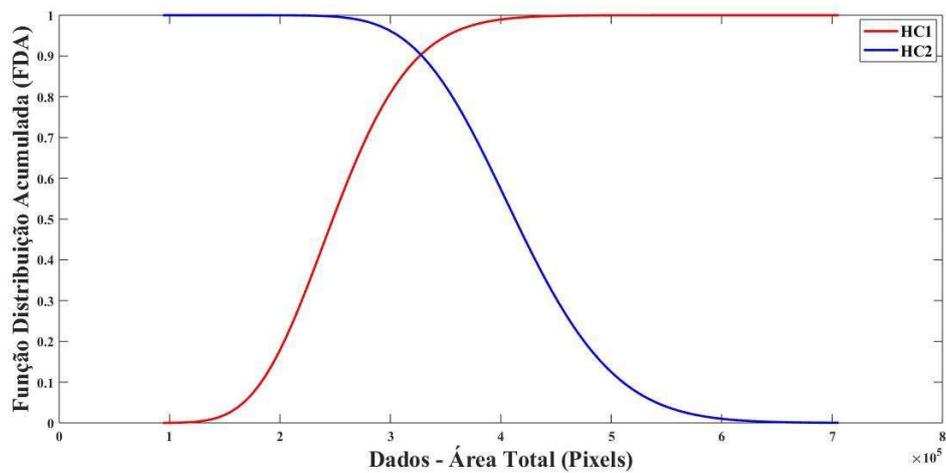
Fonte: Autoria própria.

A área de sobreposição de duas funções de densidade de probabilidade Gama, representa a probabilidade de um dado pertencer a um ou outro nível HC, dependendo da posição do dado em relação a esta distribuição. Ocorre numa região onde as duas curvas sobrepõem-se, indicando que um determinado dado tem igual probabilidade de pertencer às duas classes, conforme apresentado na Figura 33. Nesta situação foi estabelecido um critério de decisão a partir da definição de limiares.

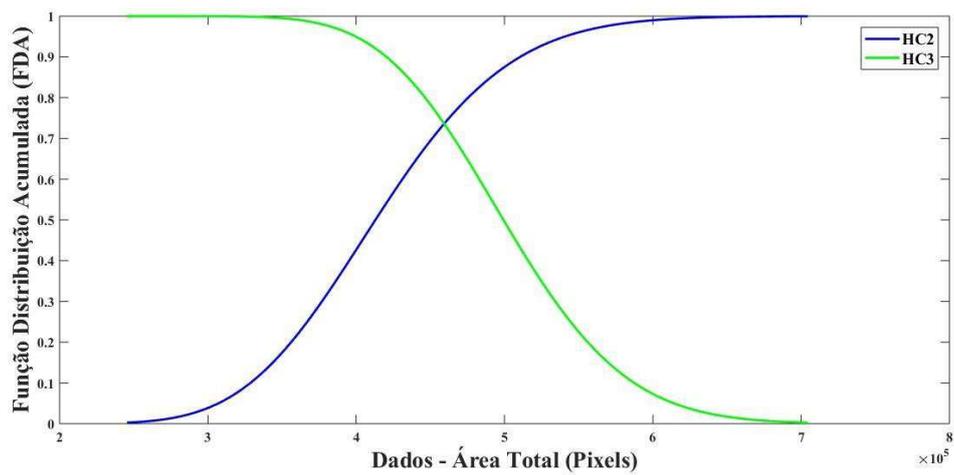
Neste trabalho optou-se por determinar o limiar entre os níveis HC por meio da função de probabilidade acumulada (FDA), para tanto, foram representadas a FDA de uma classe HC e o complementar da FDA da classe HC vizinha. Logo, a probabilidade de confusão entre as duas classes HC será a mesma. Na Figura 34 pode ser visualiza as representações da FDA e o complementar da FDA para os pares HC (HC1-HC2; HC2-HC3; HC3-HC4; HC4-HC5; HC5-HC6), evidenciando que os pontos de interseção entre as FDA correspondem aos liminares das classes HC.

Figura 34. FDA e complementar da FDA para os pares HC: (a) FDA da classe HC1 com complementar da FDA da classe HC2; (b) FDA da classe HC2 com complementar da FDA da classe HC3; (c) FDA da

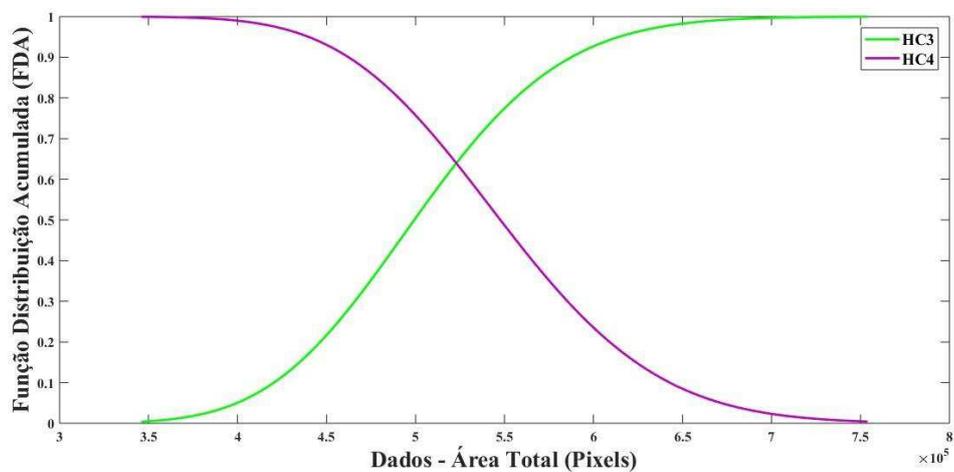
classe HC3 com complementar da FDA da classe HC4; (d) FDA da classe HC4 com complementar da FDA da classe HC5; (e) FDA da classe HC5 com complementar da FDA da classe HC6.



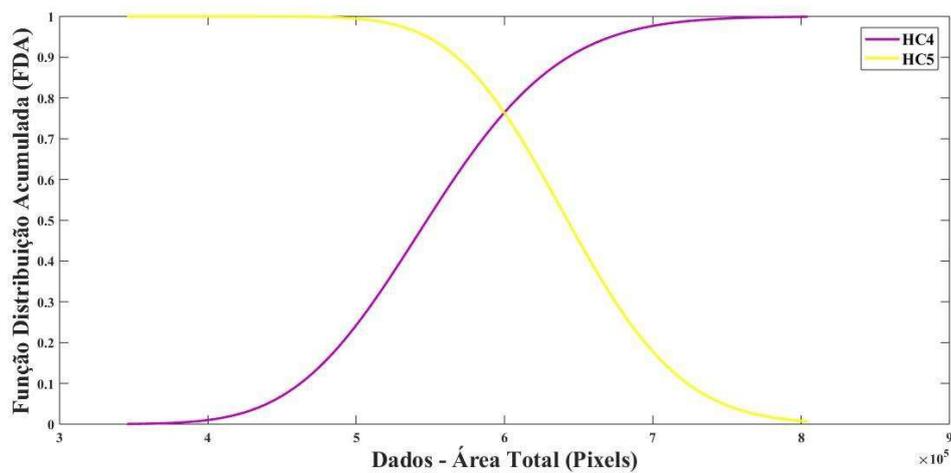
(a)



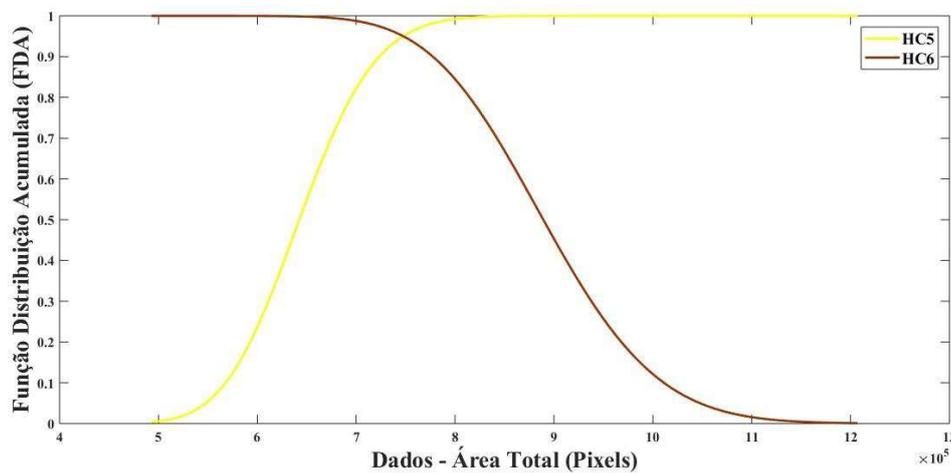
(b)



(c)



(d)



(e)

Analisando as FDA da Figura 34, tem-se os limiares e respectivas taxas de confusão entre as classes analisadas. Na Tabela 17 pode ser visualizado os limiares em *pixels* e em cm^2 e as respectivas probabilidades de confusão.

Tabela 17. Representação das 10 MCs – RNA com 6 neurônios na camada oculta e 68 amostras de teste.

	Limiar (<i>pixels</i>)	Limiar (cm^2)	Probabilidade de confusão
HC1 – HC2	328.900	4,54	10%
HC2 – HC3	458.800	6,34	26%
HC3 – HC4	523.200	7,23	36%
HC4 – HC5	600.500	8,30	24%
HC5 – HC6	745.400	10,30	5%

Fonte: Autoria própria.

Nota-se uma alta probabilidade de confusão entre os níveis HC2, HC3 e HC4. A confusão pode ser justificada pela escolha de classificação preliminar subjetiva e pela degradação não uniforme do material, podendo ter pontos de uma determinando nível e pontos de outro nível em uma mesma região analisada.

5.2.3 REDE NEURAL ARTIFICIAL COM OITO PARÂMETROS DE ENTRADA

Um sistema de rede neural foi desenvolvido e treinado neste trabalho, a fim de classificar os níveis de hidrofobicidade de superfícies poliméricas por meio dos parâmetros extraídos.

Os oitos parâmetros foram extraídos para todas as imagens do banco de dados (450 imagens). Assim, uma matriz de dados com dimensão 450 linhas por 8 colunas foi definida. Esta matriz foi utilizada no treinamento, validação e teste da rede neural artificial. Os percentuais da base de dados destinados ao treinamento, validação e teste da RNA, foram arbitrados da seguinte forma:

- Treinamento - 70% (314 amostras);
- Validação - 15% (68 amostras);
- Teste - 15% (68 amostras).

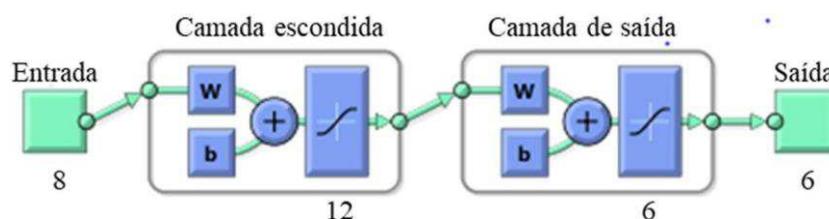
A arquitetura do sistema neural utilizado foi constituída de uma rede do tipo *multilayer feedforward networks* de duas camadas e implementada no *software* MATLAB®. Neste trabalho, foi empregado na camada oculta e na camada de saída a função de ativação não-linear do tipo sigmoidal (logsig), que assume um intervalo contínuo de valores entre 0 e 1 e é definida como uma função estritamente crescente, que exibe um balanceamento adequado entre comportamento linear e não-linear. Para o treinamento, foi utilizado o algoritmo de “Levenberg Marquardt” (LM), sendo as redes projetadas para calcular os pesos sinápticos do MLP empregando aprendizagem por retropropagação do erro.

O desempenho da rede é avaliado pelo erro quadrático médio (MSE – *mean squared error*) que é a média do somatório dos quadrados dos erros de cada caso, tanto do conjunto de treinamento, quanto do conjunto de testes. É normal se adotar a raiz quadrada do erro quadrático médio no cálculo do erro da rede.

De posse dos vetores supracitados, foram avaliadas três topologias distintas de RNA contendo 8 neurônios na camada de entrada (número correspondente a quantidade

de parâmetros extraído de cada imagem), 6 neurônios na camada de saída (número correspondente ao número de classes) e um número variável de neurônios na camada oculta (6, 9 e 12). Na Figura 35 é apresentada a configuração da rede. A finalidade desta etapa foi identificar qual é a configuração de Rede Neural Artificial que apresenta o melhor desempenho no processo de classificação.

Figura 35 Estrutura da RNA.



Fonte: MATLAB®, 2015.

O processo de classificação foi repetido 10 vezes para análises dos resultados. Foram geradas 10 Matrizes de Confusão (MC) para todas as RNA trabalhadas, o valor de acurácia médio pode ser visualizado na Tabela 18. A Matriz de Confusão (MC) pode ser entendida como um tipo de tabela que permite a visualização do desempenho de um algoritmo de aprendizado. As colunas da matriz representam as instâncias de uma classe prevista, enquanto as linhas representam os casos de uma classe real. O somatório das 10 MCs e os respectivos valores de acurácia da classificação por classe podem ser visualizados nas Tabelas 19, 20 e 21.

Tabela 18. Taxa de acerto média das 10 MCs – RNA com 6, 9 e 12 neurônios na camada oculta.

Número de neurônios	Taxa Média de Acerto (%)
6	81,62
9	83,38
12	83,53

Fonte: Autoria própria.

Tabela 19. Representação das 10 MCs – RNA com 6 neurônios na camada oculta e 68 amostras de teste.

	HC1	HC2	HC3	HC4	HC5	HC6	Acertos (%)
HC1	95	7	0	0	0	0	93,14
HC2	9	92	17	4	0	0	75,41
HC3	0	13	70	21	0	0	67,31
HC4	0	0	34	68	5	0	63,55

HC5	0	0	0	6	113	4	91,87
HC6	0	0	0	0	3	119	97,54

Fonte: Autoria própria.

Tabela 20. Representação das 10 MCs – RNA com 9 neurônios na camada oculta e 68 amostras de teste.

	HC1	HC2	HC3	HC4	HC5	HC6	Acertos (%)
HC1	93	6	0	0	0	0	93,94
HC2	6	93	11	2	0	0	83,04
HC3	0	17	72	32	0	0	59,50
HC4	0	1	26	88	9	0	70,97
HC5	0	0	0	0	115	1	99,14
HC6	0	0	0	0	2	106	98,15

Fonte: Autoria própria.

Tabela 21. Representação das 10 MCs – RNA com 12 neurônios na camada oculta e 68 amostras de teste.

	HC1	HC2	HC3	HC4	HC5	HC6	Acertos (%)
HC1	118	5	0	0	0	0	95,93
HC2	9	93	16	2	0	0	77,50
HC3	0	15	57	33	0	0	54,29
HC4	0	0	20	67	2	0	75,28
HC5	0	0	0	6	113	1	94,17
HC6	0	0	0	0	1	122	99,19

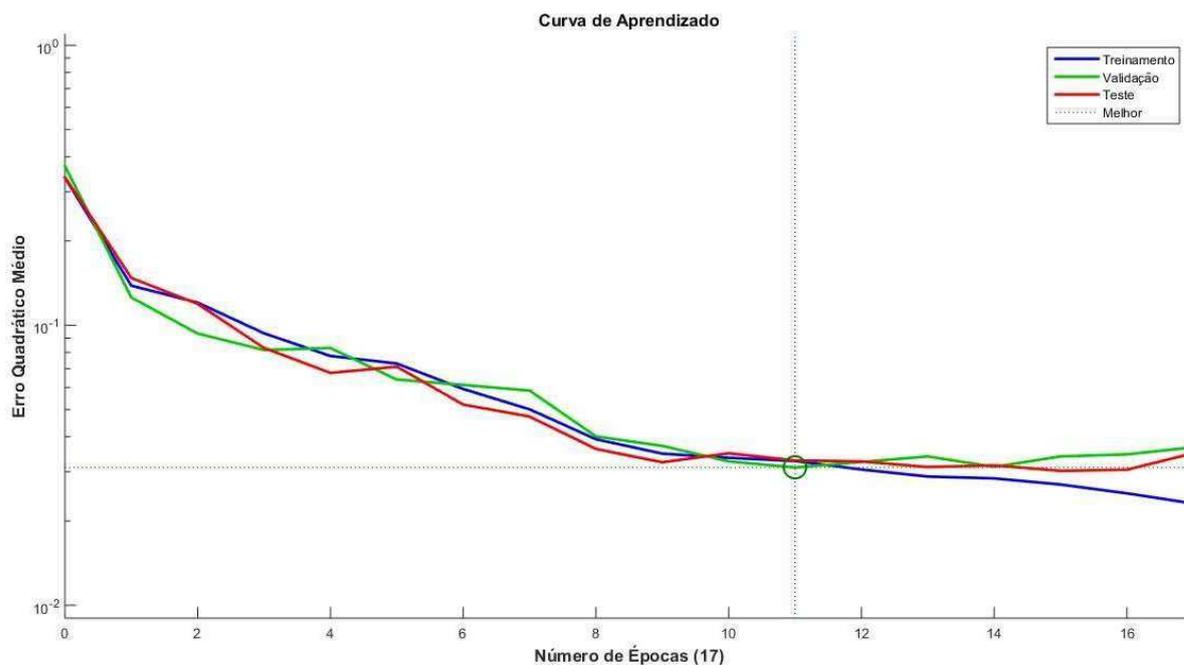
Fonte: Autoria própria.

A partir do valor de acurácia médio e das MCs apresentadas, verifica-se que a Rede Neural Artificial contendo 12 neurônios na camada oculta apresentou um maior valor de acurácia médio, entretanto obteve o menor valor de acurácia para a classe HC3. Pode-se afirmar, pela análise dos resultados que a rede obteve resultados satisfatórios para estimar as classes de hidrofobicidade. No entanto, observa-se que a rede é mais precisa em classificar as classes HC1, HC2, HC4, HC5 e HC6. A classe HC3 não teve um comportamento bem definido, sendo confundido com as classes HC2 e HC4.

Na Figura 36, pode ser visto graficamente o comportamento do erro quadrático para um processo de classificação durante a fase de treinamento da rede para a RNA contendo 12 neurônios na camada oculta e um valor de acurácia de 83,83%. Pode-se notar com clareza a atuação do processo de validação cruzada empregado no treinamento. No início do mesmo os valores de erro de treinamento e validação diminuem praticamente no mesmo ritmo, porém, em um determinado momento, o erro de validação se estabiliza e o erro de treinamento continua a diminuir, indicando a polarização da rede. O

treinamento é então interrompido devido ocorrência deste comportamento em cinco épocas consecutivas, o treinamento apresentado na Figura 36 foi interrompido na época 17.

Figura 36 Curva de Aprendizado para RNA com 12 neurônios.



Fonte: Autoria própria.

O melhor desempenho da RNA ocorre na época 11, apresentando um erro quadrático médio de 0,031062.

5.2.4 REDE NEURAL ARTIFICIAL COM PARÂMETROS DO MÉTODO *STEPWISE*

Analisando os resultados apresentados na seção 5.2.1, optou-se por otimizar a RNA utilizando os parâmetros de entradas obtidos com o método *Stepwise*. Os parâmetros Área Máxima, Área Total, Número de Regiões Molhadas e Fator de Forma apresentaram, para algumas classes, uma correlação.

A partir dos dados dos quatro parâmetros extraídos para todas as imagens do banco de dados, criou-se uma matriz de dados com dimensão 450 linhas por 4 colunas. Esta matriz foi utilizada no treinamento, validação e teste da rede neural artificial. Os percentuais da base de dados destinados ao treinamento, validação e teste da RNA, foram arbitrados de forma semelhante a RNA para 8 parâmetros de entrada.

Assim como a RNA de 8 parâmetros a RNA de 4 parâmetros foi implementada no toolbox do software MATLAB® utilizando a configuração do tipo padrão (*patternnet*). Arquitetura é *feed-forward* de duas camadas, com função de transferência sigmoide. A rede é treinada utilizando o algoritmo de *back-propagation*.

De posse dos vetores supracitados, foram avaliadas três topologias distintas de RNA contendo números diferentes de neurônios na camada oculta (6, 9 e 12). Para a análise dos resultados, foram geradas 10 Matrizes de Confusão para todas as RNA desenvolvidas, o somatório das 10 MCs e os respectivos valores de acurácia da classificação por classe podem ser visualizados nas Tabelas 22, 23 e 24.

Tabela 22. Representação das 10 MCs – RNA com 6 neurônios na camada oculta e 68 amostras de teste.

	HC1	HC2	HC3	HC4	HC5	HC6	Acertos (%)
HC1	115	2	0	0	0	0	98,29
HC2	11	63	29	2	0	0	60,00
HC3	0	15	67	22	0	0	64,42
HC4	0	0	32	77	3	0	68,75
HC5	0	0	0	3	108	0	97,30
HC6	0	0	0	0	13	118	90,08

Fonte: Autoria própria.

Tabela 23. Representação das 10 MCs – RNA com 9 neurônios na camada oculta e 68 amostras de teste.

	HC1	HC2	HC3	HC4	HC5	HC6	Acertos (%)
HC1	96	9	0	0	0	0	91,43
HC2	9	88	20	1	0	0	74,58
HC3	0	23	67	29	0	0	56,30
HC4	0	0	30	76	1	0	71,03
HC5	0	0	0	1	116	2	97,48
HC6	0	0	0	0	0	112	100,00

Fonte: Autoria própria.

Tabela 24. Representação das 10 MCs – RNA com 12 neurônios na camada oculta e 68 amostras de teste.

	HC1	HC2	HC3	HC4	HC5	HC6	Acertos (%)
HC1	104	4	0	1	0	0	95,41
HC2	3	76	9	3	0	0	83,52
HC3	0	21	72	30	0	0	58,54
HC4	0	0	24	95	3	0	77,87
HC5	0	0	0	3	102	3	94,44
HC6	0	0	0	0	0	127	100,00

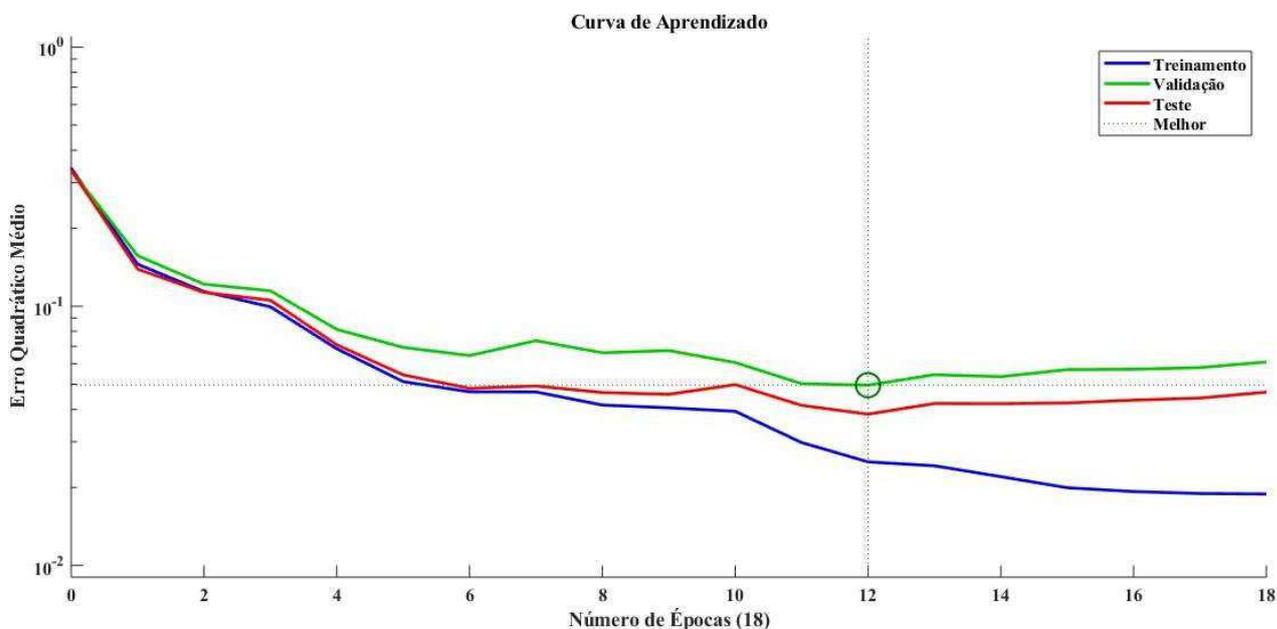
Fonte: Autoria própria.

A partir das MCs apresentadas, verifica-se que a Rede Neural contendo 12 neurônios na camada escondida foi a que apresentou os melhores resultados de saída. O valor da acurácia da classificação foi de 84,96%.

A partir do valor de acurácia médio e das MCs apresentadas, verifica-se que a Rede Neural Artificial contendo 12 neurônios na camada oculta apresentou um maior valor de acurácia médio, entretanto obteve o menor valor de acurácia para a classe HC3. Pode-se afirmar, pela análise dos resultados que a rede obteve resultados satisfatórios para estimar as classes de hidrofobicidade. No entanto, observa-se que a rede é mais precisa em classificar as classes HC1, HC2, HC5 e HC6.

Na Figura 37, pode ser visto graficamente o comportamento do erro quadrático para um processo de classificação durante a fase de treinamento da rede para a RNA contendo 12 neurônios na camada oculta e um valor de acurácia de 86,76%. Pode-se notar com clareza a atuação do processo de validação cruzada empregado no treinamento. O treinamento é então interrompido devido ocorrência deste comportamento em cinco épocas consecutivas, o treinamento apresentado na Figura 37 foi interrompido na época 18.

Figura 37. Curva de Aprendizado para RNA com 12 neurônios – 4 parâmetros de entrada.



Fonte: Autoria própria.

O melhor desempenho da RNA ocorre na época 12, apresentando um erro quadrático médio de 0,049596. Conforme observado, a RNA com 4 parâmetros

apresentou desempenho similar da RNA com 8 parâmetros ressaltando a não significância de alguns parâmetros.

Neste capítulo foram apresentados os resultados obtidos e suas respectivas análises. No capítulo seguinte serão apresentadas as considerações finais da proposta e os trabalhos que podem ser desenvolvidos no futuro.

6 CONCLUSÃO

Neste trabalho foi desenvolvido e aplicado com êxito o algoritmo em processamento digital de imagens para identificação de regiões molhadas e extração de parâmetros matemáticos, e os algoritmos de tomada de decisão automática conforme a classificação do guia STRI. A extração de parâmetros, por meio do processamento digital de imagens, permitiu traçar um comportamento da classificação das diferentes classes de hidrofobicidade, sendo desenvolvida uma ferramenta de diagnóstico totalmente automática.

O banco de dados foi constituído de forma estruturado com diversos níveis de hidrofobicidade (HC1 – HC6) classificadas por meio da metodologia subjetiva e do PDI. O banco de dados robusto contribuiu para o aprimoramento da ferramenta e modelos utilizados na classificação da hidrofobicidade, evitando a subjetividade de uma única pessoa, além de ter como consequência a agilidade no diagnóstico da situação operacional dos isoladores elétricos em campo.

A metodologia, representada pelo estudo, avaliação e classificação da hidrofobicidade, foi proposta, desenvolvida e testada. Desse modo, pode-se concluir que a metodologia de extração de parâmetros e classificação HC resultou na consolidação da ferramenta, cujos resultados foram verificados nas análises linear e probabilística.

A análise linear representada pelo coeficiente de correlação linear de Pearson e pelo método *Stepwise* reduziu e modelou, de forma eficiente, os parâmetros necessários para a tomada de decisão, sem perda significativa de informação, ou seja, não prejudicando a compreensibilidade do modelo obtendo parâmetros não correlacionadas.

De acordo com as análises, probabilística e a RNA, realizadas para as seis classes HC, entende-se que a classe HC3 apresentou menor taxa de confiabilidade na classificação, tanto na classificação via Redes Neurais quanto nos limiares observados na FDP Gama. Esta confusão na classificação deve-se à degradação não uniforme do material e também à possível dificuldade dos colaboradores em identificar as imagens classificadas como HC3 de acordo com a imagem referência do guia STRI.

O modelo de Redes Neurais apresentou desempenho similar ao modelo probabilístico, apresentando taxas de confusão próximas (taxa de confusão média de 20,2% para o modelo probabilístico e 18,4% para RNA ótima). Ressalta-se que a RNA

com quatro parâmetros de entrada apresentou desempenho muito próximo da RNA com oito parâmetros, salientando a significância dos parâmetros: Área Total, Área Máxima, Número de Regiões Molhadas e Fator de Forma.

Pelo exposto, conclui-se assim, que a ferramenta computacional automática foi desenvolvida com êxito para classificação da hidrofobicidade de isoladores elétricos poliméricos de alta tensão. Assim, esta ferramenta se apresenta como uma técnica eficiente no auxílio à tomada de decisões quanto à necessidade de intervenção ou não aos isoladores.

7 TRABALHOS FUTUROS

Com os objetivos da dissertação atingidos, novos estudos podem ser desenvolvidos com o intuito de dar continuidade à pesquisa, uma vez que, para a elaboração de um sistema computacional otimizado de tomada de decisão são necessárias análises e modelagens das variáveis matemáticas, ambientais e externas. Assim, sugerem-se como trabalhos futuros as seguintes atividades:

- Desenvolver um banco de dados de hidrofobicidade dos isoladores de campo e com degradação natural;
- Associar a medição de hidrofobicidade a outras técnicas de monitoramento, tais como a medição de radiação infravermelha, radiação ultravioleta, poluição e corrente de fuga;
- Desenvolver e validar o modelo de distribuição de probabilidade que represente das variáveis ambientais e variáveis matemáticas na classificação da degradação dos isoladores elétricos poliméricos;
- Elaborar algoritmos mais robustos de segmentação das imagens, especialmente para quando os isoladores se encontram em campo;
- Desenvolver um sistema otimizado e automatizado para classificação da hidrofobicidade em isoladores em campo, levando em consideração metodologia que correlacione variáveis matemáticas, ambientais e externas.

PUBLICAÇÕES

Durante a elaboração desta dissertação foram publicados os seguintes artigos científicos.

- ALVES, L. N. T.; COSTA, E. G.; OLIVEIRA NETO, A. B.; NOBREGA, R. B.; FERREIRA, T. V. **Electrical Insulators Hydrophobicity Classification using Digital Image Processing**. In: 20th International Symposium on High Voltage Engineering, 2017, Buenos Aires.
- XAVIER, G. V.; COSTA, E. G.; DIAS, R.; FERREIRA, R. S.; ALVES, L. N. T.; SOUSA, H. F. **Dielectric Characteristics Comparison Of Insulating Babaçu's Grain Vegetable Oil And Transformers Mineral Oil**. In: 20th International Symposium on High Voltage Engineering, 2017, Buenos Aires.
- NOBREGA, R. B.; COSTA, E. G.; GERMANO, A. D.; ALVES, L. N. T.; BEZERRA, D. C.; COSTA, A. C. F. M. **Analysis of an Alternative Filler for RTV Silicone Rubber Coatings Applied in Outdoor Insulation**. In: 20th International Symposium on High Voltage Engineering, 2017, Buenos Aires.
- SANTOS, A. S. S.; ALVES, L. N. T.; SOUSA, H. F.; OLIVEIRA NETO, A. B. **Análise Energética dos Resíduos Orgânicos Proveniente do Restaurante Universitário da Universidade Federal de Campina Grande**. In: 8º Simpósio Internacional sobre Gerenciamento de Resíduos em Universidades, 2017, Campina Grande.

REFERÊNCIAS

ALMIRALL, I. P. **Empleo Conjunto de Cargas Micrométricas y Nanométricas para Mejorar el Desempeño de la Silicona Vulcanizada a Temperatura Ambiente Empleada para Recubrir el Aislamiento Externo**. Tese de Doutorado. Instituto Superior Politécnico José Antônio Echeverría, 2013.

ALVES, L. N. T. **Algoritmo em Processamento Digital de Imagens para Auxiliar a Classificação da Hidrofobicidade em Isoladores Elétricos**. Trabalho de Conclusão de Curso. Universidade Federal de Campina Grande (UFCG), Campina Grande, Junho de 2016.

AURA CONCI, E. A.; LETA, F. R. **Computação gráfica**. Elsevier, 2 edition. 2008.
BARROS, R. M. R.; FERREIRA, T. V.; COSTA, E. G. **Determinação de posicionamento ótimo de anel equalizador em Isoladores Poliméricos**. Ingeniería Energética, V. XXXIV, N. 2, 2013, p. 89-94.

BAPTISTELLA, M. **O uso de redes neurais e regressão linear múltipla na engenharia de avaliações: determinação dos valores venais de imóveis urbanos**. Dissertação de Mestrado. Programa de Pós-Graduação em Métodos Numéricos em Engenharia. Universidade Federal do Paraná, 2005.

BERG, M.; THOTTAPPILLIL, R.; SCUKA, V. **Hdrophobicity estimation of HV polymeric Insulating Materials – Development of a digital image processing method**, IEEE Trans. on Dielectric and Electrical Insulation, v. 8, n. 6., p. 1098-2007, 2001.

BLACKMORE, P.; BIRTWISTLE, D. **Surface discharges on polymeric insulator shed surfaces**. Journal IEEE Transactions on Dielectrics and Electrical Insulation; vol.4, no.2, p.210-17;1997.

BOGORODITSKY, N. P.; PASYNKOV, V. V.; TAREEV, B. M. **Eletrical Engineering Materials**, Editora Mir, 1979.

BRADWELL, A. **Importance of preventing moisture ingress to polymeric insulators**. Electric Power Applications, IEE Proceedings B, v.131, n.6. Novembro, 1984.

BRAINI, S. **Coatings for outdoor high voltage insulators**. 2013. Tese de Doutorado. Cardiff University.

BRAGA, A. P.; CARVALHO A. C.; LUDERMIR T. B. **Redes Neurais Artificiais**, In Rezende, S. O. (Coordenadora) Sistemas Inteligentes: Fundamentos e Aplicações. Editora Manole, Barueri, SP, 525 p., p. 141-168, 2003.

BRITO, S. F.; CARVALHO, J. M. **Sistemas de Processamento Digital de Imagens para Fins Didáticos/Científicos: Estudo, Seleção e Implementação de Algoritmos de Segmentação**. Relatório de iniciação científica, 1998.

- CAMPOS, H. **Estatística experimental não-paramétrica**. 4.ed. Piracicaba: ESALQ, 1983. 349 p.
- CATALUNHA, M.J.; SEDIYAMA, G.C.; LEAL, B.G.; SOARES, C.P.B.; RIBEIRO, A. **Aplicação de cinco funções densidade de probabilidade a séries de precipitação pluvial no Estado de Minas Gerais**. Revista Brasileira de Agrometeorologia, v.10, p.153-162, 2002
- CHEN, X.;LI, C.; HUANG, X.; ZHAO, L.; SONG, W. **On-line Estimating the Level of Hydrophobicity of Composite Insulators Using the Digital Images**.Electrical Insulation Conference and Electrical Manufacturing Expo, 2005.
- CHONG, IL-GYO, JUN, CHI-HYUCK. **Performance of some variable selection methods when multicollinearity is present**. Chemometrics and Intelligent Laboratory Systems, v. 78 p. 103, 2005.
- CORDEIRO, H. H. **Modelos probabilísticos aplicados à biometria**. Dissertação de mestrado. Universidade Federal Rural de Pernambuco, Recife, 2005.
- CORREIA, R. U.; PRETTE, A. L. G.; ALARCON, O. E.; FREDEL, M. C. **Esmaltes semicondutores a base de SO₂ para uso em isoladores elétricos em alta tensão**. Citenel, 2007.
- DENG, H.; HACKAM, R.; CHERNEY, E.A. **Effects of addition of silicone fluid on electrical performance of rtv silicone rubber coatings**. IEEE 5th International Conference on Conduction and Breakdown in Solid Dielectrics, 1995.
- DINIZ, L.S. **Regionalização de parâmetros de modelo chuva-vazão usando redes neurais**. Tese de Doutorado em Engenharia de Recursos Hídricos e Saneamento Ambiental. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.
- DONG, Z.; FANG, Y.; WANG, X.; ZHAO, Y.; WANG, Q. **Hydrophobicity classification of polymeric insulators based on embedded methods**.Materials Research, v. 18, n. 1, p. 127-137, 2015.
- EHSANI, M.; BORSI, H.; GOCKENBACH, E.; MORSHEDIAN, J.; BAKHSHANDEH, G. R.; SHAYEGANI, A. A. **Effect of Aging on Dielectric Behavior of Outdoor Polymeric Insulators**. IEEE International Conference on Solid Dielectrics. Julho 2004.
- ESQUEF, I. A.; ALBUQUERQUE, M. P. de **Processamento digital de imagens**. Centro Brasileiro de Pesquisas Físicas, Rio de Janeiro, 2003, p. 12.
- FAUSETT, L. **Fundamentals of Neural Networks - Architectures, algorithms and applications**. Prentice Hall, New Jersey, 1994.
- FERREIRA, T. V. **Estimação Inteligente da Poluição de Isolamentos Elétricos Baseada nos VECSE do Ruído Ultrassônico**.Tese de Doutorado. Universidade Federal de Campina Grande, UFCG, 2011

GODOY, J. **Estudo de um novo compósito madeira-resina poliuretana para o desenvolvimento de um isolador híbrido**. Tese de Doutorado. Universidade de São Paulo, 2007.

GORUR, R. S.; CHERNEY, E. A.; BURNHAM, J. T. **Outdoor insulators**. Phoenix: R. S. Gorur, 1999. p. 262.

GONZALEZ, R. WOODS, P. **Digital Image Processing**. Prentice Hall, 2nd ed. 2002.

GUIDE, S. T. R. I. 92/1. **Hydrophobicity classification guide**, 1992.

HALL, J.F. **History and bibliography of polymeric insulators for outdoor applications**. IEEE Transactions on Power Delivery. Volume: 8, Issue: 1, Jan. 1993. Pags: 376 – 385.

HAYKIN, S. **Redes neurais, princípios e prática**. 2ª Edição. ed. Porto Alegre: Bookman, 2001.

IEC, T. S. 62073. **Guidance on the measurement of wettability of insulator surfaces**, v. 1, p. 2003-06, 2003.

JIZ, Z.; GUAN, Z.; **The discharge along hydrophobic and hydrophilic surfaces**. International Symposium on Electrical Insulation. IEEE, 2002.

KHALAYLI, L.; SAGBAN, H. A.; SHOMAN, H.; ASSALEH, K.; EL-HAG, A. **Automatic inspection of outdoor insulators using image processing and intelligent techniques**. In: Electrical Insulation Conference (EIC), 2013 IEEE. IEEE, 2013. p. 206-209.

KIKUCHI, T.; NISHIMURA, S.; NAGAO, M.; IZUMI, K.; KUBOTA, Y.; SAKATA, M. Survey on the Use on Non-Ceramic Composite Insulator, **Trans. On Dielectric and Electric Insulation**, v. 6, n. 5, 1999, p. 548-556.

KIM, S.H.; CHERNEY, E.A. e HACKAM, R. **Effects of filler level in RTV silicone rubber coatings used in HV insulators**. IEEE Transactions on Electrical Insulation, v. 27, n. 6, 1992, p. 1065 – 1072.

LEVINE, D.M; BERENSON, M.L.; STEPHAN, D. **Estatística: Teoria e Aplicações**. Rio de Janeiro: LTC, 2005.

LIEBERMANN, J. **Electric behavior of porcelain insulators in polluted environments**. *American Ceramic Society Bulletin*, v. 81, n. 6, 2002.

LIEBERMANN, J. **New effective ways toward solving the problem of contamination of porcelain insulators**. *Refractories and Industrial Ceramics*, v.43, n.1-2, p.55-64. 2002.

LYMAN, W. J.; ROSENBLATT D. H.; REEHL, W. J., **Handbook of Chemical Property Estimation: Environmental Behavior of Organic Compounds**, American Chemical Society, Washington: Mcgraw-Hill, 1990, p. 960.

MACKEV, J.; SHAH, M.; **Polymer outdoor insulating materials part I: comparison of porcelain and polymer electrical insulation.** IEEE Electrical Insulation Magazine, v. 13, n. 3, 1997.

MCCULLOCH, W.; PITTS, W. **A logical calculus of ideas immanent in nervous activity.** Bulletin of Mathematical Biophysics, vol. 5, pp. 115–133, 1943.

MELO, R. G. C. **Using Fractal Characteristics such as Fractal Dimension, Lacunarity and Succolarity to Characterize Texture Patterns on Images.** Tese de Doutorado. Universidade Federal Fluminense, 2005.

NERI, M. G., DA COSTA, E. G., GARCIA, R. W. PAIVA, O. L. **Avaliação de Técnicas de Monitoramento de Isoladores Poliméricos.** 2005.

NOBREGA, R. B. **Avaliação de uma Nova Carga na Composição de Revestimentos Externos Aplicados em Isoladores de Alta Tensão.** Dissertação de Mestrado. Universidade Federal de Campina Grande, Campina Grande PB, 2016.

NUNES, P.G.A. **Uma nova técnica para seleção de variáveis em calibração multivariada aplicada às espectrometrias uv-vis e nir.** Tese de Doutorado em Química. Universidade Federal da Paraíba, João Pessoa, 2008.

OSÓRIO, F. S. **Redes neurais - aprendizado artificial.** Forum de I.A., Canoas: ULBRA, 1999.

QUEIROZ, J. E. R.; GOMES, H. M. **Introdução ao Processamento Digital de Imagens.** Revista Rita, v. VIII, n. 1, 2001.

REINKE, M. **Utilização de redes neurais artificiais aplicadas a mapeamento hidrogeológicos.** Dissertação de Mestrado em Geologia. Universidade do Vale do Rio dos Sinos. São Leopoldo, 2008.

RODRIGUES, J. A. **Distribuições bivariadas Gama, Exponencial e a distribuição Beta tipo II univariada aplicadas a dados de precipitação pluviométrica.** Tese de Doutorado. Universidade Federal de Lavras, Lavras - MG, 2012.

SANTOS FILHO, J. A. **Utilização de redes neurais artificiais em classificação autônoma de peças metálicas empregando imagens radiográficas aplicáveis a sistemas IVA.** Dissertação de Mestrado. Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2006.

SILVA, A. B. M. **Redes Neurais Artificiais, Análise de Sensibilidade e o Comportamento De Funções de Comércio Exterior do Brasil.** Tese de Doutorado. Universidade Federal do Rio Grande do Sul, 2002.

SILVA, K. M. **Diagnóstico de Faltas em Linhas de Transmissão Baseado em Redes Neurais Artificiais e Transformada Wavelet.** Campina Grande: Departamento de Engenharia Elétrica, Universidade Federal da Paraíba, 2005. Dissertação de Mestrado.

SILVA, P. P. J. C. G. P. O. **Inspeção da degradação nos isoladores de compósito de linhas de transmissão através de ensaios não destrutivos**. Dissertação de Mestrado. Universidade Federal de Pernambuco, 2009.

SPRING, G. CAMARA, R. C. M. SOUZA, U. M. FREITAS, J. Garrido, **Integrating Remote Sensing and GIS by Object Oriented Data Modeling**. Computers & Graphics, 1996, p. 395-403.

STIGLER, S. M. **Karl Pearson and the Rule of Three**. Department of Statistics, University of Chicago, 2011.

THOMAZINI, D. **Classificação da hidrofobicidade em isoladores elétricos poliméricos de alta tensão**. Tese de Doutorado. Escola de Engenharia de São Carlos da Universidade de São Paulo, 2009.

THOMAZINI, D.; GELFUSO, M. V. e ALTAFIM, R. A. C. **Hydrophobicity classification of polymeric materials based on fractal dimension**. Materials Research. 2008; 11(4):415-419. [http:// dx.doi.org/10.1590/S1516-14392008000400006](http://dx.doi.org/10.1590/S1516-14392008000400006).

VALENÇA, M. **Fundamentos das Redes Neurais**. Olinda - PE, Brasil: Livro Rápido, 2009. ISBN 978-85-7716-342-7.

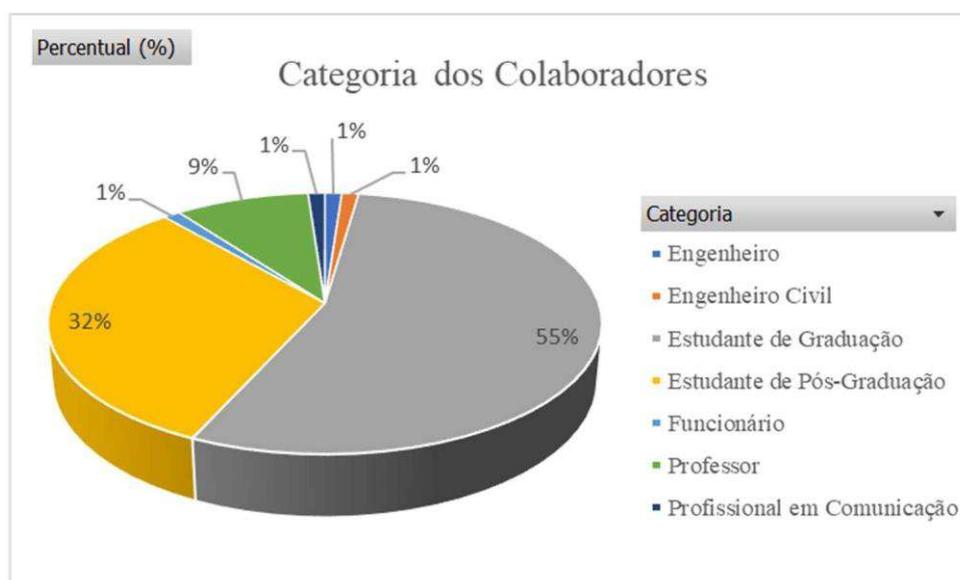
WANG, Q.; Huang, Y.; Mo, X.; Lai, W.; Dong, H.; Yang, Y.; Liu, J.; Huang, Sun, Y. **The Study of the Improved Multilayer Perceptron Algorithm on Hydrophobicity Detection Research of Composite Insulator Bushing**. In: Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2016 8th International Conference on. IEEE, 2016. p. 438-441.

APÊNDICE A

A pesquisa para classificação da hidrofobicidade via o guia STRI foi realizada de modo que os colaboradores avaliassem a similaridade das imagens fotografadas (enviadas) com as imagens padrão presente no guia STRI, sendo um recurso para tentar eliminar a subjetividade de uma única pessoa.

A pesquisa obteve a participação dos 88 colaboradores vinculados aos cursos de engenharia. Conforme pode ser visualizado na Figura 1, 55% dos colaboradores correspondem aos alunos de graduação em engenharia elétrica e 32% dos colaboradores correspondem aos alunos da Pós-Graduação em engenharia elétrica, os demais 13% estão dispersos entre professores, funcionários e engenheiros.

Figura 1. Categoria dos Colaborados - Percentual.



Fonte: Autoria própria.

Os nomes e as respectivas instituições de todos os colaboradores pode ser visualizado na Tabela 1. Ressalto o meu agradecimento a todas as pessoas que se dispuseram a colaborar com este trabalho.

Tabela 1. Colaboradores e respectivas instituições.

Nome	Instituição
Yuri Loia	UFCG
Henrique N. Santana	UFCG

Arthur Francisco Andrade	UFCG
Regelii Suassuna	UFCG
Ítalo de Oliveira Medeiros	UFCG
Adriano Costa de Oliveira	UFCG
Ramon Araújo Dias	UFCG
Augusto Cesar Beserra Gomes	UFS
Paulo Ricardo Gomes Gois Silva	UFS
George Victor Rocha Xavier	UFCG
Paulo	UFS
Guilherme	UFS
Newton Costa	UFS
Paulo Victor	UFS
Aline	UFS
João Jenisson	UFS
Jugurta Montalvão	UFS
José Lucas da Silva	UFS
Raissa	UFS
Amaury	UFS
Helem Monyelle de Mélo Alves	UFCG
Petersson	UFS
Almir	UFS
Sérgio Augusto Silveira Oliveira	Tribunal de Justiça de Sergipe
Caian Menezes Santos	UFS
Inácio	UFS
Bianca de Souza Neves	UFS
Graziella	UFS
Gregory	UFS
Ingrid	UFS
Daniel Obdoral Lopes de Siqueira	UFS
Ana Laura Brasileiro Santos	UFS
Raphael Borges da Nóbrega	UFCG
Thiago Gomes de Lima	UFS
Natasha Rusty	UFS
Kal-El Basílio Brito	UFCG
Herbet Filipe dos Santos Sousa	UFCG
Harrison Batista de Lima	UFCG
Bruno Dias	UFCG
Ítalo André Cavalcanti de Oliveira	UFCG
Moisés	UFCG
Marcus Tullius Barros Florentino	UFCG
Bruna Larissa Lima Crisostomo	UFCG
Wellington Santos Mota	UFCG
Filipe Lucena	UFCG
Jônatas	UFS
Raphael Borges da Nóbrega	UFCG
Raimundo Carlos Silvério Freire	UFCG
Laysa Lúcia de Souza	UFCG
Aylla Echily	UFCG

Tony Cavalcanti	UFCEG
Saulo Oliveira Dornellas Luiz	UFCEG
Rhavel Batista	UFCEG
Valmir	UFCEG
Bianca Porto	UFCEG
Marcus Marinho	UFCEG
Natália Medeiros	UFCEG
André Luiz de Jesus Dias	UFS
Alberto Jesús Gutiérrez Aguayo	UFSC
Hieron Giacomini	UFSC
Dianne	UFSC
Cícero Rômulo Campos de Amorim Filho	UFCEG
Filipe Ribeiro Rocha	UFSC
William de Jesus Kremes	UFSC
Rodolfo Cardoso Buontempo	FATEC / UNICAMP / CBPol
Janaína Esmeraldo Rocha	UFSC
Ana Luiza Scharf	UFSC
Erika Pequeno	UFSC
Talita	UFSC
Geórgia Cristina da Costa Kumlehn	UFSC
André	UFSC
Yuri Berwanger	UFSC
Leonardo	UFSC
Artur Burnier	UFSC
Danilo Rodrigues Fortes Ribeiro	UNIFEI
Thiago Arantes Nogueira	LAT - EFEI
Natália	UFSC
Arthur de Araújo Farias	UFCEG
Edson L M Neto	IFS
Renato Pinto de Andrade Filho	UFCEG
Ricardo Wesley Salles Garcia	CEPEL
Ígor Almeida	UFCEG
Caroline	UFS
Amanda	UFS
Ana Lara Araújo Santos	UFS
Monice	UFS
Larissa Karine de Oliveira Santos	UFS
Fraíse Passos	UFS

Fonte: Autoria própria