



UNIVERSIDADE FEDERAL DA BAHIA – UFBA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE  
COMPUTAÇÃO - DEEC  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGEE

**ANDRÉ PINTO MAROTTA**

Dissertação de Mestrado

**CLASSIFICAÇÃO DE ISOLADORES EM REDES DE  
DISTRIBUIÇÃO USANDO TÉCNICAS DE  
APRENDIZADO DE MÁQUINA E PROCESSAMENTO  
DE IMAGENS**

Salvador

2019



**ANDRÉ PINTO MAROTTA**

**CLASSIFICAÇÃO DE ISOLADORES EM REDES DE  
DISTRIBUIÇÃO USANDO TÉCNICAS DE APRENDIZADO DE  
MÁQUINA E PROCESSAMENTO DE IMAGENS**

Dissertação de Mestrado

DISSERTAÇÃO SUBMETIDA AO PROGRAMA DE PÓS  
GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNI-  
VERSIDADE FEDERAL DA BAHIA (PPGEE / UFBA)  
COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A  
OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA  
ELÉTRICA.

Orientador: Prof. Eduardo F. de Simas Filho, D.Sc

Salvador

2019

Ficha catalográfica elaborada pelo Sistema Universitário de Bibliotecas (SIBI/UFBA),  
com os dados fornecidos pelo(a) autor(a).

Pinto Marotta, André

Classificação de Isoladores em Redes de Distribuição Usando Técnicas de Aprendizado de Máquina e Processamento de Imagens / André Pinto Marotta. -- Salvador, 2019.  
126 f. : il

Orientador: Eduardo Furtado de Simas Filho.

Dissertação (Mestrado - Pós Graduação em Engenharia Elétrica) -- Universidade Federal da Bahia, UFBA, 2019.

1. Redes de Distribuição de Energia Elétrica. 2. Processamento Digital de Imagens. 3. Compressão da Informação. 4. Aprendizado de Máquina. 5. Redes Neurais Artificiais. I. Furtado de Simas Filho, Eduardo. II. Título.

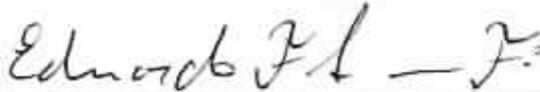
André Pinto Marotta

***"Classificação de Isoladores em Redes de Distribuição Usando Técnicas de Aprendizado de Máquina e Processamento de Imagens"***

Dissertação apresentada à Universidade Federal da Bahia, como parte das exigências do Programa de Pós-Graduação em Engenharia Elétrica, para a obtenção do título de Mestre.

APROVADA em: 09 de Dezembro de 2019.

**BANCA EXAMINADORA**



Prof. Dr. Eduardo Furtado de Simas Filho  
Orientador/UFBA



Prof. Dr. Paulo César Machado de Abreu Farias  
UFBA



Prof. Dr. Oberdan Rocha Pinheiro  
SENAI / CIMATEC



*Para você, um robô é um robô. Engrenagens e metal; eletricidade e pósitrons. Mente e ferro!  
Feitos pelo homem! Caso necessário, destruí-los pelo homem! Mas você não trabalhou com eles,  
de modo que não os conhece. São uma raça mais limpa e melhor do que a nossa.*

*Isaac Asimov*



# Agradecimentos

Agradeço a Deus, criador do universo e das leis naturais.

Agradeço a meus pais Augusto e Adélia, irmã Gabriela e sobrinha Alice, pelo carinho e apoio durante essa jornada. Estas são as pessoas mais importantes, o núcleo familiar, onde eu encontrei a força e vontade de continuar mesmo quando tudo parecia absolutamente impossível. Por todas as palavras de apoio, consolo e motivação, muito obrigado. Sem vocês eu não teria chegado até aqui.

Aos companheiros de pesquisa professores Rodrigo Ramos e Ricardo Prates, pelas palavras de incentivo, pela colaboração e troca de informações, sempre dispostos a ajudar de boa vontade e dar suas contribuições, principalmente na elaboração técnica, foram pessoas muito importantes para aumentar a qualidade do trabalho. A vocês, muito obrigado.

Agradeço à minha namorada, que é uma pessoa especial para mim, com a qual aprendo muito sobre a vida. Definitivamente, os caminhos que conduzem na direção da felicidade não formam uma linha reta. Pela sua compreensão, respeito e carinho principalmente nos momentos finais, meu muito obrigado.

Os meus amigos e colegas de curso, Anderson, Edmar e Moisés, membros do LSD - Laboratório de Sistemas Digitais da UFBA, grandes amigos que fiz ao longo do curso e que foram absolutamente fundamentais em vários momentos, tanto nos diversos bate-papos no laboratório ao longo dos anos, quanto em todo tipo de ajuda que se possa imaginar, tanto na pesquisa, quanto na elaboração dos artigos e inclusive deste documento. Muito obrigado pelo grande apoio e ajuda de vocês.

Agradeço à Coordenação de aperfeiçoamento de pessoal de nível Superior (CAPES) pelo suporte financeiro.

Por fim um agradecimento em especial ao meu orientador, grande mestre, professor Eduardo Simas, pessoa absolutamente respeitável e que tenho em grande estima. Sem dúvida nenhuma seus ensinamentos fizeram toda a diferença na elaboração deste trabalho. Com o Sr. eu aprendi, amadureci e me tornei uma pessoa melhor. Muito obrigado pela paciência quase infinita e dedicação para comigo.

Muito obrigado a todos!



# Resumo

No âmbito da inspeção e manutenção em redes aéreas de distribuição de energia em média tensão, há uma variedade de métodos utilizados para manutenção preventiva e corretiva, sendo parte deles, empíricos. No caso do planejamento da intervenção corretiva, um dos problemas associados é a falha na identificação dos componentes a serem substituídos. Por isso, o desenvolvimento de técnicas de processamento de imagens para serem embarcadas em robôs e drones é uma proposta útil para listagem destes componentes, permitindo o levantamento e identificação dos equipamentos alvo com maior praticidade. Esse trabalho tem como foco classificar diferentes tipos de isoladores de redes de distribuição na faixa de 15 Kv, através de imagens obtidas tanto em laboratório como em um ambiente externo. São estudados aspectos como o formato, influência da inclinação e do ambiente na classificação dos isoladores. Neste trabalho a proposta é realizar pré-processamento e segmentação das imagens para posterior extração de atributos através de três abordagens distintas: geométrica, estatística e do domínio da frequência. Este conjunto de atributos serve de entrada para o treinamento de 8 tipos diferentes de classificadores dentre os quais as Redes Neurais Artificiais, a Máquina de Vetor de Suporte, Modelo Oculto de Markov, *Naive Bayes*, Árvore de Decisão, Floresta Aleatória, K-vizinhos mais próximos e o 1-vizinho mais próximo, para estudar o comportamento dos modelos de classificação. Por fim, são aplicadas técnicas de compressão através de PCA (*Principal Component Analysis*) e da DWT (*Discrete Wavelet Transform*) a fim de obter a mínima informação necessária para uma classificação eficiente. Os resultados encontrados mostram que a metodologia aplicada é capaz de identificar uma faixa de operação de inclinação de imagem do objeto que permite a operação adequada do sistema. Observa-se ainda que é possível melhorar a acurácia de classificação de isoladores no ambiente externo com base em imagens obtidas em um ambiente controlado.



# Abstract

In the context of inspection and maintenance in medium voltage overhead power distribution lines, there are a variety of methods used for preventive and corrective maintenance, part of them being empirical. In the case of corrective intervention planning, one of the associated problems is the failure to identify the components to be replaced. Therefore, the development of image processing techniques to be embedded in robots and drones is a useful proposal for listing these components, allowing the survey and identification of target equipment with greater practicality. This work focuses on classifying different types of distribution network isolators in the 15 Kv range, through images obtained both in the laboratory and in an external environment. Aspects such as shape, influence of slope and environment on the classification of insulators are studied. In this work the proposal is to perform image pre-processing and segmentation for further attribute extraction through three different approaches: geometric, statistical and frequency domain. This set of attributes serves as input for training 8 different types of classifiers including Artificial Neural Networks, Support Vector Machine, Markov Hidden Model, Naive Bayes, Decision Tree, Random Forest, K-nearest neighbors and the nearest 1-neighbor to study the behavior of classification models. Finally, compression techniques are applied through PCA (Principal Component Analysis) and DWT (Discrete Wavelet Transform) in order to obtain the minimum information necessary for efficient classification. The results show that the applied methodology is able to identify an object image tilt operating range that allows the proper operation of the system. It is also observed that it is possible to improve the classification accuracy of insulators in the external environment based on images obtained in a controlled environment.



# Lista de ilustrações

Figura 1 – Ilustração de recursos de inteligência embarcada em um <i>drone</i> utilizados para inspeção em uma rede elétrica de distribuição aérea. Fonte: Próprio Autor. . .	31
Figura 2 – Diagramas ilustrativos de diferentes formas de montagem de redes de distribuição. Adaptado de [13]. . . . .	36
Figura 3 – Diagramas ilustrativos de diferentes formas de montagem de redes de distribuição. Adaptado de [13]. . . . .	37
Figura 4 – Rede de distribuição: Elementos elétricos a serem inspecionados em um poste com circuito trifásico e transformador (cotas em mm). Adaptado de [15]. . .	38
Figura 5 – Os 8 tipos mais comuns de isoladores: (a) Pino, (b) Pilar ,(c) Suporte, (d) <i>Station Post</i> , (e) Pedestal, (f) Roldana, (g) Castanha, (h) Disco. Adaptado de [16]. . . . .	41
Figura 6 – Posição de montagem dos isoladores: Isolador de porcelana montado como apoio e isolador de vidro montado como suporte. Adaptado de [28]. . . . .	41
Figura 7 – Diagrama ilustrativo das etapas de um sistema de reconhecimento de padrões em imagens. Fonte: Próprio Autor. . . . .	42
Figura 8 – Diagrama ilustrativo de etapas típicas do processamento digital de imagens considerando a opção da segmentação de imagens.Fonte: Próprio Autor. . . .	42
Figura 9 – Diagrama de blocos: Tipos e métodos para extração de atributos de uma imagem digital.Fonte: Próprio Autor. . . . .	43
Figura 10 – Diagrama de blocos: Exemplo de etapas de um processo de extração de atributos de uma imagem digital. Fonte: Próprio Autor. . . . .	44
Figura 11 – Diagrama ilustrativo da extração de atributos escalares geométricos extração de atributos de uma forma com base em aspectos geométricos.(a) Imagem de uma forma. (b) Extração de área, perímetro e centróide. (c) aproximação para figuras geométricas conhecidas. Fonte: Próprio Autor. . . . .	44
Figura 12 – Diagrama ilustrativo da extração de atributos com base na aproximação de figuras geométricas. (a) imagem de uma forma. (b) extração de informações das figuras geométricas aproximadas. Fonte: Próprio Autor. . . . .	45
Figura 13 – Cálculo de escalares e extração de atributos de uma forma com base em aspectos estatísticos. (a) imagem com fundo branco. (b) histograma de escala de cinza da imagem. Fonte: Próprio Autor. . . . .	46
Figura 14 – Extração de assinatura de contorno de um objeto de interesse presente em uma imagem. (a) Imagem em escala de cinza. (b) assinaturas de contorno em relação ao plano XY e em relação aos deslocamentos parciais de X e de Y.Fonte: Próprio Autor. . . . .	48

Figura 15 – Formação de um classificador que distingue duas classes A e B (a) Representação de uma Fronteira de Decisão (b) Representação de uma superfície de decisão entre as densidades de probabilidade das duas classes, onde eB e eA na área cinzenta do diagrama, representam o erro cometido pelo classificador. Fonte: Próprio Autor. . . . .	50
Figura 16 – Formação de um vetor de características com base em conjuntos de valores escalares e de relações entre escalares. (a) Imagens de classes distintas. (b) Vetores de atributos extraídos das imagens. (c) Classificação de objetos com base nas diferenças entre as características. Fonte: Próprio Autor. . . . .	50
Figura 17 – Matriz de confusão de um problema de duas classes. Fonte: Próprio Autor. . . . .	51
Figura 18 – Construção da curva ROC com dois classificadores binários. Fonte: Próprio Autor. . . . .	52
Figura 19 – Neurônio Biológico. Adaptado de [43]. . . . .	54
Figura 20 – Modelo matemático do neurônio. Fonte: Próprio Autor. . . . .	55
Figura 21 – Exemplo de RNA multicamadas totalmente conectada. Fonte: Próprio Autor. . . . .	55
Figura 22 – Exemplo de um hiperplano de separação binária de uma SVM. Fonte: Próprio Autor. . . . .	56
Figura 23 – Diagrama Ilustrativo de uma Árvore de Decisão: (a) Árvore com Regras, nós de decisão e folhas (b) Exemplo de uma Divisão de 5 classes em um espaço de objetos. Fonte: Próprio Autor. . . . .	60
Figura 24 – Diagrama Ilustrativo de uma constituição de uma Floresta Aleatória. Fonte: Próprio Autor. . . . .	61
Figura 25 – Modelo proposto do sistema de reconhecimento de padrões em imagens. . . . .	65
Figura 26 – Amostras de isoladores, locais de instalação e respectivo desenho de referência da esquerda para a direita: polimérico [IPL], porcelana [IPN], isolador de vidro [IVD] e saia baiana [ISB]. . . . .	66
Figura 27 – Exemplos dos três tipos de imagens processadas e seus respectivos contornos. (a) Referência. (b) Laboratório. (c) Ambiente externo. . . . .	66
Figura 28 – Fluxograma das atividades realizadas neste trabalho. . . . .	67
Figura 29 – Fluxograma das atividades realizadas na parte 1 deste trabalho. . . . .	68
Figura 30 – Fluxograma das atividades realizadas na parte 2 deste trabalho. . . . .	68
Figura 31 – Estúdio SEAI (Sistema Experimental de Aquisição de imagens). . . . .	69
Figura 32 – Projeto CAD do SEAI: Mesa Giratória e Suporte do <i>Smart Phone</i> . . . . .	70
Figura 33 – Diagrama que ilustra a simulação da movimentação da câmera embarcada em um drone em relação ao objeto de interesse para classificação. . . . .	70
Figura 34 – Diagrama ilustrativo da utilização do SmartPhone e recursos de alinhamento para aquisição de imagens em laboratório. . . . .	70
Figura 35 – SEAI: Sistema de iluminação controlada. . . . .	71
Figura 36 – Amostra das imagens brutas com inclinação $\theta$ de 0 a 90 graus da esquerda para a direita. . . . .	71
Figura 37 – Rede de Distribuição didática instalada na UNIVASF. . . . .	72
Figura 38 – Amostra das imagens brutas dos isoladores instalados em ambiente externo. . . . .	72

Figura 39 – Diagrama ilustrativo da metodologia adotada para a construção das bases de dados C1 e C2. . . . .	73
Figura 40 – Modelo de sistema computacional proposto para processamento de imagens. .	74
Figura 41 – Imagem do sistema utilizado neste trabalho para processamento e reconhecimento de padrões em imagens. . . . .	74
Figura 42 – Processamento de imagens de referência. (a) <i>Datasheet</i> (b) Recorte e redimensionamento da forma (c) Inversão (d) Contorno da forma. . . . .	75
Figura 43 – Processamento de imagens em laboratório. (a) foto (b) recorte e redimensionamento (c) Escala de cinza (d) Binarização (e) Inversão (f) Contorno. . . .	76
Figura 44 – Técnicas de transformação de imagens utilizadas (a) Imagem colorida. (b) Transformação para escala de cinza (c) Decomposição RGB (d) Transformação de RGB para YCbCr. . . . .	76
Figura 45 – Diagrama do método geométrico utilizado. . . . .	76
Figura 46 – Diagrama ilustrativo da extração de escalares geométricos obtidos das imagens de referência dos isoladores. (a) [APC] Área, perímetro e centróide. (b) [RQ] Relações com retângulo (c) Relações com círculo (d) relações com elipse. . .	77
Figura 47 – Diagrama do método estatístico utilizado. . . . .	77
Figura 48 – Diagrama ilustrativo da extração de histogramas das imagens dos isoladores. (a) Imagens coloridas dos isoladores (b) [GS] Histogramas de escala de cinza das imagens (c) [R][G][B] - Histogramas RGB da imagens (d) [Y][Cb][Cr] - Histogramas YCbCr das imagens. . . . .	78
Figura 49 – Diagrama do Método para extração de atributos no domínio da frequência. .	78
Figura 50 – . Diagrama ilustrativo de extração de atributos no domínio da frequência (a) imagens de referência dos isoladores (b) Contorno (c) [AC] Assinatura de contorno recortadas (d) [F(50)] Decomposição de Fourier dos sinais (e) [W1] Decomposição Wavelet dos sinais. . . . .	79
Figura 51 – Diagrama ilustrativo da decomposição Wavelet para os contornos parciais das imagens de referência dos isoladores: (a) [C(x,y)] Contorno em relação ao plano XY. (b) [ACx] Assinatura de contorno parcial em relação a $x$ . (c) [W2x] Decomposição Wavelet do sinal $x$ . (d) [ACy] Assinatura de contorno parcial em relação a $y$ . (e) [W2y] Decomposição Wavelet do sinal $y$ . . . . .	79
Figura 52 – Diagrama ilustrativo do procedimento de validação cruzada de dados, a partir da separação da base de dados C1 em duas bases de dados em função da inclinação das imagens. . . . .	81
Figura 53 – Diagrama ilustrativo do procedimento de validação cruzada dupla de dados , a partir do uso da base de dados C2 para testar os classificadores treinados com a base de dados C1.. . . .	81
Figura 54 – Diagrama ilustrativo do procedimento de validação cruzada dupla de dados em paralelo, de forma a garantir a mesma quantidade de dados adicionados no grupo de treino e no grupo de teste. . . . .	81
Figura 55 – Resultado dos treinamentos das RNAs em $\theta = 0^\circ$ . . . . .	87
Figura 56 – Resultado dos treinamentos das RNAs em $\theta = 0^\circ$ com 60 Neurônios na camada oculta. . . . .	87

Figura 57 – Curvas ROC do melhor resultado com 60 neurônios na camada oculta em $\theta = 0^\circ$ . . . . .	88
Figura 58 – Resultados dos testes das RNAs considerando a variação da inclinação $\theta$ de 10 a 90 graus da esquerda para a direita. . . . .	88
Figura 59 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por PCA. . . . .	89
Figura 60 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por PCA e 60 Neurônios na camada oculta. . . . .	90
Figura 61 – Resultados dos testes considerando o efeito da compressão por PCA. . . . .	90
Figura 62 – Resultados dos treinamentos das RNAs considerando o efeito da decomposição por <i>wavelet</i> . . . . .	91
Figura 63 – Resultados dos treinamentos das RNAs considerando o efeito da decomposição por <i>wavelet</i> considerando 60 neurônios na camada oculta. . . . .	91
Figura 64 – Resultados dos testes considerando o efeito da decomposição por WAVELET. . . . .	92
Figura 65 – Comparação da análise da influência da inclinação da imagem com os melhores resultados de compressão por PCA e Wavelet. . . . .	93
Figura 66 – Comparação entre as médias e desvio padrão dos métodos GEO, EST, FRQ e FUS. . . . .	93
Figura 67 – Resultados de melhor Acurácia de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C1, considerando a mistura gradual de dados de C2 no conjunto de treino. . . . .	94
Figura 68 – Resultados de média e desvio padrão de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C1, considerando a mistura gradual de dados de C2 no conjunto de treino. . . . .	95
Figura 69 – Resultados de melhor Acurácia de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C2, considerando a mistura gradual de dados de C2 no conjunto de treino. . . . .	95
Figura 70 – Resultados de média e desvio padrão de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C2, considerando a mistura gradual de dados de C2 no conjunto de treino. . . . .	96
Figura 71 – Resultados do treino e teste dos classificadores com o teste FUS-C1 e FUS-C2 variando de 10 a 100 o número de neurônios na camada oculta . . . . .	97
Figura 72 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por PCA e 60 Neurônios na camada oculta. . . . .	98
Figura 73 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por WLT e 60 Neurônios na camada oculta. . . . .	99
Figura 74 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por WLT e por PCA variando de 10 a 100 o número de Neurônios na camada oculta no caso de 30% de mistura de dados de C2 no treino dos classificadores. . . . .	99
Figura 75 – Comparação entre WLT e por PCA, considerando 30 neurônios na camada oculta e 30% de mistura de dados de C2 no treino dos classificadores . . . . .	100

Figura 76 – Curvas ROC do melhor resultado com 30 neurônios na camada oculta através do método FUS, dos testes com a base de dados C2 - FUS C2, considerando a adição de 0%, 10%, 20% e 30% de dados de C2 no treino das RNAs. . . . .	100
Figura 77 – Resultados do histograma dos valores de saída de teste de C1 de 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino. . . . .	101
Figura 78 – Resultados do histograma dos valores de saída de teste de C2 de 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino. . . . .	102
Figura 79 – Resultados do histograma dos valores de saída de teste de C1 de classificadores SVM binários para a classe 1 (IPL) com mistura gradual de dados de C2 no treino. . . . .	102
Figura 80 – Resultados do histograma dos valores de saída de teste de C1 de classificadores SVM binários para a classe 3 (IVD) com mistura gradual de dados de C2 no treino. . . . .	103
Figura 81 – Resultados do histograma dos valores de saída de teste de C2 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino. . . . .	103
Figura 82 – Resultados do histograma dos valores de saída de teste de C2 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino. . . . .	104
Figura 83 – Tipos de Topologias comuns em redes de distribuição. Adaptado de [12]. . . . .	119
Figura 84 – Diagrama Ilustrativo do processo de aquisição de uma imagem digital. Fonte: Próprio Autor. . . . .	121
Figura 85 – Sensor eletro-óptico para aquisição de imagens. (a) Sensor (b) Matriz de sensores. Adaptado de [23] . . . . .	122
Figura 86 – Exemplo de um processo de aquisição de uma imagem digital. Adaptado de [23]	122
Figura 87 – Digitalização de uma imagem. (a) Imagem analógica. (b) Imagem digital. Adaptado de [23] . . . . .	123



# Lista de tabelas

Tabela 1 – Exemplos de tensões de isolamento de materiais dielétricos. Adaptado de [23]	40
Tabela 2 – Especificação de Hardware e Software utilizados para o processamento das imagens. . . . .	75
Tabela 3 – Tabela de parâmetros do Classificador tipo Rede Neural Artificial. . . . .	82
Tabela 4 – Tabela de parâmetros do Classificador tipo Máquina de Vetor de Suporte. . .	82
Tabela 5 – Tabela de parâmetros do Classificador tipo Bayesiano. . . . .	83
Tabela 6 – Tabela de parâmetros do Classificador tipo Cadeia Oculta de Markov. . . . .	83
Tabela 7 – Tabela de parâmetros do Classificador tipo Árvore de Decisão. . . . .	84
Tabela 8 – Tabela de parâmetros do Classificador tipo Floresta Aleatória. . . . .	84
Tabela 9 – Tabela de parâmetros do Classificador tipo K-Vizinhos Próximos. . . . .	85
Tabela 10 – Tabela de parâmetros do Classificador tipo 1-Vizinho Próximo. . . . .	85
Tabela 11 – Resultados: GEO x EST x FRQ x FUS com 60 Neurônios na camada oculta.	88
Tabela 12 – Fatores de compressão de sinais EST pelo método PCA . . . . .	89
Tabela 13 – Fatores de compressão de sinais EST pelo método WLT . . . . .	91
Tabela 14 – Resultados de melhor Acurácia dos 8 tipos de Classificadores utilizando o método FUS com a mistura de dados de treino entre C1 e C2. . . . .	96
Tabela 15 – Fatores de compressão de sinais FUS pelo método PCA . . . . .	97
Tabela 16 – Fatores de compressão de sinais FUS pelo método WLT . . . . .	98
Tabela 17 – Resultados: Método FUS com 0 % a 30% de mistura de dados de C2 no treino dos classificadores e 30 Neurônios na camada oculta, nos testes com a base de dados C1 - FUS-C1 e com a base de dados C2 - FUS C2. . . . .	101



# Lista de símbolos

$f_l(x, y)$	Luminosidade da imagem na coordenada $x, y$
$r(x, y)$	Reflectância da imagem na coordenada $x, y$
$i(x, y)$	Iluminância da imagem na coordenada $x, y$
$A_1$	Atributo A1 do tipo Geométrico
$A_2$	Atributo A2 do tipo Geométrico
$A_3$	Atributo A3 do tipo Geométrico
$A_4$	Atributo A4 do tipo Geométrico
$A_5$	Atributo A5 do tipo Geométrico
$A_6$	Atributo A6 do tipo Estatístico
$A_7$	Atributo A7 do tipo Estatístico
$A_8$	Atributo A8 do tipo Estatístico
$A_9$	Atributo A9 do tipo Estatístico
$A_{10}$	Atributo A10 do tipo Estatístico
$A_{11}$	Atributo A11 do tipo Estatístico
$A_{12}$	Atributo A12 do tipo Contorno e Frequência
$A_{13}$	Atributo A13 do tipo Contorno e Frequência
$A_{14}$	Atributo A14 do tipo Contorno e Frequência
$A_{15}$	Atributo A15 do tipo Contorno e Frequência
$A_{16}$	Atributo A16 do tipo Contorno e Frequência
$A_{17}$	Atributo A17 do tipo Contorno e Frequência
$A_{18}$	Atributo A18 do tipo Contorno e Frequência
$A_{geo}$	Concatenação de atributos do tipo geométrico
$A_{est}$	Concatenação de atributos do tipo Estatístico
$A_{frq}$	Concatenação de atributos do tipo domínio da Frequência
$Pe_o$	Perímetro Equivalente do Objeto

$A$	Área Equivalente do Objeto
$E_x$	Excentricidade
$D_{eq}$	Diâmetro Equivalente
$P_{ecc}$	Perímetro do círculo
$L_{Ma}$	Lado Maior
$L_{Me}$	Lado Menor
$E_t$	Extensão
$\mu$	Média
$\sigma$	Desvio Padrão
$\sigma^2$	Variância
$\sigma^3$	Assimetria
$\sigma^4$	Curtose
$E_n$	Energia
$E_t$	Entropia
$D_f$	Descritor de Fourier
$D_{wx}$	Descritor Wavelet do contorno parcial no eixo x
$D_{wy}$	Descritor Wavelet do contorno parcial no eixo y
$E_{tx}$	Entropia do contorno parcial no eixo x
$E_{nx}$	Energia do contorno parcial no eixo x
$E_{ty}$	Entropia do contorno parcial no eixo y
$E_{ny}$	Energia do contorno parcial no eixo y
$err_+(f_p)$	Taxa de erro na classe positiva
$err_-(f_p)$	Taxa de erro na classe negativa
$A_{cu}(f_p)$	Taxa de acerto total ou Acurácia total
$ED_n$	Eficiência de detecção de uma classe
$u_k$	Entrada total (RNA)
$Y_k$	Saída total (RNA)
$\omega_j$	Peso (RNA)

$X$	Conjunto de treinamento (SVM)
$Y$	Rótulos de saída (SVM)
$h(x)$	Hiperplano de separação de classes (SVM)
$\psi_M$	Mapeamento (SVM)
$\Gamma$	Espaço de características (SVM)
$K(x_i, x_j)$	Função <i>kernel</i> (SVM)
$g(\mathbf{x})$	Classificador (SVM)
$b^*$	Coefficiente de distância (SVM)
$a_{ij}$	Probabilidade de transição entre estados (HMM)
$\pi_i$	Probabilidade inicial de cada estado (HMM)
$P(C x)$	Probabilidade condicional de $C$ dado $x$ (BAYES)
$y_{map}$	Função discriminante - Critério MAP (BAYES)
$P(y_i)$	Regra de decisão para classificação <i>Naive-Bayes</i> (BAYES)
$d_{Eu}$	Distância Euclidiana
$KV$	Kilo Volts
$V/mm$	Volts por Milímetro
$f$	Frequência
$Hz$	Hertz
m	Metro
$\pi$	Pi



# Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
AS	Assimetria
ANEEL	Agência Nacional de Energia Elétrica
AUC	<i>Área Under ROC Curve</i> (Área sobre a curva ROC)
BAYES	<i>Classificador Naive bayes</i>
CT	Curtose
DWT	<i>Discrete Wavelet Transform</i> (Transformada Discreta Wavelet)
DW	Descritor <i>Wavelet</i>
DF	Descritor de Fourier
DTREE	<i>Decision Tree</i> (Árvore de Decisão)
EST	<i>Técnicas de extração de atributos Estatísticas</i>
EN	Energia
ET	Entropia
FRQ	<i>Técnicas de extração de atributos Frequência</i>
FUS	<i>Fusão entre as técnicas de extração de atributos</i>
FP	<i>Falsos Positivos</i>
FND	<i>Forma Normal Disjuntiva</i>
GEO	<i>Técnicas de extração de atributos Geométricas</i>
HMM	<i>Hidden Markov Model</i> (Modelo Oculto de Markov)
IA	Inteligência Artificial
IPL	Isolador Polimérico (Classe 1)
IPN	Isolador de Pino Cerâmico (Classe 2)
IVD	Isolador de Vidro (Classe 3)
ISB	Isolador tipo Saia Baiana (Classe 4)
k-NN	<i>k-Nearest Neighbors</i> (k-Vizinhos mais próximos)

MAP	<i>Maximum A Posteriori</i>
ME	<i>Média</i>
NBR	Norma Técnica Brasileira
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
PDI	Processamento Digital de Imagens
PDF	<i>Probability Density Function</i> (Função Densidade de Probabilidade)
RFOREST	<i>Randon Forest</i> (Floresta Aleatória)
RGB	<i>Red Green Blue</i>
RDAs	Redes de Distribuição Aéreas
ROC	<i>Receiver Operating Characteristics</i>
RNA	<i>Rede Neural Artificial</i>
SVM	<i>Support Vector Machine</i> (Máquina de Vetor de Suporte)
TVP	<i>Taxa de Verdadeiros Positivos</i>
TFP	<i>Taxa de Falsos Positivos</i>
TFN	<i>Taxa de Falsos Negativos</i>
VA	Variância
VP	Verdadeiros Positivos
VN	<i>Verdadeiros Negativos</i>
WLT	<i>Compressão por Transformada Wavelet</i>
YCbCr	Luminância, Crominância de Azul, Crominância de vermelho
1-NN	<i>1-Nearest Neighbor</i> (1-Vizinho mais próximo)

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>31</b>
1.1	Motivação	32
1.2	Objetivo	32
1.3	Organização do Documento	33
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>35</b>
2.1	Redes de Distribuição de Energia Elétrica	35
2.1.1	Instalação de Postes em Redes de Distribuição	35
2.1.2	Manutenção de Redes de Distribuição	35
2.1.3	Planejamento e Controle de Manutenção	38
2.2	Isoladores de Redes Elétricas	39
2.2.1	Classificação de Isoladores em Redes de Distribuição	40
2.3	Reconhecimento de padrões em imagens	42
2.3.1	Etapas do reconhecimento de padrões em imagens	42
2.3.2	Processamento digital de imagens	42
2.3.3	Extração de atributos de imagens	43
2.3.3.1	Atributos Geométricos	44
2.3.3.2	Atributos Estatísticos	46
2.3.3.3	Atributos de Contorno e Frequência	47
2.3.3.4	Vetor de Características	49
2.3.4	Reconhecimento de Padrões e Classificação	49
2.4	Aprendizado de Máquina	53
2.4.1	Métodos Baseados em Otimização	53
2.4.1.1	Redes Neurais Artificiais	53
2.4.1.2	Máquina de Vetor de Suporte	56
2.4.2	Métodos Baseados em Probabilidade	57
2.4.2.1	Modelo Oculto de Markov	57
2.4.2.2	Modelo Naive Bayes	58
2.4.3	Métodos Baseados em Distâncias	59
2.4.3.1	Modelo do 1-Vizinho mais Próximo	59
2.4.3.2	Modelo dos k-Vizinhos mais Próximos	60
2.4.4	Métodos Baseados em Busca	60
2.4.4.1	Árvores de Decisão	60
2.4.4.2	Florestas Aleatórias	61
2.5	Compressão de Sinais	61
2.5.1	Análise de Componentes Principais	61
2.5.2	Transformada Wavelet	62
<b>3</b>	<b>METODOLOGIA</b>	<b>65</b>

<b>3.1</b>	<b>Modelo Proposto</b>	<b>65</b>
<b>3.2</b>	<b>Materiais e Métodos</b>	<b>65</b>
3.2.1	Material	65
3.2.2	Métodos	66
3.2.3	Aquisição de Imagens em Laboratório (UFBA)	69
3.2.4	Aquisição de Imagens em uma Rede de Distribuição didática (UNIVASF)	71
3.2.5	Construção das bases de dados C1 e C2	73
3.2.6	Plataforma Computacional utilizada para Processamento de Imagens	74
<b>3.3</b>	<b>Técnicas de Processamento de Imagem Utilizadas</b>	<b>75</b>
<b>3.4</b>	<b>Técnicas de Extração de Atributos Utilizadas</b>	<b>76</b>
3.4.1	Método Geométrico [GEO]	76
3.4.2	Método Estatístico [EST]	77
3.4.3	Atributos no Domínio da Frequência [FRQ]	78
<b>3.5</b>	<b>Atributos extraídos</b>	<b>79</b>
<b>3.6</b>	<b>Técnicas de treino, teste e classificação Utilizadas</b>	<b>80</b>
3.6.1	Parte 1: Influência da Inclinação	80
3.6.2	Parte 2: Influência da Mistura dos Dados de C2 no treino de C1	80
3.6.3	Validação Cruzada	80
3.6.4	Classificadores	82
<b>3.7</b>	<b>Métodos de avaliação de desempenho Utilizados</b>	<b>86</b>
<b>3.8</b>	<b>Técnicas de compressão da informação utilizadas</b>	<b>86</b>
<b>4</b>	<b>RESULTADOS</b>	<b>87</b>
<b>4.1</b>	<b>Ambiente Controlado</b>	<b>87</b>
4.1.1	Classificação para o caso sem inclinação: ( $\theta = 0^\circ$ )	87
4.1.2	Inclinação Variável: ( $0^\circ < \theta < 90^\circ$ )	88
4.1.3	Compressão por PCA	89
4.1.4	Compressão por WLT	90
4.1.5	Análise Comparativa	92
<b>4.2</b>	<b>Ambiente Externo</b>	<b>93</b>
4.2.1	Fusão entre Atributos	93
4.2.2	Classificadores e Mistura de Dados	94
4.2.3	Teste FUS C1	94
4.2.4	Teste FUS C2	95
4.2.5	Sensibilidade dos Classificadores	96
4.2.6	Compressão por PCA	97
4.2.7	Compressão por WLT	98
4.2.8	Análise Comparativa - Compressão	99
4.2.9	Análise Comparativa - Confusão entre Classes	100
<b>5</b>	<b>CONCLUSÕES</b>	<b>105</b>
<b>5.1</b>	<b>Trabalhos Futuros</b>	<b>107</b>

REFERÊNCIAS .....	109
-------------------	-----

<b>APÊNDICES</b>	<b>115</b>
------------------	------------

APÊNDICE A – TRABALHOS PUBLICADOS .....	117
---	-----

A.1 Artigos em Congressos .....	117
---------------------------------	-----

A.2 Artigo em Periódico .....	118
-------------------------------	-----

APÊNDICE B – TOPOLOGIA DE PROJETO DE REDES DE DISTRIBUI- ÇÃO .....	119
---	-----

APÊNDICE C – AQUISIÇÃO DE IMAGEM DIGITAL .....	121
--	-----

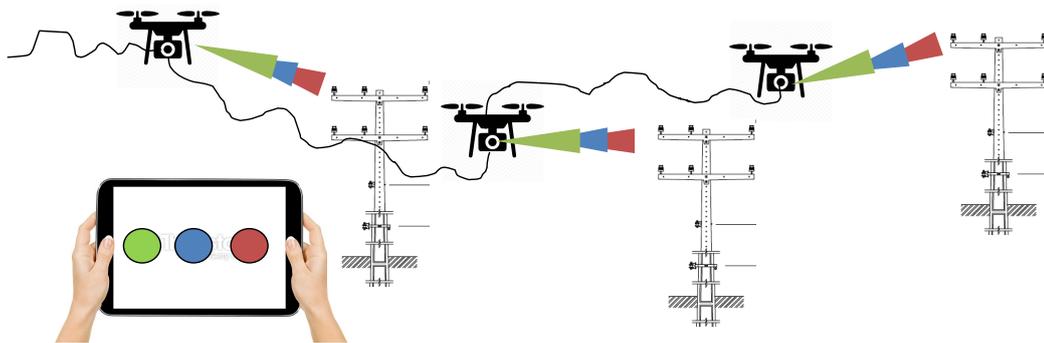


# 1 Introdução

Nas redes de distribuição aéreas (RDAs) de energia elétrica de média tensão, as atividades de inspeção corretiva e preventiva [1] muitas vezes são realizadas na modalidade de inspeção visual, "por patrulha a pé", ou assistidas por helicóptero. Essas atividades são normalmente baseadas em métodos empíricos de avaliação, o que pode gerar falhas na identificação de componentes defeituosos e conseqüentemente em planos de manutenção inadequados. Isso pode provocar o aumento nos custos com logística e manutenção. Um erro na avaliação do isolamento, pode ainda interferir na qualidade de fornecimento de energia para o consumidor final.

Diante desta perspectiva, uma solução automatizada pode ser fornecida através do uso de robôs de inspeção. A inspeção industrial em robótica é um campo relativamente novo, mas promissor na área de engenharia industrial [2]. Os recentes avanços na área de inteligência artificial embarcada [3], a crescente disponibilidade de processamento inteligente tanto em software [4] quanto em hardware [5] e a busca de eficiência operacional em sistemas de engenharia [6] está tornando a inspeção robótica cada vez mais popular.

Em relação ao desenvolvimento de tecnologias inteligentes de inspeção de RDAs, alguns autores sugeriram soluções usando o processamento de imagem digital (que podem ser incorporadas em robôs) como classificação [7], diagnóstico [8] e localização [9]. Uma ilustração de um sistema de inspeção usando *drone* é apresentada na Figura 1.



**Figura 1** – Ilustração de recursos de inteligência embarcada em um *drone* utilizados para inspeção em uma rede elétrica de distribuição aérea. Fonte: Próprio Autor.

Uma das contribuições possíveis para auxiliar na resolução destes problemas de manutenção, são as técnicas de classificação automática [10], [11], [12], [13]. Estes classificadores podem ser utilizados tanto para identificação de material para inventário, quanto para diagnósticos de falhas elétricas ou inconformidades mecânicas dos componentes em uma inspeção preventiva [14], [15]. Em algumas aplicações de inspeção de rede de distribuição é comum o uso de termografia e sensores de ultrassom, entretanto, também podem ser utilizadas imagens convencionais.

## 1.1 Motivação

No caso do problema da identificação do isolador com base em imagens no campo, faz-se necessária a construção de uma base de dados de imagens. Uma questão é captar fotos de isoladores localizados em posições de difícil acesso humano e com interferência de outros componentes e acessórios de instalação, bem como do ambiente externo que forma o plano de fundo da imagem. Outro desafio é que algumas dessas técnicas de classificação precisam de elevada especificação de *hardware* tanto para extração de atributos quanto para o processamento das imagens, impactando no desempenho e no tempo de autonomia de um robô em uma futura implementação embarcada. Portanto, este contexto torna pertinente a investigação sobre as melhores formas de adquirir estas imagens e o estudo de métodos de extração de atributos, bem como o uso de algoritmos computacionais simplificados e técnicas de compactação de dados.

Neste trabalho, são aplicadas técnicas de processamento digital de imagens e inteligência computacional com o intuito de classificar, diferentes isoladores elétricos de média tensão, tomando como base as próprias imagens dos objetos. Nesta pesquisa serão utilizadas tanto imagens adquiridas em laboratório, quanto de isoladores instalados em postes de distribuição numa rede didática não energizada. As primeiras serão utilizadas para verificar a influência do ângulo de inclinação da imagem na eficiência de classificação, que é um aspecto prático importante, pois na operação de um sistema automático com *drone*, não é possível garantir que todas as imagens serão adquiridas com mesma inclinação. Serão também utilizadas para auxiliar na melhoria da eficiência de classificação das imagens dos isoladores no ambiente externo.

Esse trabalho está enquadrado em um projeto de pesquisa em parceria entre professores do Departamento de Engenharia Elétrica da UNIVASF e o programa de pós-graduação em Engenharia Elétrica da UFBA, visando contribuir para o desenvolvimento de técnicas de inspeção em Redes de Distribuição.

## 1.2 Objetivo

Este trabalho teve como objetivo principal o projeto e o desenvolvimento de um sistema para captura e processamento de imagem capaz de classificar isoladores elétricos empregados em redes de distribuição que operam na faixa de 15 kV. O experimento considera, tanto um ambiente controlado como uma instalação não energizada, avaliando aspectos práticos como a influência da inclinação, iluminação e interferência do fundo na classificação, de modo que, a partir da obtenção de imagens em um ambiente controlado, seja viável classificar estes mesmos objetos em uma condição operacional.

Para atingir o objetivo geral, pode-se destacar os objetivos específicos listados a seguir:

- Projeto e montagem de um estúdio para aquisição de imagens que permita a variação da inclinação da câmera em relação ao eixo central e a rotação do objeto em torno do seu próprio eixo.

- Implementar técnicas de processamento de imagem para efetuar a extração de atributos dos objetos de interesse através de 3 metodologias distintas.
- Determinar o melhor resultado para com ele verificar a influência na classificação das imagens conforme varia o ângulo de inclinação.
- Implementar uma metodologia de treinamento de classificadores com validação cruzada, considerando a fusão entre os atributos e verificar se ocorre a compensação das desvantagens de cada método.
- Testar as técnicas de extração de atributos em imagens de isoladores instalados em uma rede de distribuição didática não energizada.
- Implementar técnicas para compressão da informação.

### 1.3 Organização do Documento

O presente capítulo apresenta uma breve introdução ao trabalho, destacando a motivação para o desenvolvimento do projeto e objetivos propostos. No segundo capítulo é apresentado um breve histórico sobre redes de distribuição aéreas e isoladores, bem como as teorias que cercam os principais assuntos relacionados a este tema. O terceiro capítulo apresenta os fundamentos teóricos das técnicas de processamento de imagens e de sinais e de reconhecimento de padrões utilizadas neste trabalho. O quarto capítulo aborda a metodologia utilizada no desenvolvimento deste trabalho e na validação do sistema proposto. No quinto capítulo são apresentados os resultados obtidos a partir dos dados de referência e também de dados experimentais utilizando a metodologia proposta. Por fim, o sexto capítulo apresenta as conclusões e perspectivas para continuação deste trabalho.



## 2 Fundamentação Teórica

Neste capítulo é realizada uma breve introdução a aspectos como: topologias de projeto e montagem de Redes de distribuição aéreas (RDAs) de energia e isoladores de média tensão. Este capítulo também apresenta as técnicas utilizadas pela metodologia proposta neste trabalho para classificação de isoladores de média tensão.

### 2.1 Redes de Distribuição de Energia Elétrica

Nos sistemas de energia elétrica (que genericamente podem ser considerados como sendo compostos por subsistemas de geração, transmissão e distribuição) a etapa de distribuição é a última etapa, responsável por levar a energia elétrica aos consumidores finais (cargas). As redes de distribuição podem ser instaladas em área urbana ou rural, na modalidade doméstica, comercial ou industrial [16]. O subsistema de distribuição pode ser estudado do ponto de vista da topologia de projeto, instalação ou manutenção.

#### 2.1.1 Instalação de Postes em Redes de Distribuição

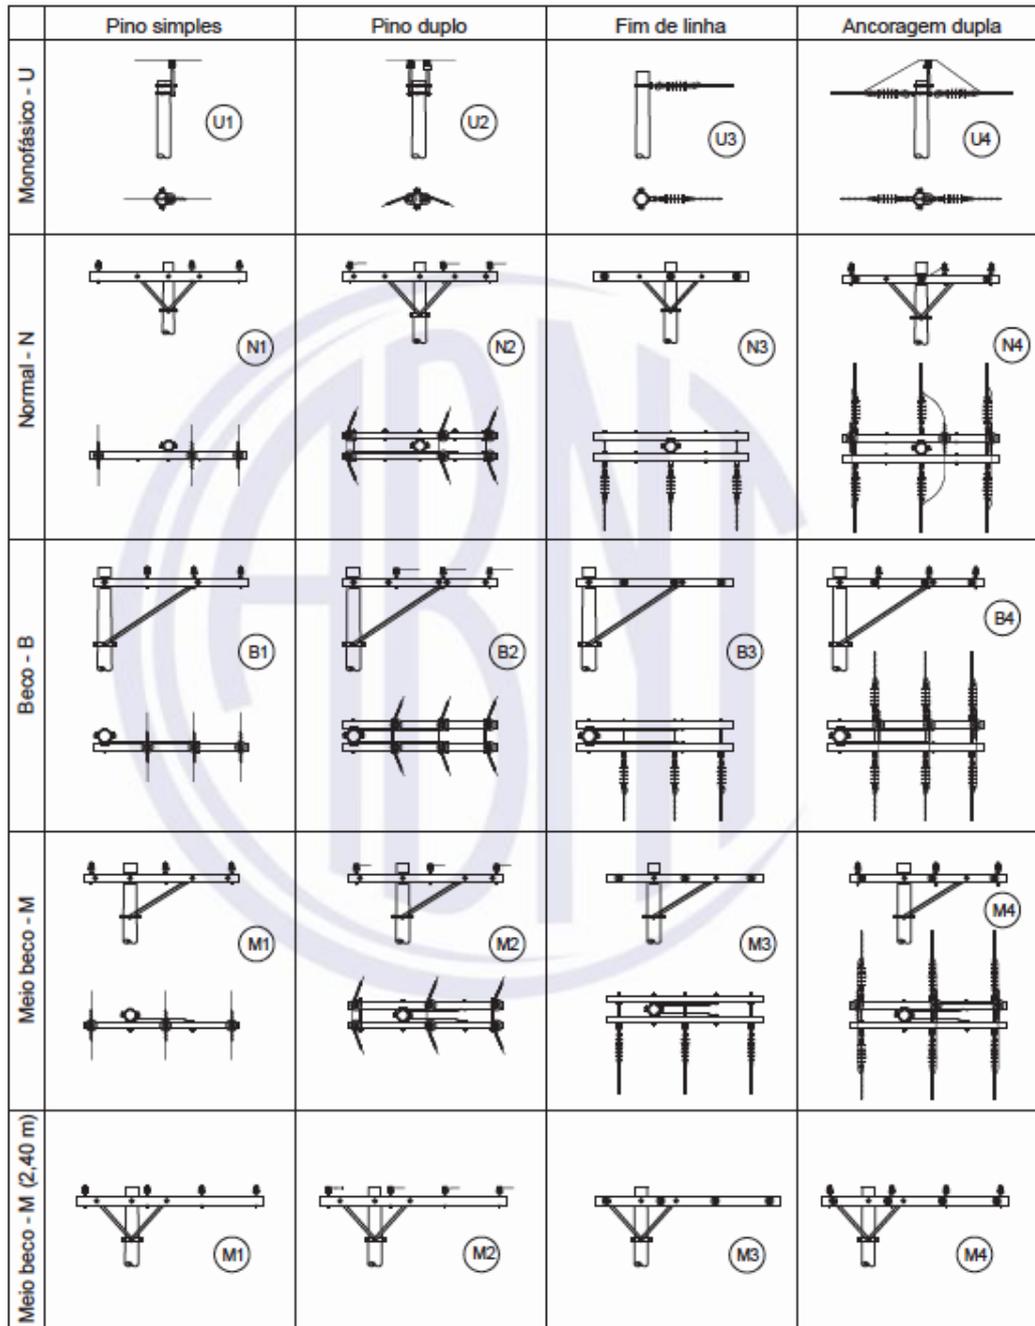
A instalação dos equipamentos nas redes de distribuição aéreas segue normas como NBR 15688 [17] e NBR 15992 [18], procedimentos técnicos como [19] e também os procedimentos operacionais das concessionárias de energia, como, por exemplo [20].

No referente ao circuito primário (instalação do circuito de alta tensão) a norma NBR 15688 divide os padrões de montagem em U, N, B e M (monofásico, trifásico normal, trifásico meio beco e trifásico beco, respectivamente) e também consideram suas variações 1, 2, 3 e 4. As Figuras 2 e 3 apresentam as categorias de montagem padronizada [17].

#### 2.1.2 Manutenção de Redes de Distribuição

A manutenção nas redes de distribuição de energia, requer um conhecimento específico sobre os componentes que fazem parte do sistema, sobretudo da disposição dos equipamentos de alta tensão.

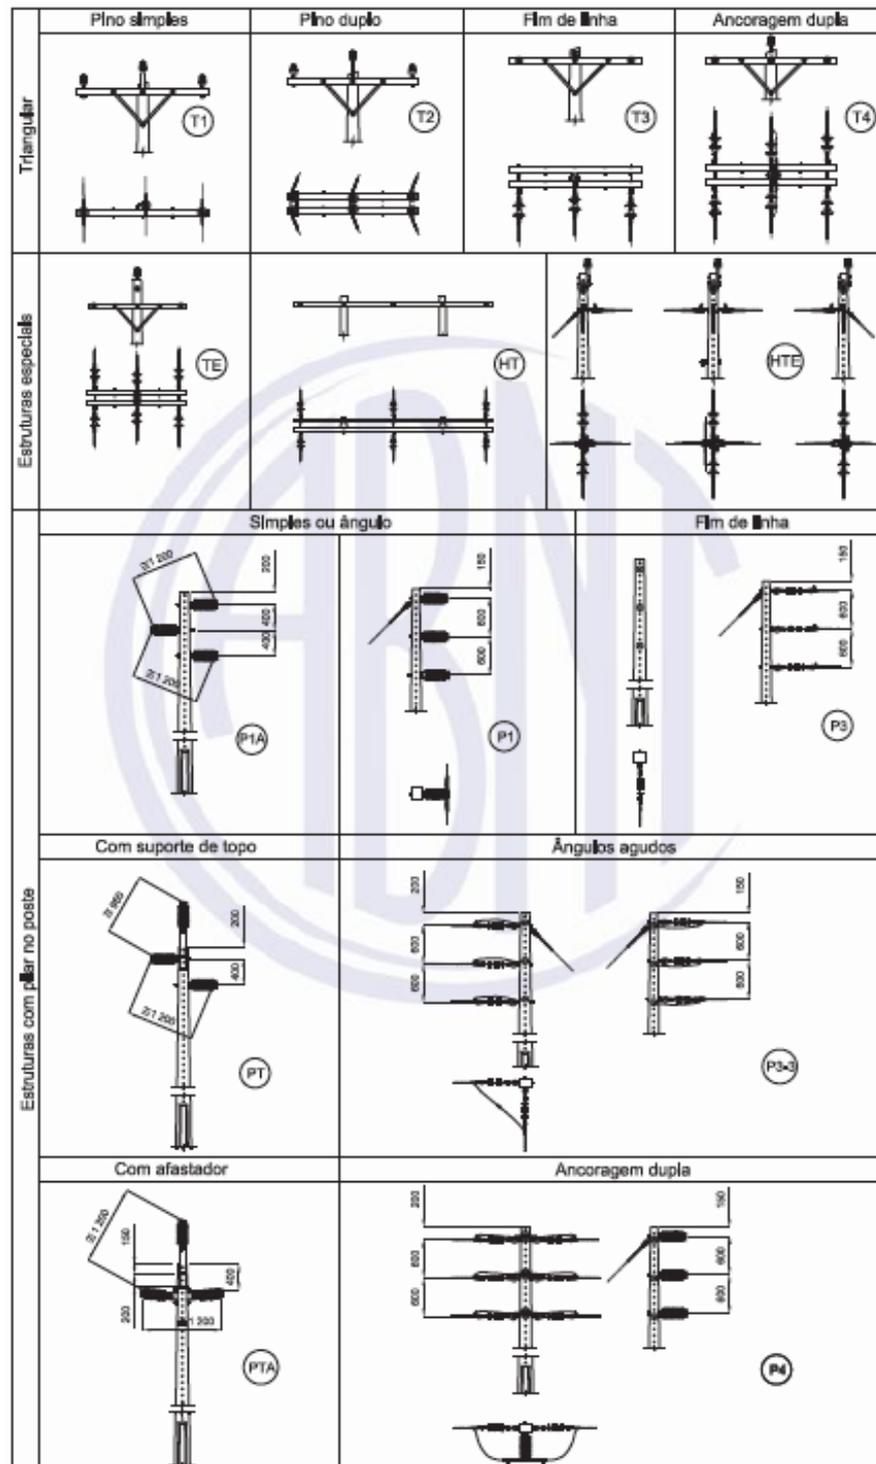
A manutenção corretiva consiste no ato de reparo de uma falha em uma máquina ou equipamento, que interrompe o seu funcionamento ou a continuidade de um processo. Já a manutenção preventiva, consiste em um conjunto de técnicas de inspeção em máquinas ou equipamentos, realizando ações programadas como limpeza, reaperto, lubrificação, ajuste, etc, de modo a prolongar o tempo entre falhas dos mesmos. Por fim, a manutenção preditiva utiliza instrumentos eletrônicos que identificam através de análises como qualidade de energia, vibração, termografia, descargas parciais e ultrassom, potenciais problemas não visíveis a olho nu, que podem vir a causar uma falha futura [1].



**Figura 2** – Diagramas ilustrativos de diferentes formas de montagem de redes de distribuição. Adaptado de [13].

No caso particular do sistema elétrico, considerando uma rede de distribuição de energia de média tensão, o desafio para a manutenção preditiva é o desenvolvimento e aplicação destas técnicas e instrumentos com o sistema energizado, com a aplicação de ensaios não destrutivos e para os quais não seja necessária a instalação de pontas de prova, garras e conexões elétricas adicionais. Neste sentido, as inspeções com recurso visual e processamento de imagem e sinais, apresentam vantagens em relação às demais técnicas.

A Figura 4 apresenta um exemplo de um poste de uma rede de distribuição de energia identificando os elementos elétricos a serem verificados para o caso de uma inspeção, manutenção



**Figura 3** – Diagramas ilustrativos de diferentes formas de montagem de redes de distribuição. Adaptado de [13].

preventiva ou preditiva.

Na prática, as inspeções comumente realizadas neste caso são: a detecção da presença de alta tensão [21], a análise termográfica nos pontos de contato (isoladores, muflas, fusível e buchas do transformador) [22] a inspeção dos isoladores através de análise de ultrassom [23].



No caso dos componentes energizados na região de alta tensão de um poste em uma rede de distribuição (contemplando, por exemplo, isoladores, buchas, muflas, fusíveis e transformadores) são necessários instrumentos e técnicas de medição para identificar possíveis anomalias em seu funcionamento quando estão energizados. As técnicas podem ser: análise termográfica, de ultrassom, descargas parciais e qualidade de energia.

A termografia em circuitos elétricos tem o objetivo de verificar se existe um aquecimento além do normal nas conexões elétricas entre os componentes. O funcionamento do sistema elétrico naturalmente gera aquecimento, entretanto, nas regiões em que ocorrem conexões entre equipamentos elétricos, pode surgir uma variação na pressão de contato que ocasione o aumento da temperatura naquela região. Ao longo do tempo, este aquecimento produzirá uma falha no equipamento [24]. No caso das redes de distribuição, esta técnica de inspeção pode ser utilizada para verificar a integridade dos isoladores de alta tensão, muflas, fusível, base e as buchas do transformador.

A inspeção por ultrassom tem como princípio a emissão de um sinal sonoro em regiões de alta frequência e através da captura da sua reflexão no objeto de interesse, efetuar um diagnóstico sobre o estado do equipamento [25]. No caso das redes de distribuição, esta técnica de inspeção pode ser utilizada para verificar a integridade das propriedades dielétricas do isolador elétrico.

A análise de descargas parciais tem como objetivo identificar se está ocorrendo uma degradação das propriedades isolantes da superfície de um equipamento elétrico. Esta técnica identifica se estão ocorrendo pequenas descargas à terra por meio de correntes parasitas [26]. No caso da aplicação para as redes de distribuição de energia elétrica, esta técnica pode ser utilizada principalmente para verificar a integridade dos isoladores, das muflas de alta tensão e das buchas do transformador.

A análise de qualidade de energia elétrica tem como objetivo avaliar se as grandezas elétricas estão dentro dos padrões estabelecidos pela Agência Nacional de Energia Elétrica [27], a exemplo da curva de carga, do equilíbrio entre as fases e do nível de distorção harmônica do circuito. Estas variáveis influenciam na vida útil, aquecimento, nas perdas de transformação e na vibração do transformador [28].

Por fim, a inspeção visual de componentes, tem como objetivo verificar a conformidade mecânica dos mesmos, identificando se estão derretidos, trincados, queimados, folgados ou apresentam qualquer tipo de deformação que comprometa sua condição de funcionamento.

Portanto, neste conjunto, o perfeito estado dos isoladores elétricos (tanto dielétrico quanto físico) é fundamental para garantir que a energia elétrica seja entregue com qualidade e segurança ao consumidor final.

## 2.2 Isoladores de Redes Elétricas

Os isoladores elétricos são elementos que impedem a passagem de corrente elétrica. Possuem elevada resistência elétrica, por isso não permitem a livre circulação de cargas elétricas. PVC, vidro, cerâmica são exemplos de materiais com elevada propriedade isolante (dielétricos). O que torna um material bom condutor elétrico é a grande quantidade de elétrons livres que ele

apresenta à temperatura ambiente.

Com o material isolante acontece o contrário, ele apresenta poucos elétrons livres à temperatura ambiente [29]. No caso das redes de distribuição, os isoladores são utilizados em faixas de isolação de acordo com as tensões padronizadas para as redes de distribuição [29]. A Tabela 1 apresenta exemplos de valores de tensão de isolamento para alguns tipos materiais com propriedades dielétricas comumente utilizados em equipamentos elétricos e eletrônicos [30].

**Tabela 1** – Exemplos de tensões de isolamento de materiais dielétricos. Adaptado de [23]

Dielétrico	Tensão de Isolamento (V/mm)
Ar	75
Cerâmica	75
Porcelana	200
Óleo de Transformador	400
Baquelite	400
Borracha	700
Papel Parafinado	1300
Teflon	1500
Vidro	3000
Mica	5000

### 2.2.1 Classificação de Isoladores em Redes de Distribuição

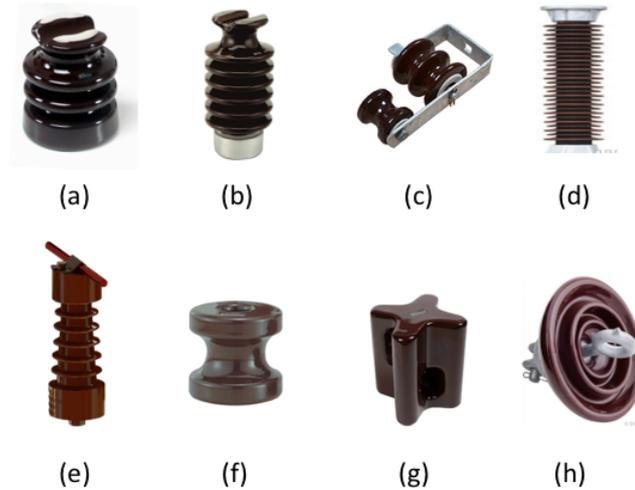
De acordo com [29], os isoladores de redes elétricas de distribuição podem ser classificados pela capacidade de regeneração, a classe de isolação, o tipo do material isolante, formato e forma de montagem. Estes isoladores são divididos em dois grupos conforme sua função de isolamento [29]:

- Isolamento não regenerativo: aqueles em que o dielétrico não se recupera após uma solicitação elétrica superior às suas características fundamentais,
- Isolamento auto-regenerativo: são aqueles em que o dielétrico consegue se recuperar após a ocorrência de uma solicitação elétrica superior.

A classe de isolação dos isoladores, varia dentro das faixas de tensão dos circuitos de geração, transmissão e distribuição de energia elétrica. A ANEEL (Agência Nacional de Energia Elétrica) para o caso das redes de distribuição, define as faixas como 15KV, 25KV e 35KV [31].

O material do isolador pode, usualmente, ser composto de porcelana, vidro ou compostos plásticos [32].

Os isoladores podem ser identificados, conforme os padrões encontrados por diferentes fabricantes como, por exemplo [32], [33], [34], [35] e [36], de acordo com os níveis de tensão. Os 8 tipos mais comuns são: pino, pilar, suporte, *station post*, pedestal, roldana, castanha e disco. A Figura 5 apresenta estes tipos de isoladores.



**Figura 5** – Os 8 tipos mais comuns de isoladores: (a) Pino, (b) Pilar, (c) Suporte, (d) *Station Post*, (e) Pedestal, (f) Roldana, (g) Castanha, (h) Disco. Adaptado de [16].

Os isoladores podem ser montados em posição de suporte, ou posição vertical livre chamados isoladores de apoio, ou isoladores de suspensão. Conforme [29], os isoladores de apoio são os utilizados para apoiar mecanicamente os condutores como também nos topos dos postes das redes de distribuição. Os isoladores de suspensão, são instalados na referência horizontal e suportam as extremidades dos condutores ligados entre os postes subsequentes [37]. A Figura 6 apresenta estas duas categorias de montagem de isoladores.



**Figura 6** – Posição de montagem dos isoladores: Isolador de porcelana montado como apoio e isolador de vidro montado como suporte. Adaptado de [28].

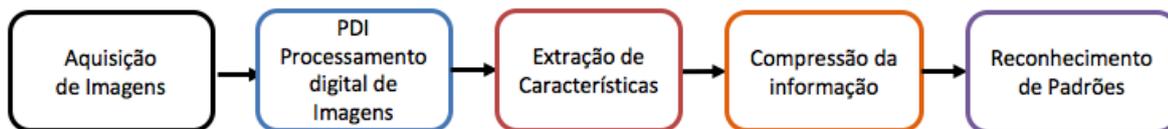
Portanto, é importante a classificação correta dos tipos de isoladores. Primeiro durante a montagem, identificando os modelos corretos dentro das condições de tensão de trabalho, segundo, durante o levantamento prévio dos componentes para a programação de uma manutenção corretiva a fim de substituir corretamente as peças defeituosas.

## 2.3 Reconhecimento de padrões em imagens

O reconhecimento de padrões em imagens [38] é um tema em constante evolução, com muitas áreas de aplicação em ciências e na engenharia. Tais áreas incluem o sensoriamento remoto [39], transmissão e armazenamento de imagens para aplicações no setor de negócios [40], medicina [41], militar [42], robótica industrial [43], dentre outros. Cada um desses sistemas requer soluções diferentes, sendo importante o conhecimento sobre o que é uma imagem digital e sobre as etapas que compõem um sistema de reconhecimento de padrões em imagens.

### 2.3.1 Etapas do reconhecimento de padrões em imagens

O reconhecimento de padrões em imagens é uma parte indispensável para qualquer sistema de classificação de imagens de alto padrão. De modo a otimizar o processamento um conjunto de valores numéricos (atributos) é extraído da imagem e utilizado para a sua representação. Um sistema de reconhecimento sofisticado deve ser capaz de reconhecer um objeto independentemente de sua orientação, tamanho e posição no campo de visão. Isso é possível quando são extraídos atributos que são insensíveis à rotação, escala e translação, respectivamente. A Figura 7 apresenta as etapas mais comuns de um sistema de reconhecimento de padrões em imagens.



**Figura 7** – Diagrama ilustrativo das etapas de um sistema de reconhecimento de padrões em imagens. Fonte: Próprio Autor.

Conforme a Figura 7, as imagens adquiridas passam por um processamento que as condicionam para a extração de características, formando sinais. Estes, são processados para treinamento de um classificador com o objetivo de torná-lo capaz de diferenciar classes de objetos ou cenários distintos, identificando padrões.

### 2.3.2 Processamento digital de imagens

O campo do processamento digital de imagens (PDI) refere-se ao processamento de imagens digitais através de um sistema computacional [44]. A Figura 8 apresenta um diagrama com etapas para o processamento digital de imagens.



**Figura 8** – Diagrama ilustrativo de etapas típicas do processamento digital de imagens considerando a opção da segmentação de imagens. Fonte: Próprio Autor.

O pré-processamento de imagens é a etapa inicial, onde a imagem é submetida a ajustes que façam com que a saída seja uma imagem modificada. As técnicas geralmente utilizadas no

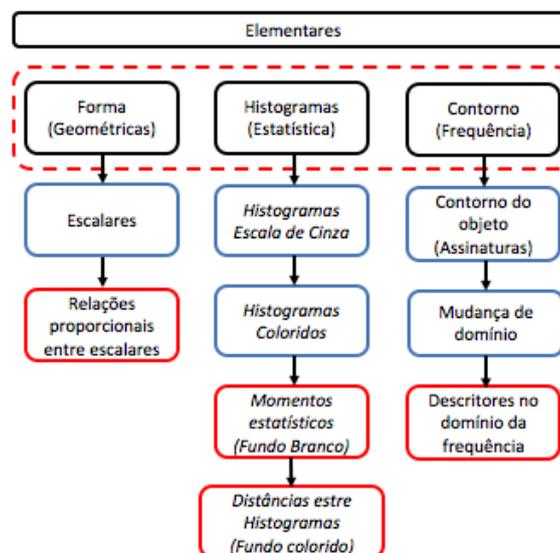
pré-processamento são: domínio espacial, domínio da frequência, estatística e transformações com imagens.

A segmentação da imagem é uma etapa alternativa do sistema de processamento digital que tem a função de transformar os *pixels* de uma imagem (que podem assumir um valor entre 0 e 255) para um conjunto de pixels binários (0 ou 1). Geralmente para efetuar a segmentação, é necessário definir um valor limiar de decisão (*threshold*) para o qual acima deste a saída é 1 e abaixo deste a saída é 0.

Existem diversos métodos para realizar esta operação. O método arbitrário consiste em selecionar manualmente um valor de limiar de decisão. Entretanto, segundo [45], o sucesso da segmentação por binarização consiste em selecionar o limiar adequado. O método de Otzu, por exemplo, tem como objetivo a escolha de um limiar que seja determinado com base nas características intrínsecas da imagem. Existem também as técnicas de segmentação por bordas que funcionam através da busca de descontinuidades na imagem [45].

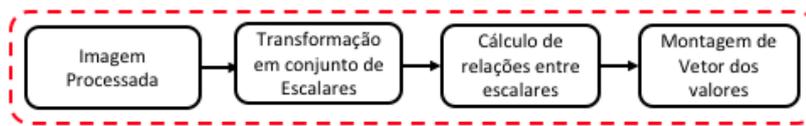
### 2.3.3 Extração de atributos de imagens

A extração de atributos de imagens, ou representação e descrição de imagens, é a etapa do processamento na qual a imagem bidimensional é transformada em uma característica escalar ou em um conjunto de características escalares que juntas, representam aquela imagem ou o objeto de interesse extraído dela. A Figura 9 apresenta os tipos e conjuntos dos principais métodos encontrados na literatura para extração de características de imagens.



**Figura 9** – Diagrama de blocos: Tipos e métodos para extração de atributos de uma imagem digital. Fonte: Próprio Autor.

Definida a metodologia ou conjunto de metodologias de abordagem, o procedimento para extração e agrupamento destas características segue, geralmente, o exemplo do diagrama de blocos apresentado na Figura 10.



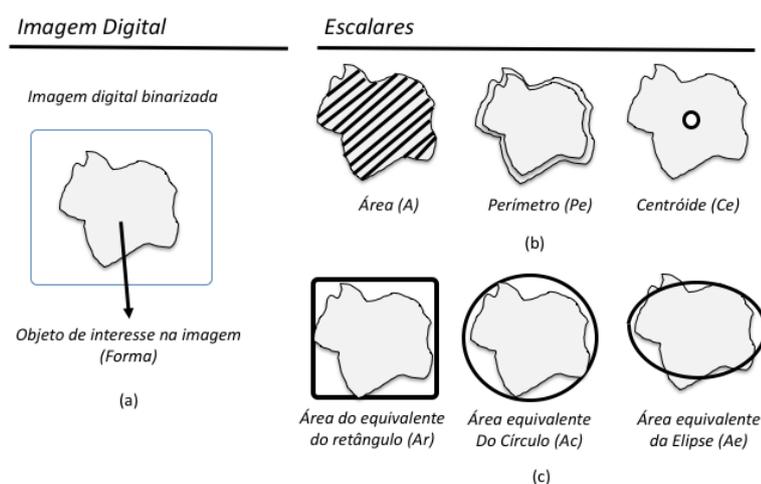
**Figura 10** – Diagrama de blocos: Exemplo de etapas de um processo de extração de atributos de uma imagem digital. Fonte: Próprio Autor.

Algumas abordagens sobre atributos que podem ser extraídos de uma imagem digital processada, são descritos a seguir.

### 2.3.3.1 Atributos Geométricos

Para que seja possível uma extração eficiente de atributos referentes à geometria de objetos de interesse em uma imagem, são aplicadas as técnicas de pré-processamento como a transformação da imagem do padrão RGB para o padrão de escala de cinza e efetuada a sua binarização. Posteriormente a imagem passa por um processo de inversão e de preenchimento, a fim de que seja possível aproximar a imagem a uma forma cujo conteúdo esteja em branco e o restante em preto.

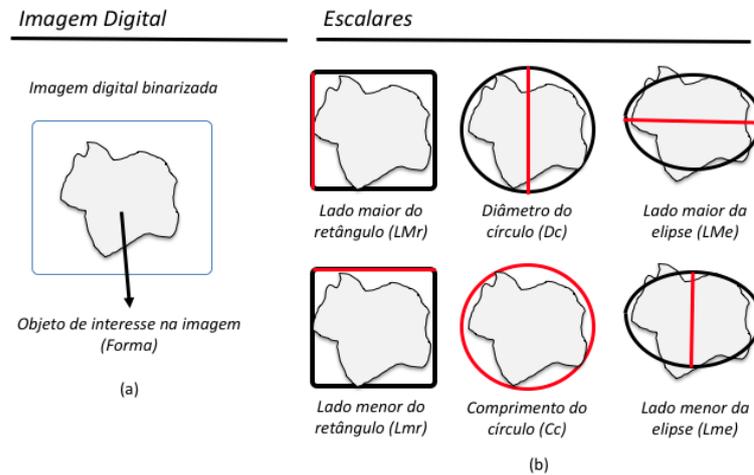
O conjunto das principais características representadas por valores escalares que podem ser extraídas da imagem com base na forma, são essencialmente a área, o perímetro e o centróide (centro de massa). Há também características que podem ser extraídas através da aproximação da área da forma com a área de um objeto geométrico conhecido. As principais aproximações são o retângulo o círculo e a elipse, entretanto, podem ser utilizadas outras figuras geométricas conhecidas. A Figura 12 apresenta exemplos de parâmetros escalares extraídos de uma imagem digital processada.



**Figura 11** – Diagrama ilustrativo da extração de atributos escalares geométricos extração de atributos de uma forma com base em aspectos geométricos.(a) Imagem de uma forma. (b) Extração de área, perímetro e centróide. (c) aproximação para figuras geométricas conhecidas. Fonte: Próprio Autor.

No caso da elipse, podem ser também extraídos os respectivos lado menor e lado maior,

aproximados. No caso do círculo, pode ser obtido o diâmetro equivalente e o comprimento da aproximação. Já para o caso do retângulo, podem ser obtidos os lados maior e menor aproximados. A Figura 12 apresenta exemplos de parâmetros escalares extraídos com base na aproximação de objetos geométricos.



**Figura 12** – Diagrama ilustrativo da extração de atributos com base na aproximação de figuras geométricas. (a) imagem de uma forma. (b) extração de informações das figuras geométricas aproximadas. Fonte: Próprio Autor.

Após a extração destes valores escalares, a próxima etapa consiste na criação dos atributos. Estes atributos geralmente possuem como base, correlações entre os valores escalares extraídos da imagem. Este tipo de abordagem tem como objetivo extrair do objeto, informações de proporcionalidade e de distribuição em relação à área total da imagem. Este método visa auxiliar na compensação de escala do objeto, tornando o atributo comparável mesmo em imagens tomadas em diferentes distâncias do objeto de interesse. Exemplos de atributos estão apresentados nas Equações 2.1 à 2.5:

$$A_1 = \frac{Pe_o^2}{A} \quad (2.1)$$

$$A_2 = E_x \quad (2.2)$$

$$A_3 = \frac{D_{eq}}{Pe_{cc}} \quad (2.3)$$

$$A_4 = \frac{L_{Ma}}{L_{Me}} \quad (2.4)$$

$$A_5 = E_t \quad (2.5)$$

O atributo  $A_1$  refere-se às relações entre as grandezas do próprio objeto da imagem, onde  $Pe_o$  é o perímetro e  $A$  é a área do objeto. O atributo  $A_2$  refere-se à aproximação da elipse, onde a excentricidade  $E_x$  de uma elipse é a proporção entre a distância entre os focos e o eixo de maior comprimento. Já o atributo  $A_3$  refere-se à aproximação do círculo, onde  $D_{eq}$  é o diâmetro equivalente e  $Pe_{cc}$  perímetro equivalente. O atributo  $A_4$  refere-se novamente à aproximação da

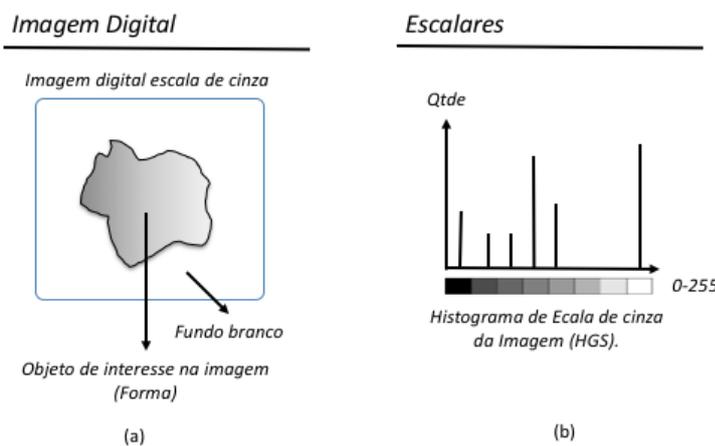
elipse, onde  $L_{Ma}$  é o lado maior e  $L_{Me}$  o lado menor e o atributo  $A5$  refere-se à aproximação do retângulo, onde a extensão  $E_t$  é a relação entre a área total da imagem e a área que contém a aproximação do retângulo.

### 2.3.3.2 Atributos Estatísticos

Uma maneira que garante uma extração eficiente de atributos referentes à informação estatística de objetos de interesse em uma imagem é a obtenção de histogramas da imagem. O histograma de uma imagem é uma apresentação gráfica que contém a informação da distribuição quantitativa dos *pixels*. O eixo horizontal descreve a tonalidade do píxel (0 a 255) e o eixo vertical indica a quantidade de vezes que o determinado *pixel* aparece na imagem.

Os histogramas podem ser extraídos de imagens coloridas e em escala de cinza. No caso da extração de histogramas da imagem colorida, é necessário realizar um pré-processamento com o intuito de separar as componentes do padrão de cor da imagem. Assim, é obtido o histograma de cada componente separadamente. Para o caso da necessidade de obter um histograma em escala de cinza de uma imagem, é necessária a realização de um pré-processamento na imagem de modo a efetuar a transformação. No caso da necessidade de obter histogramas de uma outro espaço de cores, é necessário realizar um pré-processamento para efetuar a mudança de padrão e posteriormente realizar a separação das componentes para obtenção individual dos histogramas.

O conjunto de características que podem ser extraídas com base em distribuição estatística dos *pixels* da imagem, tanto coloridos como em escala de cinza, são, por exemplo o histograma da imagem em escala de cinza e os histogramas individuais dos componentes dos padrões de cor da imagem. A Figura 13 apresenta um exemplo de histograma extraído de uma imagem digital.



**Figura 13** – Cálculo de escalares e extração de atributos de uma forma com base em aspectos estatísticos. (a) imagem com fundo branco. (b) histograma de escala de cinza da imagem. Fonte: Próprio Autor.

Após a extração do histograma ou do conjunto de histogramas, o próximo passo consiste na criação dos atributos. Graficamente o histograma apresenta o comportamento de um sinal, portanto, podem ser realizadas operações para cálculo de grandezas estatísticas sobre este conjunto de dados. Este tipo de abordagem tem como objetivo extrair do histograma, informações complementares sobre a dispersão ou concentração dos *pixels* na imagem. Exemplos de atributos estatísticos que estão apresentados nas Equações 2.6 à 2.9 onde, para o histograma  $h$  normalizado,

a probabilidade estimada  $p$  para cada intervalo da imagem é  $p(i) = h(i)/N.M$ ,  $i$  é o índice do histograma,  $L$  é quantidade máxima de *pixels* na imagem e  $N$  e  $M$  são as dimensões da imagem:

$$A_6 \rightarrow \mu_1 = \sum_{i=0}^{L-1} ip(i) \quad (2.6)$$

$$A_7 \rightarrow \sigma^2 = \sum_{i=0}^{L-1} (i - \mu_1)^2 p(i) \quad (2.7)$$

$$A_8 \rightarrow \sigma^3 = \sum_{i=0}^{L-1} (i - \mu_1)^3 p(i) \quad (2.8)$$

$$A_9 \rightarrow \sigma^4 = \sum_{i=0}^{L-1} (i - \mu_1)^4 p(i) - 3 \quad (2.9)$$

$$(2.10)$$

Também podem ser estimados do histograma informações como Entropia  $E_n$  e energia  $E_t$ . As Equações 2.11 e 2.12 apresentam exemplos de atributos:

$$A_{10} \rightarrow E_n = \sum_{i=0}^{L-1} [p(i)]^2 \quad (2.11)$$

$$A_{11} \rightarrow E_t = - \sum_{i=0}^{L-1} p(i) \log_2 [p(i)] \quad (2.12)$$

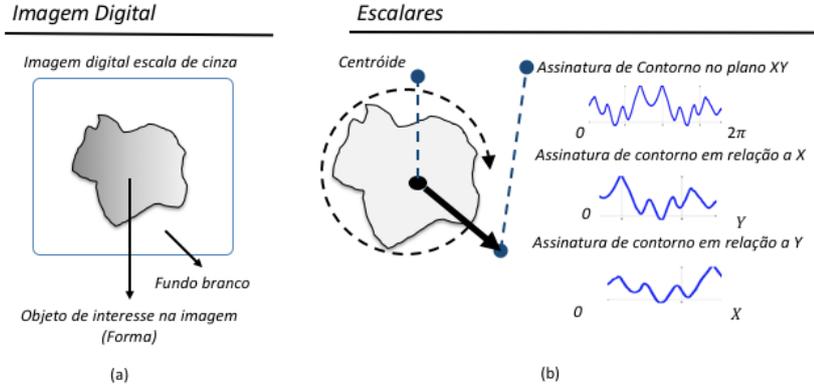
Os Atributos de  $A_6$  a  $A_9$  referem-se a informações complementares de ordem estatística sobre o histograma onde  $\mu$  é a média (ME),  $\sigma^2$ , a variância (VA),  $\sigma^3$  a assimetria (AS) (primeiro, segundo e terceiro momento da distribuição de frequências) e a Curtose é  $\sigma^4$  (CT), definida pela medida do achatamento das características da distribuição em relação à curva gaussiana. O próprio histograma também pode ser utilizado como atributo. Os atributos  $A_{10}$  e  $A_{11}$  são medidas de informação e energia, onde  $E_t$  é a Entropia (ET) e  $E_n$  é a energia (EN) do histograma.

### 2.3.3.3 Atributos de Contorno e Frequência

Para realizar a extração ótima de atributos relativos ao formato e curvatura dos objetos de interesse em uma imagem, são utilizadas técnicas de pré-processamento para colocar a imagem em escala de cinza. Esta configuração possibilita em muitos casos, a melhor resposta dos algoritmos de contorno em comparação com a imagem no padrão de cores ou segmentada.

Esta técnica tem como princípio a representação do contorno de um objeto (assinatura de contorno) de interesse em uma imagem como um sinal. Inicialmente, ocorre uma mudança de representação do plano da imagem formado por *pixels* para um plano bidimensional  $XY$  formado por coordenadas cartesianas. Após este processo, através do centroide do objeto, traça-se retas para efetuar o cálculo da distância entre determinado ponto de fronteira do objeto e o centroide, iniciando em zero e variando o ângulo de inclinação desta reta até o retorno à origem. Assim, ocorre a mudança do plano de coordenadas cartesianas para o plano de coordenadas polares. De

forma complementar, podem também ser realizados deslocamentos laterais em relação a  $X$  e em relação a  $Y$ . O processo de extração da assinatura de contorno relativo ao objeto de interesse presente na imagem, é apresentado na Figura 14.



**Figura 14** – Extração de assinatura de contorno de um objeto de interesse presente em uma imagem. (a) Imagem em escala de cinza. (b) assinaturas de contorno em relação ao plano XY e em relação aos deslocamentos parciais de X e de Y. Fonte: Próprio Autor.

A conformação da assinatura de contorno é uma representação de conjunto de escalares que pode ser interpretada como um sinal. Neste sentido, pelo comportamento do mesmo, é possível obter descritores que representem o comportamento destas curvas no domínio da frequência através de transformadas. As transformadas comumente utilizadas são a transformada de Fourier e a transformada Wavelet. As Equações 2.13 à 2.15 apresentam exemplos de atributos:

$$A_{12} = D(u)_f = \sum_{i=0}^{L-1} f(i)(exp)^{[-j2\pi iu]/N} \quad (2.13)$$

$$A_{13} = D_{wx} = \text{wavedec}(x, \text{dec}, \text{daubechies}) \quad (2.14)$$

$$A_{14} = D_{wy} = \text{wavedec}(y, \text{dec}, \text{daubechies}) \quad (2.15)$$

Assim como nos atributos de ordem estatística, neste caso também podem ser obtidas informações referentes à incerteza e à energia do sinal, conforme as equações 2.16 à 2.19.

$$A_{15} = E_{tx} = - \sum_{i=0}^{L-1} x(i) \log_2[x(i)] \quad (2.16)$$

$$A_{16} = E_{nx} = \sum_{i=0}^{L-1} [x(i)]^2 \quad (2.17)$$

$$A_{17} = E_{ty} = - \sum_{i=0}^{L-1} y(i) \log_2[y(i)] \quad (2.18)$$

$$A_{18} = E_{ny} = \sum_{i=0}^{L-1} [y(i)]^2 \quad (2.19)$$

O Atributo  $A_{12}$  refere-se ao descritor de Fourier  $D_f$ , extraído do contorno do objeto de interesse da imagem. Este descritor representa no domínio da frequência, informações sobre o módulo da assinatura de contorno. Geralmente é decomposto em uma quantidade limitada de

componentes, com o objetivo de simplificar a análise. Caso o sinal seja muito grande ou apresente muitos componentes, ele também pode ser inicialmente decomposto por uma transformada Wavelet, com o objetivo da simplificação.

O Atributo  $A_{13}$  refere-se ao descritor Wavelet  $D_{wx}$  do sinal obtido do contorno parcial em relação a  $X$  e o Atributo  $A_{14}$  refere-se ao descritor Wavelet  $D_{wy}$ , obtido do contorno parcial em relação ao eixo  $Y$ . Em ambos os casos, tanto no sinal referente ao contorno total quanto referente ao contorno parcial do objeto de interesse na imagem, podem ser obtidas informações complementares. Os Atributos  $A_{15}$  e  $A_{16}$  referem-se às informações de entropia  $E_{tx}$  e energia  $E_{nx}$  sobre estes descritores em relação a  $X$  e os Atributos  $A_{17}$  e  $A_{18}$  referentes às informações de entropia  $E_{ty}$  e energia  $E_{ny}$  sobre estes descritores em relação a  $Y$ .

#### 2.3.3.4 Vetor de Características

Com a extração dos escalares (ou conjunto de escalares) e o cálculo das relações entre eles, pode ser realizada uma combinação destes valores de forma sequencial formando vetores. Portanto, os atributos do tipo geométrico, estatístico e do domínio da frequência que foram apresentados, formam os conjuntos descritos nas equações 2.20 à 2.22, onde  $H$  é o respectivo histograma o qual serão extraídos os atributos  $A_6$  a  $A_{11}$ .

$$A_{geo} = [A_1, A_2, A_3, A_4, A_5] \quad (2.20)$$

$$A_{est} = [H, A_6, A_7, A_8, A_9, A_{10}, A_{11}] \quad (2.21)$$

$$A_{frq} = [A_{12}, A_{13}, A_{14}, A_{15}, A_{16}, A_{17}, A_{18}] \quad (2.22)$$

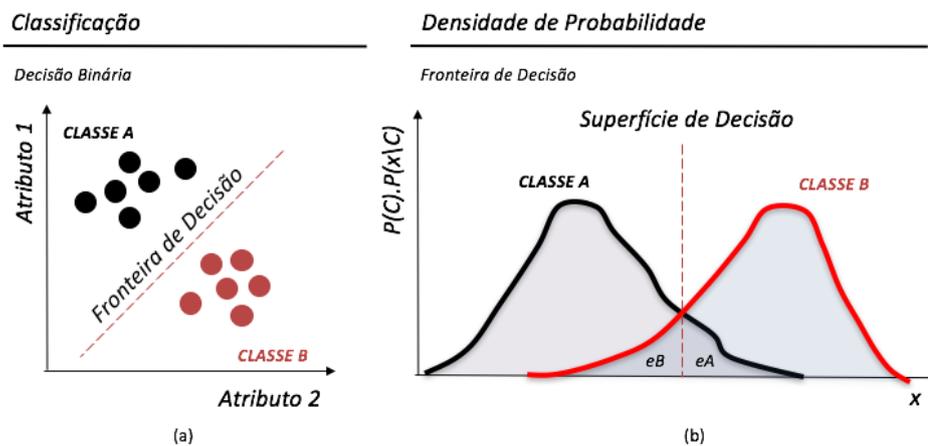
### 2.3.4 Reconhecimento de Padrões e Classificação

Um algoritmo preditivo é uma função que, dado um conjunto de exemplos rotulados, constrói um estimador. O rótulo ou etiqueta toma valores num domínio conhecido. Se esse domínio for um conjunto de valores nominais, tem-se um problema de classificação, também conhecido como aprendizado de conceitos, e o estimador gerado é um classificador [46].

Ainda segundo [46], um classificador no que lhe concerne, também é uma função que dado um exemplo não rotulado, atribui esse exemplo a uma das possíveis classes, de modo que a função que representa o classificador, assuma valores em um conjunto discreto não ordenado, representado pelo número de classes [46].

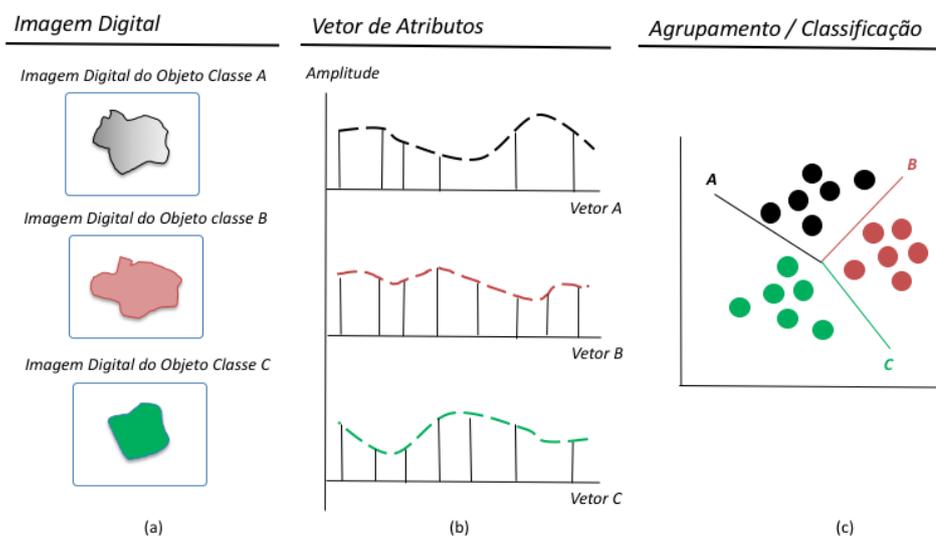
Considerando, em termos simples, um problema de classificação binário, a meta é encontrar uma fronteira de decisão que separe duas classes. Assim, assumindo que é conhecida a função de densidade de probabilidade (*Probability Density Function* - PDF) para cada classe (e um único atributo de entrada), o melhor classificador possível divide o domínio da variável no ponto de intersecção das duas PDFs, ou seja, classifica o objeto com a maior densidade de probabilidade [46]. A Figura 15 ilustra um exemplo de decisão binária na qual se estabelece uma fronteira de decisão para distinguir atributos de duas classes e uma superfície de decisão que estabelece

a escolha de uma determinada classe em função da sua posição em relação às PDFs das duas classes.



**Figura 15** – Formação de um classificador que distingue duas classes A e B (a) Representação de uma Fronteira de Decisão (b) Representação de uma superfície de decisão entre as densidades de probabilidade das duas classes, onde eB e eA na área cinzenta do diagrama, representam o erro cometido pelo classificador. Fonte: Próprio Autor.

Por conseguinte, na etapa de reconhecimento de padrões (ou etapa de classificação) os atributos extraídos da imagem podem ser utilizados para diferenciar objetos de classes distintas. A utilização de uma metodologia padronizada de extração de atributos de uma imagem, permite a construção de vetores com mesmos parâmetros, porém que apresentam formatos diferentes. Segundo [47], considera-se que estes vetores possuem uma função de densidade de probabilidade típica da sua classe. Portanto, um classificador estatístico deve ser capaz de definir superfícies ou regiões de decisão para determinadas classes. A Figura 16 apresenta um exemplo de processo de classificação com 3 classes, com base em um vetor criado a partir de atributos extraídos das respectivas imagens.



**Figura 16** – Formação de um vetor de características com base em conjuntos de valores escalares e de relações entre escalares. (a) Imagens de classes distintas. (b) Vetores de atributos extraídos das imagens. (c) Classificação de objetos com base nas diferenças entre as características. Fonte: Próprio Autor.

De modo geral, os algoritmos de classificação necessitam de uma validação experimental para medir seu desempenho, que pode seguir diversos aspectos como acurácia do modelo, tempo de processamento, compressibilidade da informação extraída, tempo de aprendizado e requisitos de armazenamento, entre outros [46]. Seja um problema de duas classes, usualmente uma classe é denominada como (+) e a outra como (-). Assim é possível obter a matriz de confusão definida na Tabela 17.

**Desempenho do Classificador**

---

*Matriz de Confusão*

		Classe Predita	
		Classe A (+)	Classe B (-)
Classe Verdadeira	Classe A (+)	VP	VN
	Classe B (-)	FP	FN

**Figura 17** – Matriz de confusão de um problema de duas classes. Fonte: Próprio Autor.

onde:

- VP corresponde ao número de verdadeiros positivos, ou seja, o número de exemplos da classe positiva classificados corretamente [46];
- VN corresponde ao número de verdadeiros negativos, ou seja, o número de exemplos da classe negativa classificados corretamente [46];
- FP corresponde ao número de falsos positivos, ou seja, o número de exemplos cuja classe verdadeira é negativa mas que foram classificados incorretamente como pertencendo à classe positiva [46];
- FN corresponde ao número de falsos negativos, ou seja, o número de exemplos pertencentes originalmente à classe positiva que foram incorretamente preditos como da classe negativa [46].
- Ademais,  $n = VP + VN + FP + FN$ .

A partir da matriz de confusão, uma série de outras medidas de desempenho podem ser derivadas, como as descritas abaixo.

- Taxa de erro na classe positiva: proporção de exemplos de classe positiva incorretamente classificados pelo preditor  $f_p$ , também conhecida como taxa de falsos negativos (TFN) [46].

$$err_+(f_p) = TFN = \frac{FN}{VP + FN} \quad (2.23)$$

- Taxa de erro na classe negativa: proporção de exemplos da classe negativa incorretamente classificados por  $f_p$ , também conhecida como taxa de falsos positivos (TFP) [46].

$$err_-(f_p) = TFP = \frac{FP}{FP + VN} \quad (2.24)$$

- Taxa de acerto total ou acurácia total: calculada pela soma dos valores da diagonal principal da matriz de confusão, dividida pela soma dos valores de todos os elementos da matriz [46].

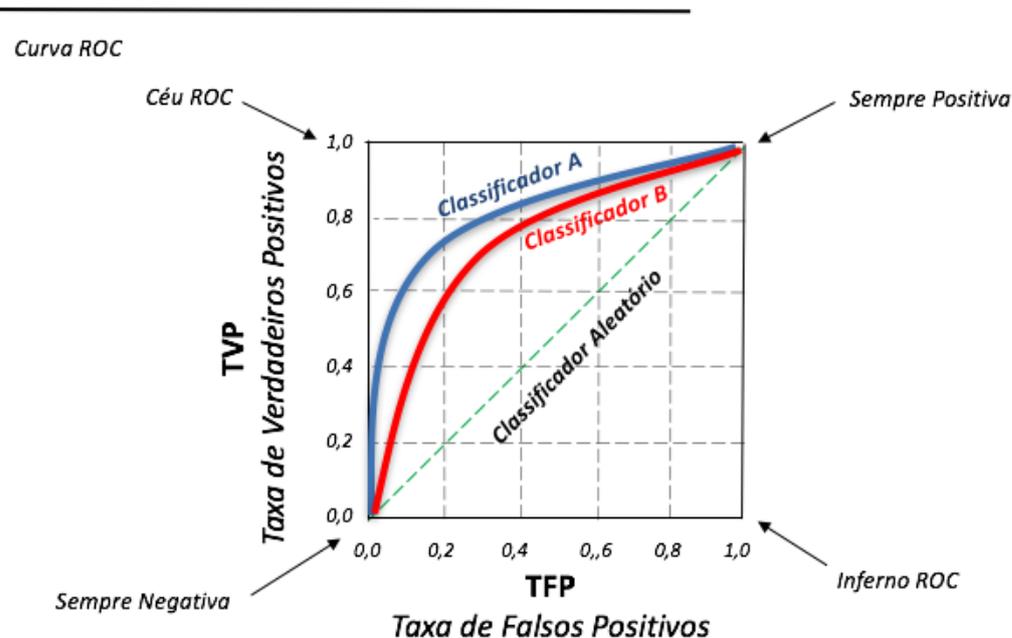
$$A_{cu}(f_p) = \frac{VP + VN}{n} \quad (2.25)$$

As medidas descritas podem ser generalizadas para problemas com mais de duas classes, pela consideração de cada classe como positiva em relação ao conjunto das demais classes, a exceção das taxas de erro e acerto totais, casos em que todas as classes são consideradas globalmente [46].

Outra forma de avaliar o desempenho de classificadores é através da análise das curvas de operações de características recebidas (*Receiver Operating Characteristics - ROC*) [46]. A ROC é uma curva bidimensional plotada em um espaço denominado espaço ROC, com os eixos  $X$  e  $Y$  representando as medidas de taxa de falsos positivos TFP e taxa de verdadeiros positivos TVP, respectivamente.

O ponto (0,1) representa classificações com todos os exemplos positivos e negativos classificados corretamente (chamado de *Céu ROC*). O ponto (1,0) representa o *Inferno ROC*. Já o ponto (1,1) representa classificações sempre positivas e o ponto (0,0) sempre negativas. Neste espaço, um classificador é considerado tão melhor quanto mais próximo do ponto (1,0) [46]. A curva ROC é apresentada na Figura 18.

### Desempenho do Classificador



**Figura 18** – Construção da curva ROC com dois classificadores binários. Fonte: Próprio Autor.

Na Figura 18 são apresentadas duas curvas ROC, representando dois classificadores. Neste caso, não está ocorrendo intersecção entre as curvas. O classificador de melhor desempenho está mais próximo do ponto (0,1). Entretanto pode haver casos em que ocorram intersecções,

fazendo com que em determinados pontos um classificador tenha desempenho melhor ou pior que o outro. Entretanto, é comum a comparação de desempenho dos algoritmos analisando a área abaixo da curva ROC (*Area Under ROC Curve AUC*) [46].

Para realizar este processo de diferenciação entre as diferentes formas, podem ser utilizadas diversas técnicas de classificação. Segundo [45], esta etapa denominada reconhecimento de padrões, possui uma extensa literatura. Deste modo, utilizam-se para este fim, técnicas da área de aprendizagem de máquina.

## 2.4 Aprendizado de Máquina

Nas últimas décadas, com a crescente complexidade dos problemas a serem tratados computacionalmente e do volume de dados gerados por diferentes setores, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, que fossem mais autônomas, reduzindo a necessidade de intervenção humana e dependência de especialistas [46]. Segundo [46], estas técnicas deveriam ser capazes de criar por si próprias, a partir da experiência, uma hipótese ou função, capaz de resolver o problema que se deseja tratar.

Ainda segundo [46], a esse processo de indução de uma hipótese (ou aproximação de função) a partir do passado dá-se o nome de Aprendizado de Máquina (AM). Portanto, a capacidade de aprendizado é considerada essencial para um comportamento inteligente. Atividades como memorizar, observar e explorar situações para aprender fatos, melhorar habilidades motoras/cognitivas através de práticas e organizar conhecimento novo em representações apropriadas podem ser consideradas atividades relacionadas ao aprendizado. Conforme [46], motivações para as pesquisas nesta área, incluem a possibilidade de aumentar a compreensão de como se dá o aprendizado dos seres vivos.

Algumas técnicas de AM realizam a busca pela hipótese que descreve os dados recorrendo à otimização de alguma função [46]. Nesse processo, um problema de aprendizado é formulado como um problema de otimização em que o objetivo consiste em minimizar (ou maximizar) uma função objetivo [48]. Uma das técnicas conhecidas que recorrem à otimização de uma função em seu treinamento, são as Redes Neurais Artificiais (RNAs) e a Máquina de Vetor de Suporte (*Support Vector Machines - SVMs*) [46]. Outras técnicas recorrem a outros métodos como a probabilidade de ocorrência de um evento através da Cadeia Oculta de Markov (*Hidden Markov Model - HMM*), o agrupamento de dados como os  $k$ -vizinhos próximos (*k-Nearest Neighbors - k-NNs*) ou técnicas de busca como as árvores de decisão (*Decision Trees - DTREES*).

### 2.4.1 Métodos Baseados em Otimização

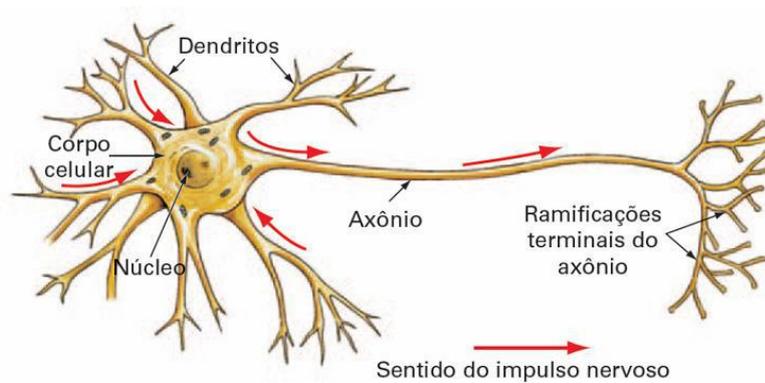
#### 2.4.1.1 Redes Neurais Artificiais

Um dos primeiros modelos matemáticos para um neurônio foi proposto por McCulloch e Pitts (1943) e tem como inspiração a estrutura e o funcionamento do sistema nervoso [46]. Inicialmente o modelo não tinha capacidade de aprendizagem, conceito que veio a ser introduzido anos depois a partir da contribuição de diversos cientistas. Conforme [46], os trabalhos iniciais de RNA tinham por objetivo compreender o cérebro e utilizar o conhecimento obtido para

desenvolver sistemas de aprendizado biologicamente plausíveis. Dessa forma, as RNAs são baseadas em modelos abstratos de como pensamos que o cérebro (e os neurônios) funcionam.

O sistema nervoso é um conjunto complexo de células que determinam o funcionamento e o comportamento dos seres vivos [46]. Segundo [49], o cérebro humano possui bilhões de neurônios, sendo que um neurônio é capaz de criar até 10 mil sinapses com outros neurônios. Entretanto, [46] afirma que o cérebro humano possui a ordem de 10 a 500 bilhões de neurônios organizados em 1000 módulos principais que se comunicam, cada um com 500 redes neurais.

Os componentes básicos do neurônio são os dendritos, o corpo e o axônio. Os dendritos efetuam a recepção de sinais oriundos de outros neurônios para o corpo celular, o qual é responsável por realizar a combinação das informações vindas de outros neurônios. Já o axônio é responsável pela transmissão das informações para os próximos neurônios ou para as células de outros sistemas. A Figura 19 apresenta um exemplo de um neurônio biológico [50].



**Figura 19** – Neurônio Biológico. Adaptado de [43].

As Redes Neurais Artificiais são sistemas computacionais distribuídos compostos de unidades de processamento simples densamente conectadas [46]. Segundo [48], um neurônio é uma unidade de processamento de informação que é fundamental para uma rede neural. O modelo do neurônio forma a base para o projeto de redes neurais artificiais.

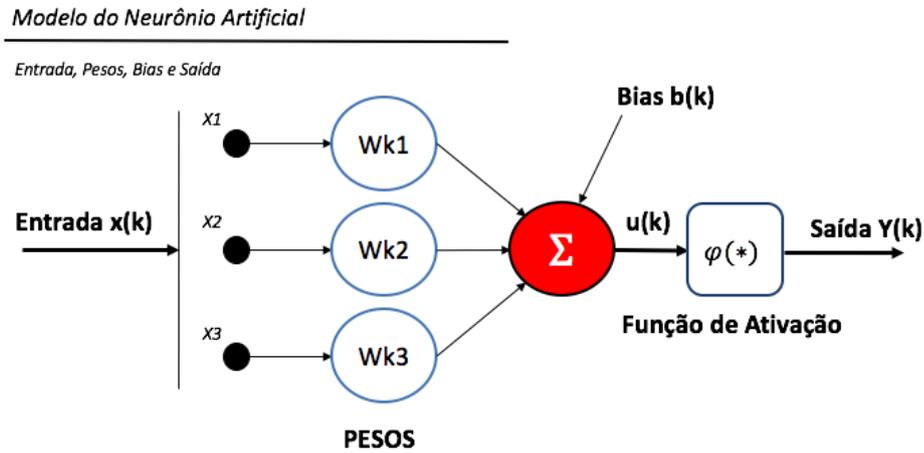
Supondo um vetor  $\mathbf{x}$  com  $d$  atributos de entrada,  $\mathbf{x} = [x_1, x_2, \dots, x_d]t$ , e um neurônio com  $d$  terminais de entrada, cujos pesos são  $w = [w_1, w_2, \dots, w_n]$ , a entrada total recebida pelo neurônio  $u$  pode ser representada pela Equação 2.26 [46] [48]:

$$u = \sum_{j=1}^d x_j \cdot w_j \quad (2.26)$$

A saída de um neurônio é definida por meio da aplicação de uma função de ativação. Existem várias propostas de funções de ativação na literatura, entretanto, as mais utilizadas são a função linear, limiar e sigmoideal [48]. Definindo  $k$  como o número da interação e  $u_k$  como a saída do combinador linear, o sinal de saída é  $Y_k$ ,  $b_k$  é o bias e  $\phi(\cdot)$  é a função de ativação. A equação 2.27 apresenta o sinal de saída do neurônio [48]:

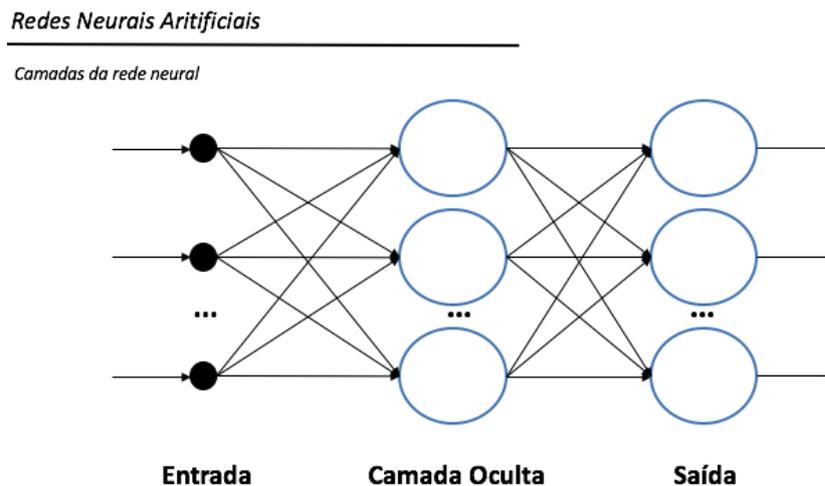
$$Y_k = \phi(u_k + b_k) \quad (2.27)$$

A Figura 20 apresenta o modelo de um neurônio artificial.



**Figura 20** – Modelo matemático do neurônio. Fonte: Próprio Autor.

Em uma RNA, os neurônios podem estar dispostos em uma ou mais camadas [46]. Quando duas ou mais camadas são utilizadas, um neurônio pode receber em seus terminais de entrada, valores de saída de uma camada anterior e/ou enviar saídas para os terminais de entrada da camada seguinte [46]. Uma rede com mais de uma camada de neurônios recebe o nome de rede multicamadas. A camada de neurônios que gera os valores de saída é chamada de camada de saída. As demais camadas são chamadas camadas intermediárias, escondidas ou ocultas [46]. A Figura 21 ilustra um exemplo de uma RNA multicamadas típica.



**Figura 21** – Exemplo de RNA multicamadas totalmente conectada. Fonte: Próprio Autor.

A primeira RNA a ser implementada que utilizou o modelo do neurônio de McCulloch-Pitts e introduziu o processo de treinamento foi a rede *perceptron*. Esta rede foi desenvolvida por Rosenblatt (1958). Entretanto, por ser uma rede de uma única camada, apresentava limitações por somente resolver problemas linearmente separáveis.

Segundo [46], para resolver problemas não linearmente separáveis usando RNAs, a alternativa mais utilizada é adicionar uma ou mais camadas intermediárias. As redes do tipo *perceptron* multicamadas, (MLP, do inglês *Multilayer Perceptron*) apresentam uma ou mais camadas intermediárias de neurônios e uma camada de saída. O algoritmo comumente utilizado para efetuar o treinamento desta rede chama-se *back-propagation* [46].

As Redes Neurais Artificiais são amplamente utilizadas na área de processamento de imagem, com aplicações voltadas a problemas de classificação, como, por exemplo, para diagnóstico de câncer [51], classificação de equipamentos elétricos [52] e diagnóstico de qualidade de materiais como madeira [53]. A solução destes problemas requer o uso dos princípios e técnicas de reconhecimento de padrões em imagens.

#### 2.4.1.2 Máquina de Vetor de Suporte

As máquinas de vetores de suporte (*Support Vector Machines - SVMs*) vem recebendo crescente atenção da comunidade de AM nos últimos anos. Os resultados da aplicação dessa técnica são comparáveis e muitas vezes superiores aos obtidos por outros algoritmos populares de aprendizado, tal como as RNAs. Exemplos de aplicações de sucesso podem se encontrados em diversos domínios, como na classificação de textos e em Bioinformática [46].

Uma SVM pode ser entendida como um classificador discriminativo que separa dados de duas classes distintas de maneira que este espaço de separação seja o maior possível. Em suma, a SVM cria um plano de separação entre dados de duas classes, chamado de hiperplano [54]. Essa linha busca a maior distância entre os pontos mais próximos em relação a cada uma das classes. A Figura 22 apresenta um exemplo de um problema de separação de duas classes com SVM.

#### Máquina de Vetor de Suporte

Hiperplano de Separação

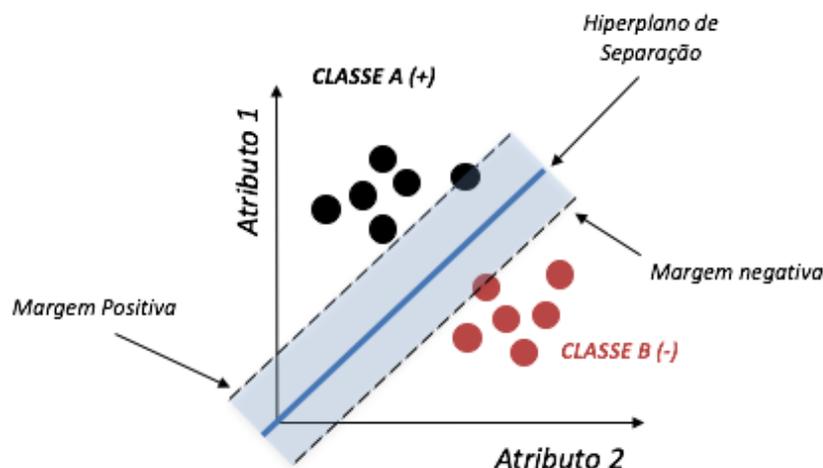


Figura 22 – Exemplo de um hiperplano de separação binária de uma SVM. Fonte: Próprio Autor.

Seja  $X$  um conjunto de treinamento com  $n$  componentes  $x_i$  e seus respectivos rótulos  $y_i \in Y$ , onde  $Y = (-1, +1)$  são as possíveis classes,  $X$  é linearmente separável se for possível

separar os objetos das classes -1 e +1 por um hiperplano [46]. Classificadores que efetuam esta separação por um hiperplano são considerados lineares. A equação 2.28 apresenta a definição do hiperplano, onde  $\mathbf{w}$  é o vetor normal e  $\frac{b}{|\mathbf{w}|}$  é a distância do hiperplano em relação a origem.

$$h(x) = \mathbf{w} \cdot \mathbf{x} + b \quad (2.28)$$

Essa equação pode ser utilizada para dividir o espaço de entrada  $\mathbf{X}$  em duas regiões  $h(x) > 0$  e  $h(x) < 0$ . A partir de  $h(x)$  é possível obter um número infinito de hiperplanos equivalentes, pela multiplicação de  $\mathbf{w}$  e  $b$  por uma mesma constante. Esta condição do caso linear, recai em um problema de otimização na qual a maximização da margem de separação entre os objetos em relação a  $\mathbf{w} \cdot \mathbf{x} + b = 0$  pode ser obtida pela minimização de  $\|\mathbf{w}\|$ , atendendo à restrição  $y_i(\mathbf{w} \cdot \mathbf{x} + b) - 1 > 0$  [46].

No caso não linear, as SVMs lidam com o problema mapeando o conjunto de treinamento de seu espaço original, referenciado como de entradas, para um novo espaço de maior dimensão, denominado espaço de características [46]. Seja  $\psi_M : X \rightarrow \Gamma$  um mapeamento, onde  $X$  é o espaço de entradas e  $\Gamma$  denota o espaço de características. A escolha apropriada de  $\psi_M$  faz com que o conjunto de treinamento mapeado em  $\Gamma$  possa ser separado por uma SVM Linear [46]. Neste modelo, se faz necessário o cálculo dos produtos escalares entre os objetos no espaço de características  $\Gamma$ . Isso é obtido com o uso das funções denominadas *kernels*, seja  $K$  definida pela equação 2.29

$$K(x_i, x_j) = \Gamma(x_i) \cdot \Gamma(x_j) \quad (2.29)$$

Os *kernels* mais utilizados são o sigmoide, função de base radial e o polinomial [46]. Assim, uma função sinal pode ser utilizada para definir o classificador dado por:

$$g(\mathbf{x}) = \text{sgn}(h(\mathbf{x})) = \text{sgn}\left(\sum_{x_i \in SV} x_i^* \cdot y_i \cdot K(\mathbf{x}_i, \mathbf{x}) + b^*\right) \quad (2.30)$$

onde o  $b^*$  é um coeficiente de distância e  $x_i^*$  é o conjunto de soluções possíveis do classificador.

## 2.4.2 Métodos Baseados em Probabilidade

### 2.4.2.1 Modelo Oculto de Markov

Os modelos ocultos de Markov são compostos por um processo estocástico duplo. O primeiro processo é descrito por um conjunto de estados não diretamente observáveis, por isso, esse modelo é denominado oculto. A transição entre os estados depende apenas do estado anterior [46]. Assim, a probabilidade de transição entre os estados desse modelo é representada através de uma matriz de transição  $A = \{a_{ij}\}$  descrita na Equação 2.31 [46]:

$$a_{ij} = P(q_{t+1} = S_j \mid q_t = S_i) \quad 1 \leq i, j \leq N \quad (2.31)$$

Sendo  $N$  o número de estados,  $q_t$  o estado atual e  $S = \{S_1, S_2, S_3, \dots, S_N\}$  o conjunto de estados

do modelo. Cada elemento  $a_{ij}$  da matriz de transição representa a probabilidade de mudança para um estado  $S_j$  no tempo  $t + 1$  sabendo que no tempo  $t$  o estado era  $S_i$  [46].

Em algumas aplicações, os estados não são diretamente observados, com isso, cada estado é observado através de um segundo processo estocástico. A sequência de observações é representada por um conjunto  $O = \{O_1, O_2, O_3, \dots, O_T\}$ , onde cada elemento  $O_t$  representa um símbolo do conjunto finito de símbolos  $V = \{v_1, v_2, \dots, v_M\}$  sendo  $M$  o número de símbolos [46]. A probabilidade de emissão de símbolos em um estado  $j$  é definida na matriz  $B = b_j(k)$  da Equação 2.35:

$$a_{ij} = P(O_t = v_k | q_t = S_j) \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (2.32)$$

A probabilidade inicial de cada estado é representada por um conjunto  $\pi = \pi_i$  mostrada na Equação 2.33 [46]:

$$\pi_i = P(q_1 = S_i) \quad 1 \leq i \leq N \quad (2.33)$$

com

$$\sum_{n=1}^N \pi_n = 1 \quad (2.34)$$

Em um modelo regular de Markov, o estado é diretamente visível ao observador, portanto os únicos parâmetros usados são as probabilidades de transição de estado. Cada estado possui uma distribuição de probabilidade sobre os possíveis resultados conforme está descrito na Equação 2.35 [46]:

$$a_{ij} = P(O_t = v_k | q_t = S_j) \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (2.35)$$

#### 2.4.2.2 Modelo Naive Bayes

O Modelo Naive Bayes é uma técnica de classificação baseado no teorema de Bayes com base na suposição da independência entre as classes preditas [46]. Em outros termos, um classificador *Naive Bayes* assume que a característica de uma classe não está relacionada com a presença de outra. Por exemplo, uma fruta pode ser uma maçã se for vermelha, redonda, e tiver um diâmetro com cerca de 7 centímetros. Mesmo que esses atributos sejam dependentes ou dependam de outras características, todas as informações contribuem de forma independente para a probabilidade de que a fruta seja uma maçã o que dá ao classificador o nome de ‘Naive’ (ingênuo) [46].

O classificador *Naive Bayes* é de simples elaboração e é também útil para grandes volumes de dados [46]. Este tipo de classificador oferece resultado com base em probabilidade. O Teorema

de Bayes fornece uma forma de calcular a probabilidade posterior  $P(c | x)$  a partir de  $P(c)$ ,  $P(x)$  e  $P(x | c)$ , conforme apresenta a Equação 2.36:

$$P(c | x) = \frac{P(c | x)P(c)}{P(x)} \quad (2.36)$$

Supondo que  $P(x)$  denota a probabilidade de um exemplo  $x$  pertencer a classe  $y$ . A função de custo zero-um, que representa custo de associar  $x$  a uma classe incorreta, é minimizada se, e somente se,  $x$  é associado a classe  $y_k$  para a qual  $P(y_k | x)$  é máxima [46]. Esse método é denominado por estimativa MAP (do inglês, *Maximum A Posteriori*) [46]. Formalmente, a classe que deve ser associada ao exemplo  $x$  é dada pela expressão descrita na Equação 2.37:

$$y_{map} = \arg \max_i P(y_i | x) \quad (2.37)$$

Na qual  $\arg \max_i$  retorna a classe  $y_i$  com maior probabilidade de estar associada a  $x$ , que é aquela que possui o valor máximo para  $P(y_i | x)$ . Assumindo que os valores dos atributos de um exemplo são independentes entre si dada a classe,  $P(x | y_i)$  pode ser decomposto no produto  $P(x^1 | y_i \times \dots \times x^d | y_i)$  em que  $x^j$  é o  $j$ -ésimo atributo do exemplo  $x$ . Com isso, a probabilidade de um exemplo pertencer à classe  $y_i$  é proporcional à Equação 2.38:

$$P(y_i | x) \propto P(y_i) \prod_{j=1}^d dP(x^j | y_i) \quad (2.38)$$

O classificador descrito é obtido pelo uso da função discriminante dada pela Equação 2.37 e pela regra de decisão ilustrada na Equação 2.38.

### 2.4.3 Métodos Baseados em Distâncias

#### 2.4.3.1 Modelo do 1-Vizinho mais Próximo

O algoritmo dos vizinhos mais próximos tem variações definidas pelo número de vizinhos considerados. Dessas variações, a mais simples é o algoritmo 1-Vizinho mais próximo (1-NN, do inglês 1-Nearest Neighbor) [46].

Nesse algoritmo, cada objeto representa um ponto em um espaço definido pelos atributos, denominado espaço de entrada. Definindo uma métrica nesse espaço, é possível calcular as distâncias entre cada dois pontos. Existem diversos tipos de distância tais como *cityblock*, *chebychev*, *correlação*, *coseno*, *hamming*, *jaccard*, *spearman*, *minkowski* [46]. A métrica mais usual para isso é a distância euclidiana [46], dada pela Equação 2.39:

$$d_{Eu}(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_{l=1}^d (x_i^l - x_j^l)^2} \quad (2.39)$$

onde  $\mathbf{x}_i$  e  $\mathbf{x}_j$  são dois objetos representados por vetores no espaço  $R_d$ , e  $x_i^l$  e  $x_j^l$  são elementos desses vetores, que correspondem aos valores da coordenada  $l$  (atributos).

### 2.4.3.2 Modelo dos k-Vizinhos mais Próximos

Uma extensão imediata do algoritmo 1 – *NN* é considerar, em vez de 1 vizinho mais próximo, os  $k$  objetos do conjunto de treinamento, mais próximos do ponto de teste  $x_t$ , em que  $k$  é um parâmetro do algoritmo. Quando o valor de  $k$  é maior que 1, para cada ponto de teste, são obtidos os  $k$  vizinhos e cada vizinho vota em uma classe [46]. As previsões dos diferentes vizinhos são agregadas de forma a classificar o ponto de teste. Essa agregação é efetuada de forma diferente em problemas de classificação e de regressão [46].

No caso do problema da classificação, em que a classe toma valores em um conjunto discreto, cada vizinho vota em uma classe. O objeto de teste é classificado na classe mais votada. Formalmente, esse processo é equivalente a  $f(x_t) \leftarrow \text{moda}(f(X_1), f(X_2), \dots, f(X_k))$  que é justificado porque a constante que minimiza a função de custo 0-1 é a moda [46].

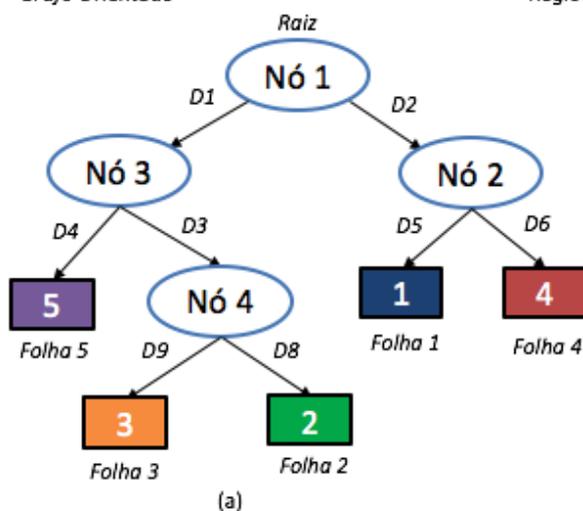
## 2.4.4 Métodos Baseados em Busca

### 2.4.4.1 Árvores de Decisão

Uma árvore de decisão utiliza a metodologia da divisão em conjuntos geralmente com nós de decisão binária. Assim, um problema complexo pode ser subdividido em diversos problemas menores. Estes podem ser combinados, na forma de uma árvore, para produzir uma solução do problema complexo. A vantagem deste modelo está na capacidade de dividir o espaço de instâncias em subespaços e cada subespaço é ajustado usando diferentes modelos [55]. A Figura 23 apresenta um exemplo de uma estrutura de uma Árvore de Decisão aplicada no problema da classificação.

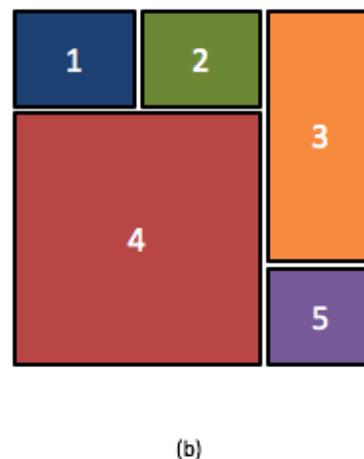
#### Árvore de Decisão

Grafo Orientado



#### Divisão das Classes na Base de Dados

Regiões de Decisão no Espaço de Objetos



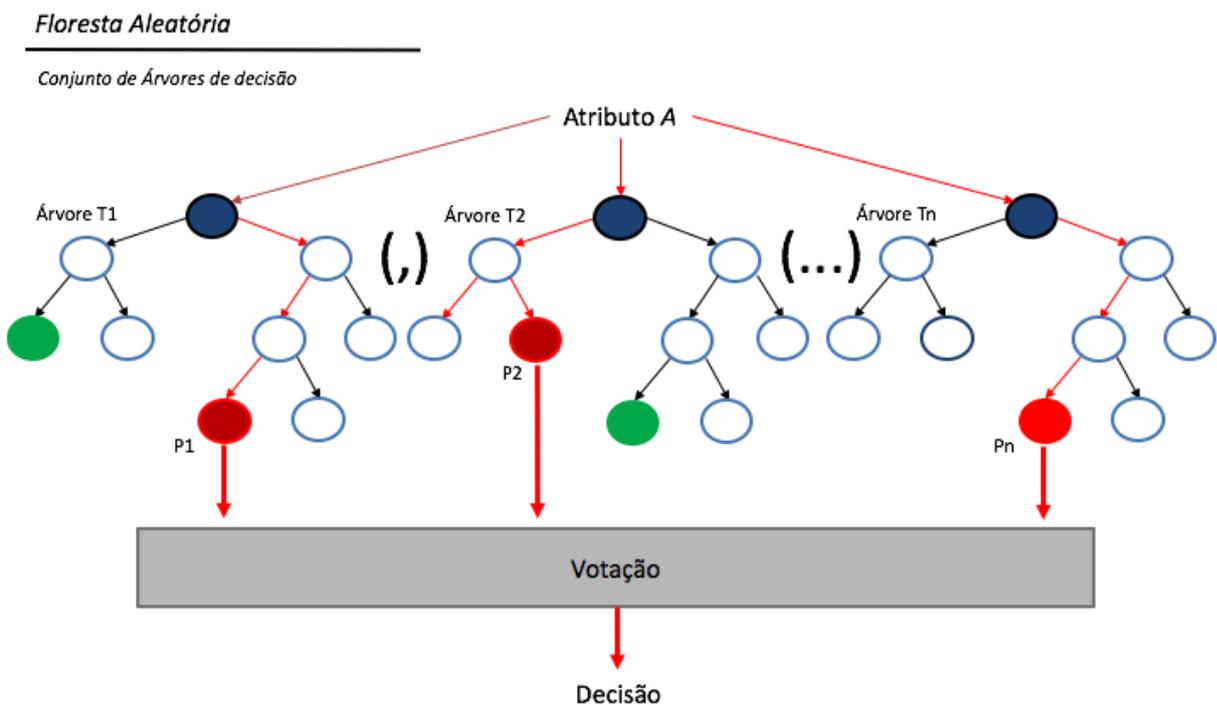
**Figura 23** – Diagrama Ilustrativo de uma Árvore de Decisão: (a) Árvore com Regras, nós de decisão e folhas (b) Exemplo de uma Divisão de 5 classes em um espaço de objetos. Fonte: Próprio Autor.

Conforme apresentado na Figura 23, uma árvore é basicamente um grafo direcionado sem ciclos, composto de nós de divisão, que contém um teste condicional, com nós e folhas que contém

uma função [55]. Uma árvore de decisão abrange todo o espaço de instâncias. Esse fato implica que uma árvore de decisão pode fazer previsões de qualquer exemplo de entrada. O espaço de hipótese da árvore de decisão enquadra-se dentro do formalismo Forma Normal Disjuntiva (FND). Classificadores gerados por esses sistemas codificam uma FND para cada classe [46].

#### 2.4.4.2 Florestas Aleatórias

A Floresta Aleatória é um algoritmo de aprendizagem que cria uma combinação (*ensemble*) de árvores de decisão, em sua maioria, são treinados com o método de agrupamento (*bagging*). Este método estabelece como princípio, que a combinação dos modelos de aprendizado tende a melhorar a eficiência global do classificador. A Figura 24 apresenta um exemplo de constituição de uma Floresta Aleatória.



**Figura 24** – Diagrama Ilustrativo de uma constituição de uma Floresta Aleatória. Fonte: Próprio Autor.

## 2.5 Compressão de Sinais

Os atributos extraídos das imagens, utilizados para a representação de uma determinada classe em aprendizagem de máquina, muitas vezes podem conter uma quantidade extensa de informação e até mesmo informação redundante. Neste sentido, as técnicas de compressão de sinais buscam a simplificação e a extração da porção relevante da informação.

### 2.5.1 Análise de Componentes Principais

Um problema comum em reconhecimento de padrões é a seleção de características ou extração de características. A seleção de características pode ser uma transformação projetada de tal forma que o conjunto de dados pode ser representado por um número reduzido de

características “efetivas” e ainda reter a maioria do conteúdo de informação intrínseco dos dados, ou seja, o conjunto de dados sofre uma redução na sua dimensionalidade [48].

A análise de componentes principais (PCA) é uma técnica estatística que tem como objetivo encontrar uma transformação linear na qual os sinais projetados não possuam correlação e a maior parte da energia esteja concentrada em um número reduzido de componentes [48].

Supondo um vetor aleatório de média nula  $\mathbf{x} = [x_1, \dots, x_n]^T$ . A projeção de  $\mathbf{x}$  na direção de  $\mathbf{v}$ , pode ser descrita como:

$$z_j = \mathbf{v}_j^T \mathbf{x} = \sum_{k=1}^N v_{kj} x_k \quad (2.40)$$

Os valores extraídos de  $z_j$  onde  $j = \{1, 2, \dots, n\}$  devem ser organizados em ordem crescente em função da variância das projeções. Devem também ser ortogonais. Assim,  $v_1$  pode ser obtido através de:

$$PCA_j(v_1) = E(z_i^2) = \mathbf{v}_1 \cdot \mathbf{C}_x \cdot \mathbf{v}_1 \quad (2.41)$$

Onde  $\mathbf{C}_x$  é a matriz de covariância de  $\mathbf{x}$ , cujos autovetores são  $\mathbf{e}_1, \dots, \mathbf{e}_n$ , o que garante a maximização da Equação 2.41. A condição para que a matriz  $\mathbf{C}_x$  seja equivalente à PCA de  $\mathbf{x}$  implica em uma organização de autovetores cujos autovalores associados obedeçam a um ordenamento decrescente em amplitude, fazendo com que  $\mathbf{v}_i = \mathbf{e}_i$ .

A análise de componentes principais é amplamente usada para compactação de informação. Como a PCA projeta os sinais em componentes ordenados por energia, usualmente armazenam-se apenas os componentes de maior energia, de modo que o sinal recuperado a partir da informação compactada tenha um erro médio quadrático pequeno, quando comparado ao sinal multidimensional original.

## 2.5.2 Transformada Wavelet

Diferentemente da transformada de Fourier, que utiliza como base funções senoidais, as transformadas Wavelet se baseiam em pequenas ondas, chamadas *wavelets*, de frequência variada e duração limitada [56]. Esta ferramenta permite avaliar um sinal através da sua decomposição no tempo e na frequência. A transformada wavelet pode ser definida como:

$$W(a, b) = \int_{-\infty}^{+\infty} f(t) \psi_{a,b}^*(t) dt \quad (2.42)$$

Onde a transformada é função dos valores  $a$  e  $b$  e a função  $f(t)$  é o sinal original no domínio do tempo. A função  $\psi_{a,b}^*(t)$  é definida como:

$$\psi_{a,b} = \frac{1}{\sqrt{|a|}} \psi^*\left(\frac{t-b}{a}\right) \quad (2.43)$$

A função  $\psi_{a,b}^*(t)$  cujo  $a = 1$  e  $b = 0$  é denominada *wavelet* mãe. As demais funções que assumem os outros valores para  $a$  e  $b$  são denominadas *wavelets* filhas. O valor  $b$  é definido como

parâmetro de translação e o valor  $a$  é definido como parâmetro de escala. Logo, as *wavelets* filhas formam uma família de curvas semelhantes à mãe, porém deslocadas no tempo e escaladas em amplitude [56].

Existem diversos tipos de *wavelets* utilizadas em diversas aplicações. No tempo contínuo, existem exemplos como *Beta wavelet*, *Mexican hat wavelet* e *Gaussian wavelet* [56]. No tempo discreto, a transformada de wavelet pode ser reescrita como:

$$f(t) = \sum_{-\infty}^{\infty} c_k \phi(t - k) + \sum_{k=-\infty}^{\infty} \sum_{j=0}^{\infty} d_{j,k} \psi(2^j t - k) \quad (2.44)$$

Onde as funções  $\phi(t)$  e  $\psi(t)$  são respectivamente *wavelet pai* e *wavelet mãe*. A equação 2.44 é denominada transformada discreta de *wavelet* (DWT). Uma maneira eficiente de realizar a DWT é através da decomposição por filtragens sucessivas do sinal discreto  $x[n]$ . Considerando os filtros digitais com espelhamento em quadratura com resposta finita ao impulso (FIR)  $g[n]$  (filtro passa-baixas) e  $h[n]$  (filtro passa-altas) o sinal original é decomposto em:

$$Y_{baixa} = \sum_{k=-\infty}^{\infty} x[k]g[2n - k] \quad (2.45)$$

$$Y_{alta} = \sum_{k=-\infty}^{\infty} x[k]h[2n - k] \quad (2.46)$$

O filtro  $g[n]$  produz o sinal de aproximação  $Y_{baixa}$  e o filtro  $h[n]$  produz o sinal de detalhe  $Y_{alta}$ . Os coeficientes destes filtros tem relação com os coeficientes da função *wavelet* selecionada para o processamento do sinal. Após a filtragem o sinal de saída é sub-amostrado por um fator de 2 [57]. A decomposição do sinal de entrada pela DWT pode ser computada em mais níveis, executando o processo de convolução dos coeficientes de aproximação pelos coeficientes do filtro selecionado, realizando novamente a sub-amostragem [57].

A DWT encontra diversas aplicações na área de processamento de imagens e visão computacional [58], com aplicações como a compressão de imagens para o padrão JPEG 2000 [59]. No tempo discreto, existem exemplos de *wavelets* como *Haar* e *Daubeuchies* que apresentam características de alta retenção de energia [60], indicando a possibilidade da sua utilização para compressão de dados [57].

As aplicações para compressão de sinais para aprendizagem de máquina, passam, por exemplo, pela área de qualidade de energia [61], diagnóstico de falhas em motores elétricos [62] e análise de risco de falhas em transformadores com reguladores de tensão [63].



## 3 Metodologia

Este capítulo apresenta a metodologia que foi utilizada para o desenvolvimento deste trabalho. Serão também descritas as características dos dados de referência utilizados para as simulações desenvolvidas.

### 3.1 Modelo Proposto

Neste trabalho, são utilizadas técnicas de processamento digital de imagens e de inteligência computacional com o intuito de classificar de forma inteligente, diferentes tipos de isoladores elétricos de média tensão, tomando como base as próprias imagens dos objetos, adquiridas em dois momentos: inicialmente em um experimento controlado em laboratório e em seguida, adquiridas em uma rede de distribuição didática não energizada em um ambiente externo. A Figura 25 apresenta o modelo proposto para o sistema de reconhecimento de padrões em imagens de isoladores:



**Figura 25** – Modelo proposto do sistema de reconhecimento de padrões em imagens.

Para avaliar aspectos relacionados a uma implementação experimental do sistema, foram adquiridas imagens com diferentes inclinações e rotações. A inclinação da imagem, por exemplo, é um aspecto prático importante, pois na operação de um sistema automático com *drones*, não é possível garantir que todas as imagens serão adquiridas com a mesma inclinação.

### 3.2 Materiais e Métodos

#### 3.2.1 Material

Amostras de isoladores de redes de distribuição para serem utilizadas neste trabalho, foram obtidas por doação da empresa local de distribuição de energia. As amostras disponíveis nos experimentos consistem em cinco isoladores de redes de distribuição que operam na faixa de 15KV, comumente utilizados em instalações rurais e urbanas são: polimérico (IPL), de porcelana (IPN), isolador de vidro (IVD) e saia baiana (ISB).

Em posse das amostras (uma amostra de cada tipo) foi feita a medição com paquímetro dos componentes e realizado o desenho CAD com fundo preto dos objetos em escala 1:10 e por

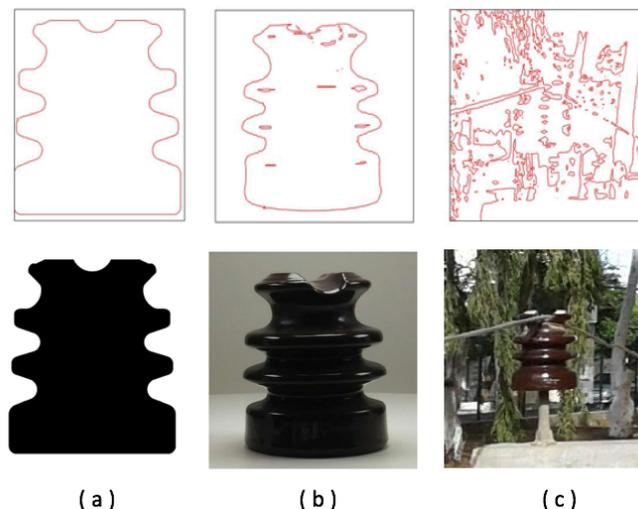
fim a sua cópia com fundo preto para testes nos algoritmos de extração de características. Os isoladores utilizados são exibidos na Figura 26.



**Figura 26** – Amostras de isoladores, locais de instalação e respectivo desenho de referência da esquerda para a direita: polimérico [IPL], porcelana [IPN], isolador de vidro [IVD] e saia baiana [ISB].

### 3.2.2 Métodos

Neste trabalho foi realizado o processamento de três tipos de imagens de isoladores: imagem de referência, imagens de laboratório e imagens em ambiente real. Em função dos desafios de implementação das técnicas de extração de atributos, as imagens de referência permitem um teste rápido dos algoritmos de extração, uma vez que a imagem encontra-se binarizada e com contorno bem definido. As imagens adquiridas em laboratório tem um fundo branco e luz normalizada, o que permite aos algoritmos de extração menor esforço na busca das regiões de fronteira que delimita o objeto. Já as imagens em ambiente real, possuem informações, tanto no fundo da imagem, quanto relativas aos componentes de fixação do isolador nos condutores e na estrutura do poste. A Figura 27 apresenta o exemplo de comparação entre os tipos de imagens estudados para o caso do isolador do tipo porcelana [IPN].

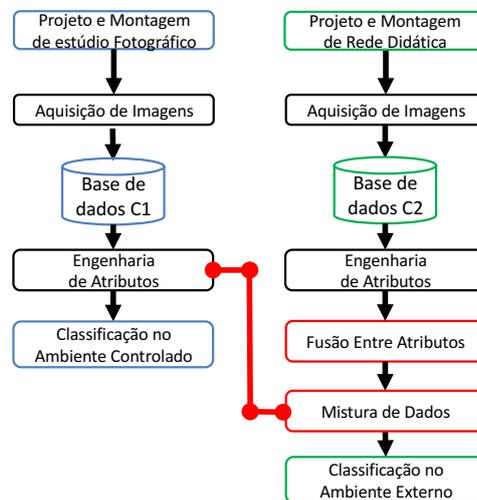


**Figura 27** – Exemplos dos três tipos de imagens processadas e seus respectivos contornos. (a) Referência. (b) Laboratório. (c) Ambiente externo.

A imagem de referência é única para cada amostra e refere-se a um desenho em escala, da projeção de cada isolador no plano bidimensional com vista frontal. As imagens adquiridas em laboratório possuem variação angular em relação ao próprio eixo do isolador e também sobre a visão frontal da câmera em relação ao objeto, com quantidades de imagens, dimensões e procedimento padronizado. Por fim, as imagens adquiridas em ambiente externo tem posicionamento aleatório da câmera em relação ao isolador, dimensão padronizada e contemplam as interferências do ambiente, comumente encontradas em uma rede de distribuição.

A metodologia para classificação de tipo de isolador (IPL, IPN, IVD, ou ISB) desenvolvida neste trabalho pode ser dividida em 2 partes. A primeira parte consiste do conjunto de estudos referente ao sistema controlado (em laboratório) e a segunda parte do trabalho consiste da realização de um conjunto de testes referente à Rede de Distribuição didática (Ambiente Externo). O objetivo destas análises é identificar os fenômenos que envolvem os dados do ambiente controlado a exemplo da avaliação das metodologias de extração de atributos e da aquisição de imagens com inclinação e como as mesmas podem contribuir para a classificação de imagens em um ambiente externo. As imagens adquiridas dos isoladores no ambiente controlado formam a base de dados C1 e as imagens dos isoladores no ambiente externo formam a base de dados C2.

Na primeira parte do trabalho é realizado o projeto e montagem do estúdio fotográfico e é utilizada somente a base de dados C1. Na segunda etapa, é realizado o projeto e montagem da rede de distribuição didática e são utilizadas as bases de dados C1 e C2. A Figura 28 apresenta o fluxograma da sequência de atividades realizadas neste trabalho.



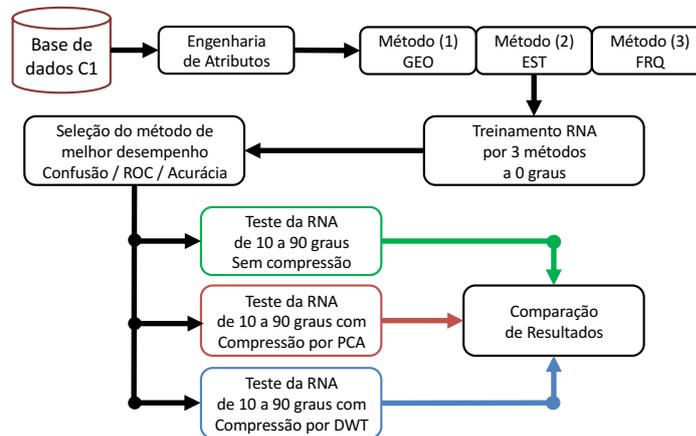
**Figura 28** – Fluxograma das atividades realizadas neste trabalho.

A partir das informações da Figura 28 identifica-se que são aplicadas técnicas de extração de atributos para classificação no ambiente controlado, que, no segundo momento, estas técnicas foram unificadas e assim foi realizada uma mistura gradual de dados entre duas bases de dados no treinamento dos classificadores para melhorar a classificação no ambiente externo.

Parte 1 (Ambiente Controlado -Estúdio Fotográfico - UFBA):

Nesta primeira parte do trabalho, o princípio metodológico consiste da extração de atributos das imagens do ambiente controlado através de 3 métodos distintos que serão deta-

lhados nas sessões posteriores: GEO, EST e FRQ. Estes atributos foram utilizados para treinar classificadores baseados em redes neurais e selecionar o método que apresentou melhor resultado. Por fim foi realizada aplicação técnicas de compressão de dados e foi verificada a influência da inclinação das imagens na classificação dos isoladores. A Figura 29 apresenta o fluxograma da sequência de atividades realizadas nesta etapa do trabalho.

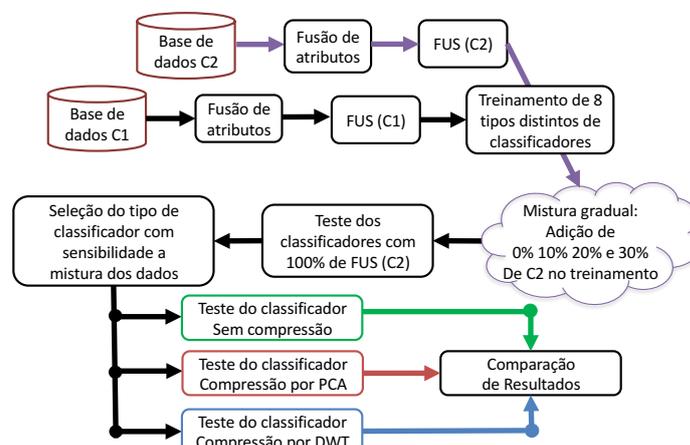


**Figura 29** – Fluxograma das atividades realizadas na parte 1 deste trabalho.

Nesta etapa, os classificadores são treinados com imagens sem inclinação e, após a seleção comparativa entre métodos, são feitos os testes do melhor classificador com imagens com inclinação entre 10 e 90 graus. Por fim, foram aplicadas as técnicas de compressão por WLT e PCA em 5 níveis, comparando-as entre si.

Parte 2 (Ambiente Externo - Rede de Distribuição Didática - UNIVASF):

Nesta segunda parte do trabalho, o princípio metodológico consiste da extração de atributos das imagens do ambiente externo, unificando as técnicas de extração de atributos ao invés de analisar os métodos separadamente. Nesta etapa, foram treinando 8 tipos distintos de classificadores, efetuando uma mistura gradual de dados das imagens de C2 no treino dos classificadores que utilizam dados de C1, com o intuito de verificar a influência da mistura dos dados na classificação dos isoladores do ambiente externo. A Figura 30 apresenta o fluxograma da sequência de atividades realizadas nesta etapa do trabalho.



**Figura 30** – Fluxograma das atividades realizadas na parte 2 deste trabalho.

Com o intuito de melhorar a classificação das imagens externas, foi realizado neste trabalho um processo de mistura gradual de dados entre C1 e C2. Para tal, foram projetados 4 classificadores neurais, utilizando o método FUS. O primeiro foi treinado usando atributos extraídos de C1, e ao restante foi adicionado ao conjunto de treino/teste 10%, 20% e 30% dos primeiros dados de C2.

Na etapa de teste 1, os 4 conjuntos de classificadores foram testados com as imagens de teste de C1, obtendo a saída 1 denominada FUS-C1. Na etapa de teste 2, estes classificadores que foram treinados com os dados de C1, foram testados com as imagens de C2, obtendo a saída 2 denominada FUS-C2.

Estes classificadores foram selecionados sendo 2 baseados em otimização, 2 baseados em busca, 2 baseados em probabilidade e 2 baseados em agrupamento, sendo selecionado o tipo de classificador que apresentou sensibilidade a mistura dos dados. Por fim, todas as etapas do processo foram repetidas em 3 níveis de compressão tanto por WLT quanto por PCA de modo a identificar a influência da compactação na eficiência da classificação.

As etapas apresentadas nos fluxogramas acima (Parte 1 e Parte 2) são detalhadas a seguir.

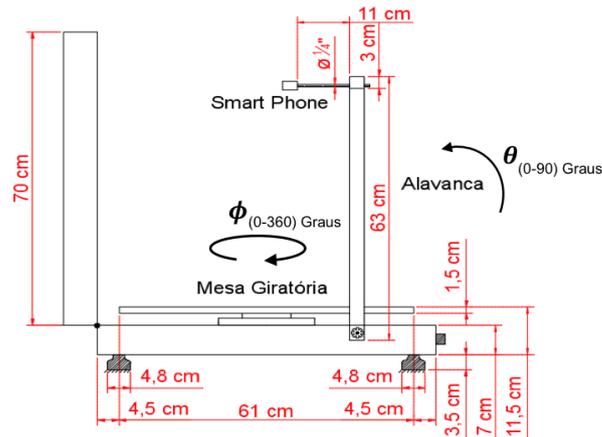
### 3.2.3 Aquisição de Imagens em Laboratório (UFBA)

A fim de atender aos objetivos da pesquisa, foi desenvolvido um estúdio para aquisição de imagens em um ambiente controlado, chamado de SEAI (Sistema Experimental de Aquisição de Imagens). Este estúdio fotográfico tem o formato de uma maleta dobrável a fim de facilitar a sua montagem. Ele foi projetado para ser instalado em cima de uma mesa retangular igualmente dobrável em forma de maleta, De modo a facilitar o transporte dos componentes. Seguindo o mesmo princípio, o sistema complementar de iluminação é igualmente modular e dobrável. A Figura 31 apresenta o sistema.



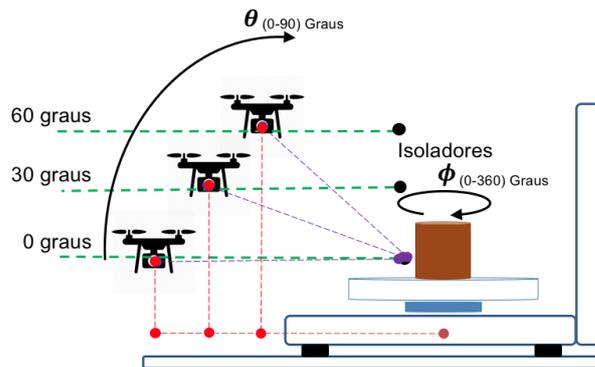
**Figura 31** – Estúdio SEAI (Sistema Experimental de Aquisição de imagens).

Este estúdio foi montado em MDF sendo composto por uma base quadrada dobrável com lateral de 700 mm e pés de apoio. Em cima, foi instalado um disco de giro livre com diâmetro de 610 mm para permitir a aquisição de imagens de um objeto rotacionando-o entre 0 e 360 graus em torno do seu próprio eixo ( $\phi$ ). Na lateral do disco, foi presa uma fita que marca o comprimento da circunferência. Na parte frontal, foi instalado um suporte para fixação ajustável em altura de um *Smartphone* para que fosse possível tirar fotos em ângulos de 0 a 90 graus em relação à vista frontal do objeto ( $\theta$ ), conforme a Figura 32.



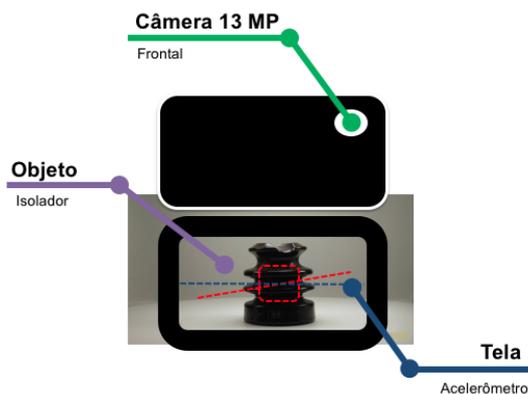
**Figura 32** – Projeto CAD do SEAI: Mesa Giratória e Suporte do *Smart Phone*.

Este sistema tem o objetivo de simular a aquisição de imagem por um drone, supondo que, com a variação de posição, ocorra uma variação da angulação da sua câmera embarcada em relação ao objeto, o que está ilustrado no diagrama da Figura 33.



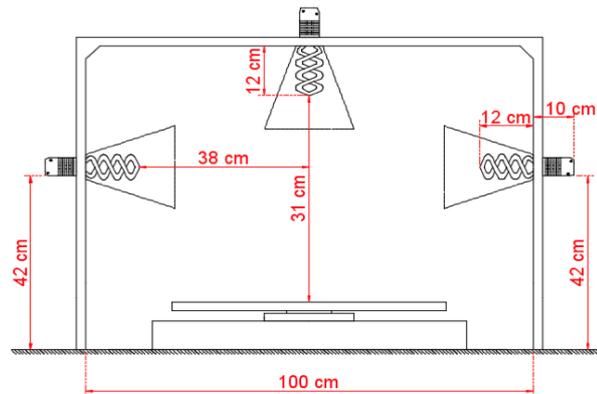
**Figura 33** – Diagrama que ilustra a simulação da movimentação da câmera embarcada em um drone em relação ao objeto de interesse para classificação.

Para a aquisição das imagens em laboratório foi utilizado um *Smart Phone* com câmera frontal, com recursos de ajuste de posição e quadratura com acelerômetro [64], de forma a garantir um alinhamento câmera-objeto. Uma ilustração do equipamento utilizado está apresentado na Figura 34.



**Figura 34** – Diagrama ilustrativo da utilização do SmartPhone e recursos de alinhamento para aquisição de imagens em laboratório.

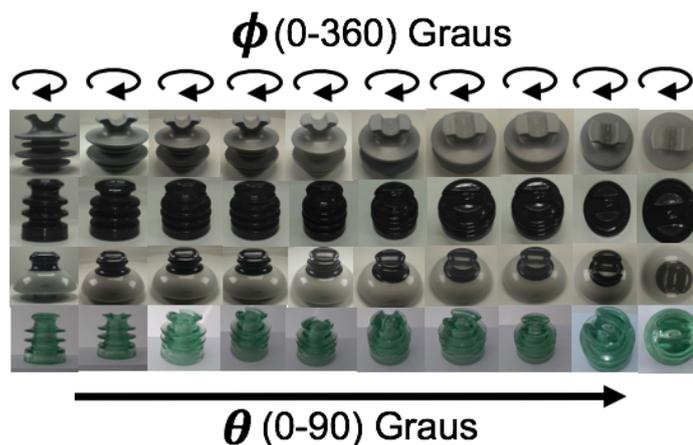
Adicionalmente, foi instalado um sistema de iluminação com 3 lâmpadas de luz corrigida Easy 220v [65] utilizadas em estúdios de fotografia, fixas em difusores de luz, conforme detalhado na Figura 35.



**Figura 35** – SEAI: Sistema de iluminação controlada.

O objetivo do uso da lâmpada corrigida é garantir que no espectro visível, a fonte de luz emita com igual intensidade, diversos comprimentos de onda. Os difusores de luz tem como objetivo evitar que a porção da luz incida com muita concentração no objeto, fazendo com que ocorra excesso de sombra na região imediatamente oposta. O uso das lâmpadas nas três posições, permite reduzir de maneira significativa as projeções de sombra sobre a base da mesa giratória.

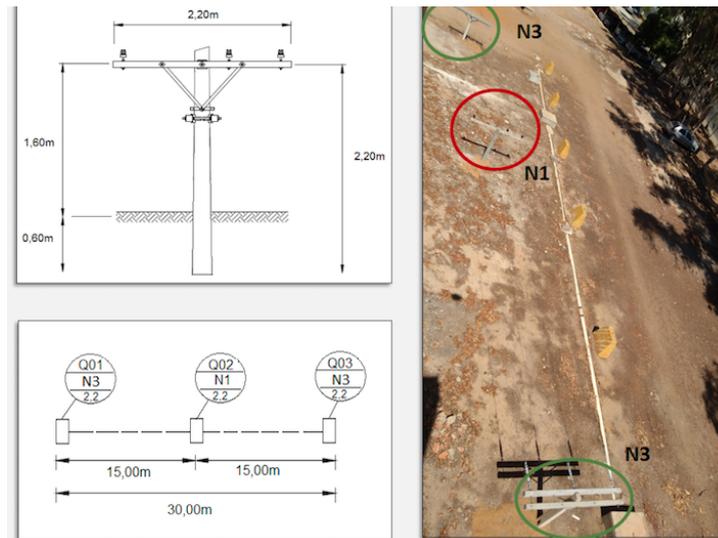
Para cada isolador, em relação a  $\phi$  (para um  $\theta$  fixo), foram adquiridas imagens de 0 a 360 graus. Em relação a  $\theta$  foram adquiridas imagens a cada 10 graus repetindo o procedimento de 0 a 90 graus. A Figura 36 apresenta amostras das imagens coletadas em laboratório para formação da base de dados de imagens.



**Figura 36** – Amostra das imagens brutas com inclinação  $\theta$  de 0 a 90 graus da esquerda para a direita.

### 3.2.4 Aquisição de Imagens em uma Rede de Distribuição didática (UNIVASF)

A RDD (Rede de Distribuição Didática) projetada pelo Professor Msc. Ricardo Prates e instalada na UNIVASF [66], tem como objetivo reproduzir uma rede de distribuição realista em um ambiente externo, incluindo acessórios de instalação. A Figura 37 apresenta o sistema montado.



**Figura 37** – Rede de Distribuição didática instalada na UNIVASF.

O sistema é composto de 3 postes com altura de 1,5 metros para facilitar a instalação dos isoladores e acessórios de fixação, bem como a aquisição das imagens. Os postes foram instalados a uma distância de 15 metros entre si. O sistema de ancoragem foi configurado supondo a instalação de 3 isoladores por poste. Assim, foram montados 3 cabos de força para proporcionar a passagem de um circuito trifásico e os isoladores foram fixos ao cabo através de um aramado.

As imagens dos isoladores instalados na Rede de Distribuição didática a serem futuramente utilizadas ao longo da pesquisa, foram adquiridas com diferentes valores de  $\phi$  e de  $\theta$ . A Figura 38 apresenta amostras das imagens coletadas em campo para formação da base de dados de imagens.



**Figura 38** – Amostra das imagens brutas dos isoladores instalados em ambiente externo.

Para cada isolador, foram adquiridas imagens em condições diversas de posição, iluminação e conseqüentemente, variações de fundo.

### 3.2.5 Construção das bases de dados C1 e C2

Para a aquisição das imagens foi utilizado um *Smart Phone* com câmera de 13 MP, 256 PPI. Para o ambiente controlado foi adotado o formato 16:9 (10 MP, 4096x2304). Já no ambiente externo foi utilizada a configuração 1:1 dimensões 1024x1078.

Para cada isolador, no ambiente controlado, em relação a  $\phi$  (para um  $\theta$  fixo), foram adquiridas 194 imagens (espaçamento de 1,85 graus). Em relação a  $\theta$  foram adquiridas imagens a cada 10 graus (de 0 a 90 graus) repetindo o procedimento  $\phi$  totalizando 1940 imagens por isolador. Por fim, as imagens foram recortadas manualmente e redimensionadas para o formato 1:1 e dimensões 1500 x 1500 pixels.

No caso do ambiente externo, foram adquiridas 500 imagens com posições de  $\phi$  entre 0 e 360 e valores de  $\theta$  entre 0 a 90 graus, repetindo o procedimento para as demais classes. Por fim, as imagens foram recortadas manualmente e redimensionadas para o formato 1:1 e dimensões 700 x 700 pixels.

Para a construção da base de dados C1 correspondente ao ambiente controlado, foram selecionados 4 tipos de isoladores. Assim, das imagens adquiridas através do estúdio, foram selecionadas 40 imagens a cada variação de  $\theta$ , totalizando 400 amostras para cada classe. Para a construção de C2 foram instalados os mesmos 4 tipos de isoladores na RDD e adquiridas 400 imagens de cada um deles para diferentes valores de  $\phi$  e  $\theta$ . Por fim, todas as imagens foram redimensionadas para o formato 1:1 e dimensões 224 x 224 pixels.

A Figura 39 apresenta um diagrama com as etapas de aquisição, recorte, seleção e redimensionamento das imagens obtidas no estúdio fotográfico e coletadas na RDD em campo para formação das bases de dados C1 e C2.

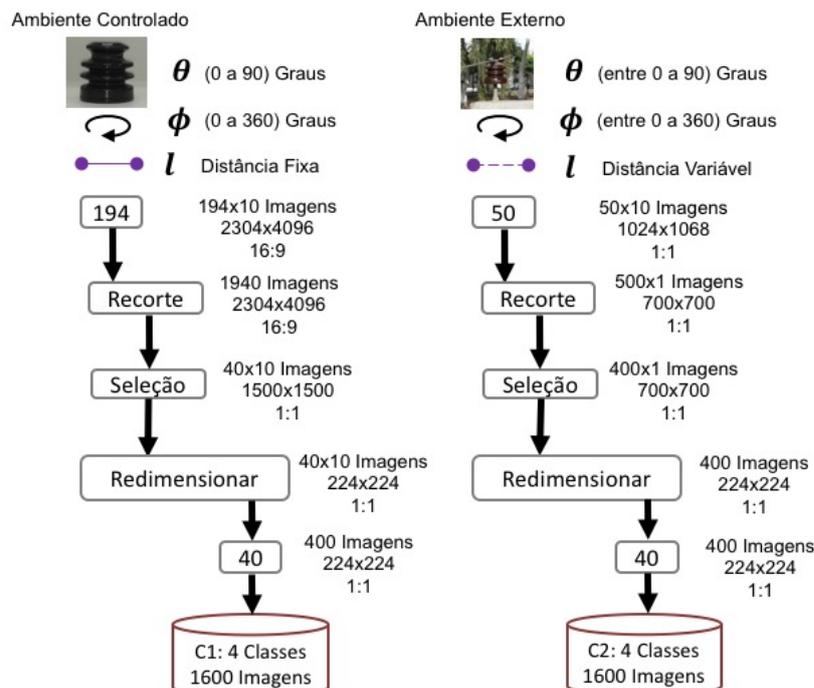
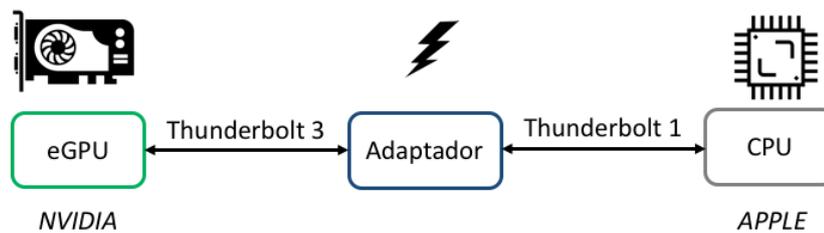


Figura 39 – Diagrama ilustrativo da metodologia adotada para a construção das bases de dados C1 e C2.

O recorte das imagens dos isoladores permite simular uma condição de um algoritmo de detecção em uma futura aplicação de visão computacional de tempo real. O redimensionamento padronizado das imagens dos dois grupos foi o critério adotado para que as técnicas de extração de atributos operem sobre as mesmas condições de dimensão nas duas bases de dados.

### 3.2.6 Plataforma Computacional utilizada para Processamento de Imagens

O sistema montado para o processamento e extração de atributos de imagens, tem como base uma Unidade Central de Processamento - CPU e uma Unidade de Processamento Gráfico - GPU. Neste trabalho foi utilizado um notebook da *Apple* [67] e uma GPU da *NVIDIA* [68] na modalidade eGPU (Unidade de Processamento Gráfico Externa). Para que isto ocorra, é necessário a aquisição de uma *Dock Station* que efetue a conversão do barramento PCI para o barramento de comunicação externo [69]. A comunicação com o acelerador gráfico externo ocorre através do protocolo Thunderbolt 3 [70], sendo necessário a utilização de um adaptador de protocolo bidirecional para o protocolo Thunderbolt 1 [71]. O modelo do sistema proposto está apresentado na Figura 40.



**Figura 40** – Modelo de sistema computacional proposto para processamento de imagens.

Esta arquitetura, permite que o processamento da imagem, utilize tanto os recursos da CPU quanto os recursos da eGPU, conforme a declaração nas linhas de código. O conjunto de equipamentos utilizado neste trabalho para o processamento de imagens descrito no modelo proposto, foi montado e está apresentado na Figura 41.



**Figura 41** – Imagem do sistema utilizado neste trabalho para processamento e reconhecimento de padrões em imagens.

As especificações do conjunto de hardware e software para processamento das imagens utilizado no presente trabalho, estão descritos na Tabela 2:

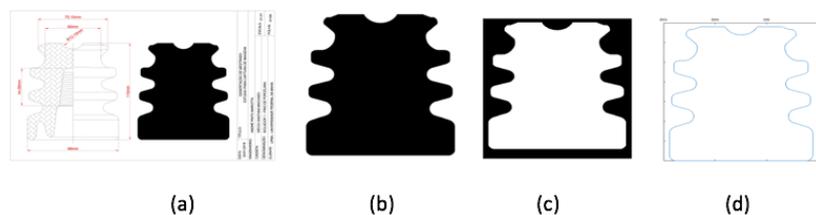
**Tabela 2** – Especificação de Hardware e Software utilizados para o processamento das imagens.

Hardware	
CPU	MacBook Pro (130-inch, Mid 2012); Processador 2,5GHz Intel Core i5; Memória 8 GB 1600 MHz DDR3; Gráfico On Board Intel HD Graphics 4000 1536 MB; Barramento Thunderbolt 1 10GBPS.
Dock Station	AKiTiO Node Thunderbolt 3 eGFX expansion chassis.
Adaptador	APPLE Thunderbolt 3 (USB-C) to Thunderbolt 2 Adapter (20GB/s / 10GB/s).
Cabo	APPLE Thunderbolt 1 cable
eGPU	Nvidia GForce Titan X; Arquitetura Maxwell; ChipSet GM2000 / 28nm; CUDA / Stream 3072; Clock Base/Max 1000/1075 MHz; Memória 12GB GDDR5 / 384 Bits; Clock de Memória 7GHz; TDP 250W.
Software	
Programação	Matlab R2017a (Licença Acadêmica);
SO	MacOS High Sierra 10.13.4;
Drivers	NVIDIA WEB Driver 387.10.10.10.35.106; NVIDIA CUDA Driver 396.148; Purge-wrangler.sh (gitHub script).

### 3.3 Técnicas de Processamento de Imagem Utilizadas

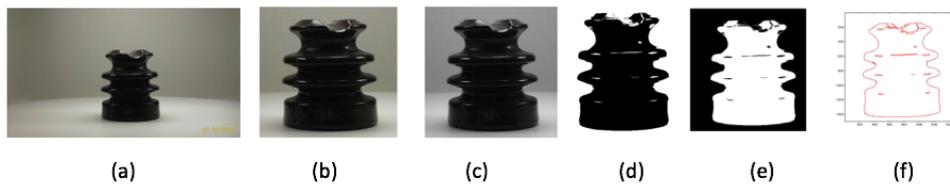
As técnicas de processamento de imagens foram utilizadas em cada tipo de imagem do objeto de estudo deste trabalho: imagens de referência, imagens obtidas em laboratório e imagens obtidas em ambiente real.

No caso das imagens de referência, construídas a partir das medidas aproximadas dos isoladores, foram aplicadas as técnicas de recorte, redimensionamento, inversão e contorno. A Figura 42 apresenta as técnicas de processamento utilizadas neste tipo de imagem.



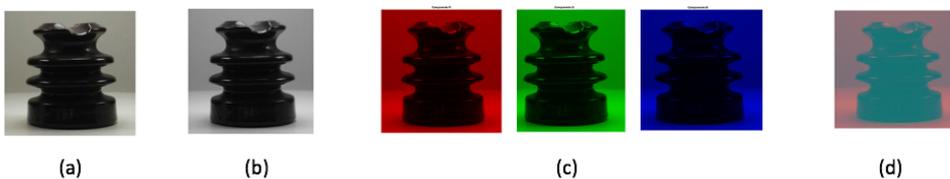
**Figura 42** – Processamento de imagens de referência. (a) *Datasheet* (b) Recorte e redimensionamento da forma (c) Inversão (d) Contorno da forma.

No caso das imagens de laboratório, obtidas a partir das fotos dos isoladores adquiridas utilizando o sistema SEAI, foram aplicadas as técnicas de recorte, redimensionamento, transformação, inversão e contorno. A Figura 43 apresenta as técnicas de processamento utilizadas neste tipo de imagem.



**Figura 43** – Processamento de imagens em laboratório. (a) foto (b) recorte e redimensionamento (c) Escala de cinza (d) Binarização (e) Inversão (f) Contorno.

Na Figura 44 está apresentado o efeito da aplicação das técnicas de transformação das imagens recortadas do padrão de cores RGB para o espaço de cores YCbCr e para escala de cinza.

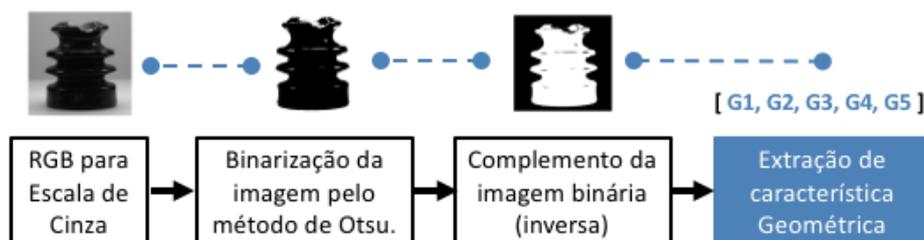


**Figura 44** – Técnicas de transformação de imagens utilizadas (a) Imagem colorida. (b) Transformação para escala de cinza (c) Decomposição RGB (d) Transformação de RGB para YCbCr.

## 3.4 Técnicas de Extração de Atributos Utilizadas

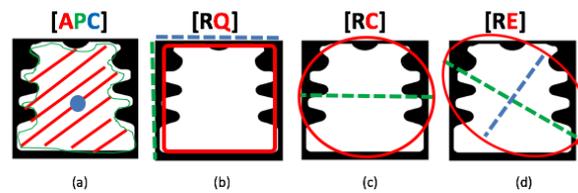
### 3.4.1 Método Geométrico [GEO]

Este conjunto de técnicas consiste em, através da obtenção da forma do objeto de interesse dentro da imagem, adquirir informações relativas às proporções geométricas do objeto, como a lateral maior, a lateral menor, a aproximação de perímetro, comparação com área equivalente de elipses e círculos [44]-[45], e transformá-las em um vetor de atributos unidimensionais. Para os atributos GEO, com a imagem binarizada dos isoladores, foram estimados os 5 parâmetros descritos no capítulo anterior nomeando-os como G1, G2, G3, G4 e G5. A Figura 45 ilustra o método em diagrama de blocos.



**Figura 45** – Diagrama do método geométrico utilizado.

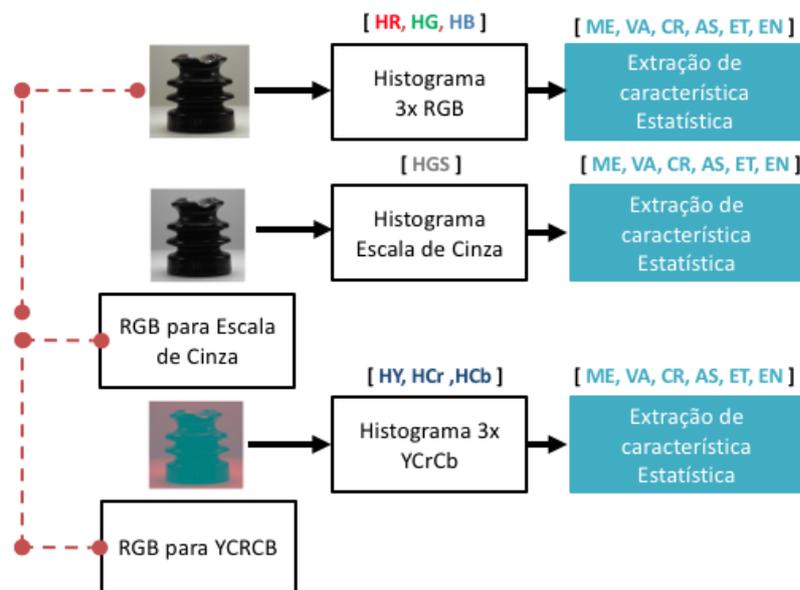
A Figura 46 apresenta o diagrama ilustrativo da extração de escalares geométricos das imagens de referência dos isoladores:



**Figura 46** – Diagrama ilustrativo da extração de escalares geométricos obtidos das imagens de referência dos isoladores. (a) [APC] Área, perímetro e centróide. (b) [RQ] Relações com retângulo (c) Relações com círculo (d) relações com elipse.

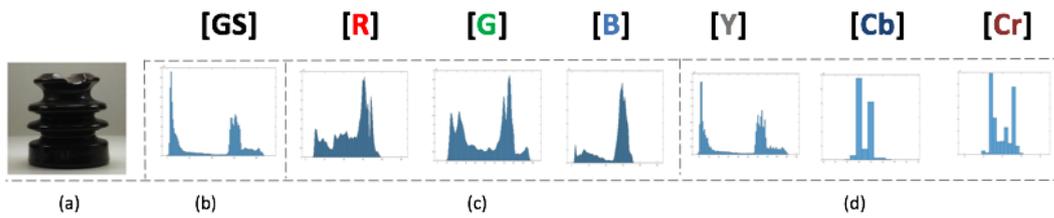
### 3.4.2 Método Estatístico [EST]

O método estatístico utilizado consiste na extração de histogramas sendo 1 em escala de cinza [GS], 3 no padrão de imagem colorida [RGB] e 3 no padrão de imagem digital [YCbCr], com o respectivo cálculo dos momentos estatísticos de cada um: média [ME], variância [VA], curtose [CR], assimetria [AS], entropia [ET] e energia [EN], definidos no capítulo anterior, a fim de formar conjuntos de vetores de atributos unidimensionais [44]-[45]. Este método extrai características da imagem inteira. A Figura 47 resume o método proposto:



**Figura 47** – Diagrama do método estatístico utilizado.

A Figura 48 apresenta um diagrama ilustrativo dos histogramas extraídos das imagens das amostras dos isoladores.

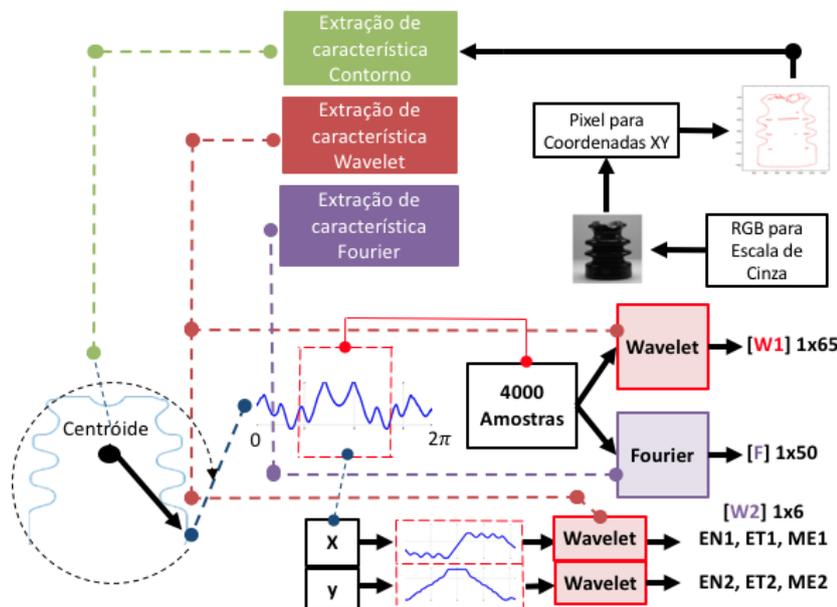


**Figura 48** – Diagrama ilustrativo da extração de histogramas das imagens dos isoladores. (a) Imagens coloridas dos isoladores (b) [GS] Histogramas de escala de cinza das imagens (c) [R][G][B] - Histogramas RGB da imagens (d) [Y][Cb][Cr] - Histogramas YCbCr das imagens.

Para cada um dos 7 histogramas descritos, foi realizado o cálculo dos momentos estatísticos, entropia e energia apresentados nas equações (2.6) a (2.12).

### 3.4.3 Atributos no Domínio da Frequência [FRQ]

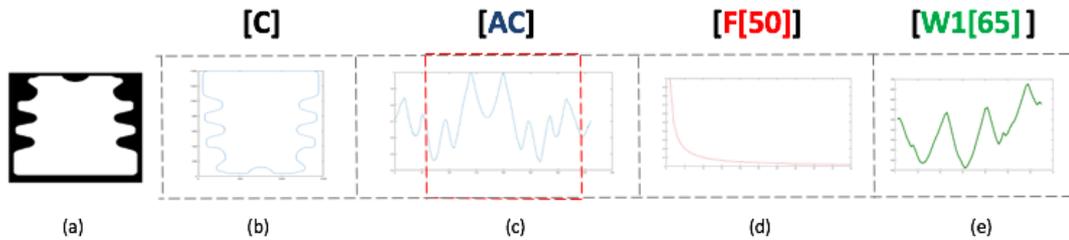
A terceira abordagem utilizada para extração de atributos consiste, primeiro, na obtenção da assinatura de contorno do objeto [44] e, segundo, em obter as coordenadas espaciais do contorno do objeto no plano  $XY$ , a fim de formar sinais que possam ser processados no domínio da frequência [45]. Este método combina o uso das Transformadas de Fourier e Wavelet com o cálculo de momentos estatísticos descritos nas equações (2.16) a (2.19). Em termos gráficos, as técnicas de extração de contornos e desenho dos sinais e a decomposição de Fourier e Wavelet do objeto são ilustrados na Figura 49.



**Figura 49** – Diagrama do Método para extração de atributos no domínio da frequência.

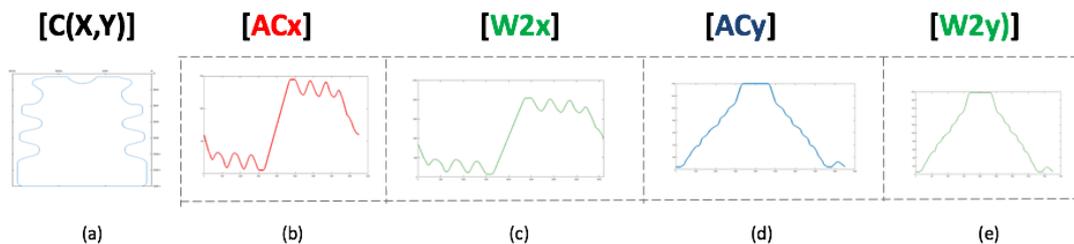
Obtidos os contornos, foi realizado um recorte padronizado dos mesmos entre as amostras na faixa de 1000 a 5000. Este procedimento foi efetuado a fim de eliminar o ruído produzido pelos algoritmos de contorno nas extremidades do sinal [72]. Após este processo, utilizou-se a decomposição de Fourier no sinal recortado, gerando o conjunto de atributos.

Para o restante do processamento, foi utilizada a transformada discreta *Wavelet*, usando a função *Daubechies*, sendo calculada de duas formas distintas: uma [DW1] db4, decomposição 6, utilizando a assinatura e outra [DW2] e db2, decomposição 1 em cada componente  $X$  e  $Y$  de coordenadas extraídas do contorno do objeto [44], [45], [72]. A Figura 50 ilustra o procedimento adotado para extração dos descritores unidimensionais para as imagens das amostras dos isoladores.



**Figura 50** – Diagrama ilustrativo de extração de atributos no domínio da frequência (a) imagens de referência dos isoladores (b) Contorno (c) [AC] Assinatura de contorno recortadas (d) [F(50)] Decomposição de Fourier dos sinais (e) [W1] Decomposição Wavelet dos sinais.

A Figura 51 apresenta um diagrama ilustrativo dos contornos parciais em relação a  $x$  e a  $y$  e seus respectivos sinais de decomposição *Wavelet*.



**Figura 51** – Diagrama ilustrativo da decomposição Wavelet para os contornos parciais das imagens de referência dos isoladores: (a) [C(x,y)] Contorno em relação ao plano  $XY$ . (b) [ACx] Assinatura de contorno parcial em relação a  $x$ . (c) [W2x] Decomposição Wavelet do sinal  $x$ . (d) [ACy] Assinatura de contorno parcial em relação a  $y$ . (e) [W2y] Decomposição Wavelet do sinal  $y$ .

### 3.5 Atributos extraídos

Ao fim da implementação dos 3 métodos descritos, os atributos extraídos para cada imagem seguem resumidos abaixo:

- **Atributos Geométricos;**
  - GEO (1x5) = [ G1, G2, G3, G4, G5].
- **Atributos Estatísticos;**
  - EST (1x1827) = [1xGS (1:255), 3xRGB(1:255), 3xYCRGB(1:255), ME(1:7), VA(1:7), AS(1:7), CT(1:7), EN(1:7), ET(1:7)].
- **Atributos no Domínio da Frequência;**
  - FRQ(1x121) = [DW-1(1:65), DF(1:50), DW-2(EN1, ET1, ME1, EN2, ET2, ME2)].

## 3.6 Técnicas de treino, teste e classificação Utilizadas

### 3.6.1 Parte 1: Influência da Inclinação

Na primeira parte do trabalho, para o estudo da influência da variação da imagem na classificação dos isoladores utilizando C1, foram realizados dois processos. Primeiro, foram projetados 3 classificadores neurais, um para cada método citado (GEO, EST e FRQ). Estes classificadores foram treinados usando atributos extraídos das 970 imagens (194 para cada um dos 4 isoladores) com  $\theta$  a 0 graus, a fim de selecionar o método que apresentasse o melhor resultado. A seguir, imagens com inclinação  $\theta$  variando entre 10 e 90 graus foram utilizadas para teste dos classificadores do método selecionado.

### 3.6.2 Parte 2: Influência da Mistura dos Dados de C2 no treino de C1

Na segunda parte do trabalho, foi realizado um processo de mistura gradual de dados entre C1 e C2. Para tal, foram projetados 4 classificadores neurais, utilizando o método FUS. O primeiro foi treinado usando atributos extraídos de C1, e ao restante foi adicionado ao conjunto de treino/teste 10%, 20% e 30% dos primeiros dados de C2.

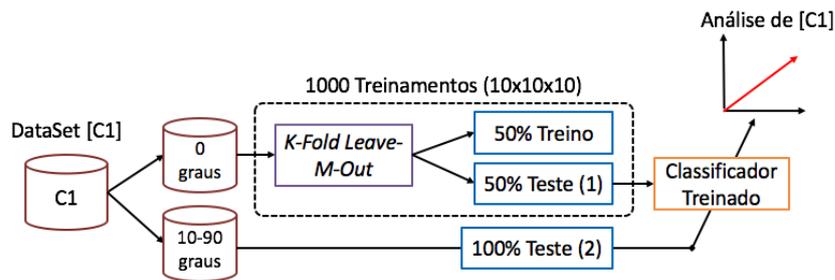
Na etapa de teste 1, os 4 conjuntos de classificadores foram testados com as imagens de teste de C1, obtendo a saída 1 denominada FUS-C1. Na etapa de teste 2, os mesmos classificadores treinados com C1, foram testados com as imagens de C2, obtendo a saída 2 denominada FUS-C2.

Por fim, utilizando os testes (FUS-C1) e (FUS-C2), foi realizado o treino e teste de 8 tipos de classificadores, a fim de selecionar o tipo de classificador que apresentasse sensibilidade à mistura dos dados.

### 3.6.3 Validação Cruzada

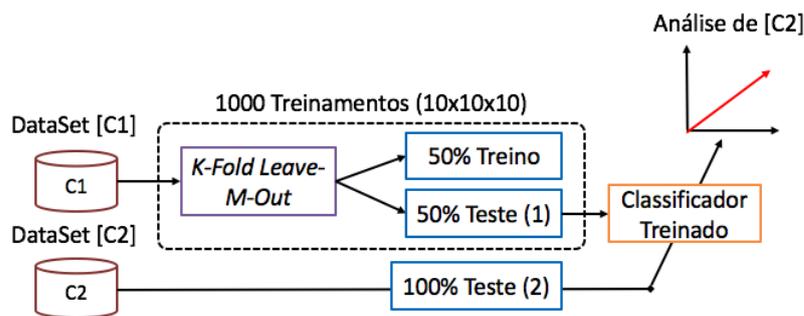
Todos os classificadores utilizados foram implementados utilizando 50% das amostras para treino e 50% para teste. O procedimento de validação cruzada *leave-M-out* foi adotado para efetuar 100 treinamentos, com um novo sorteio de dados de treino e teste a cada 10 rodadas de treinamento. Para cada classificador, foi selecionado um parâmetro que foi testado 10 vezes, totalizando 1000 treinamentos para cada cadeia de treino e cada tipo de classificador.

Na primeira parte do trabalho, a base de dados C1 foi dividida em função dos ângulos de inclinação das imagens. A Figura 52 apresenta um diagrama ilustrativo de como foi realizada a separação e o sorteio dos dados.



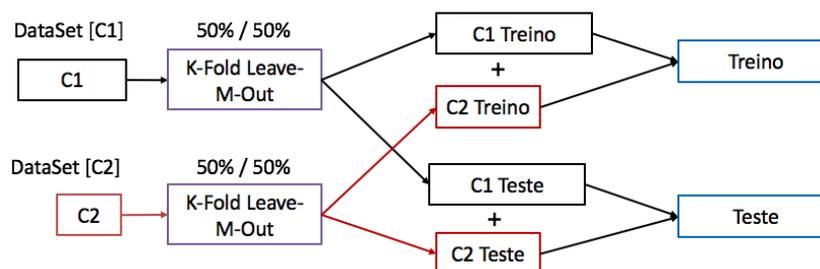
**Figura 52** – Diagrama ilustrativo do procedimento de validação cruzada de dados, a partir da separação da base de dados C1 em duas bases de dados em função da inclinação das imagens.

Na segunda etapa do trabalho, inicialmente a base de dados C2 foi utilizada para testar os classificadores que foram treinados com a base de dados C1, como apresentado na Figura 53.



**Figura 53** – Diagrama ilustrativo do procedimento de validação cruzada dupla de dados, a partir do uso da base de dados C2 para testar os classificadores treinados com a base de dados C1..

Posteriormente, foi necessário garantir que o acréscimo gradual de dados de C2 no conjunto de treinamento, estivesse proporcionalmente presente tanto no conjunto de testes quanto no conjunto de treino. Para tal foi realizado um método de validação cruzada dupla em paralelo apresentado na Figura 54.



**Figura 54** – Diagrama ilustrativo do procedimento de validação cruzada dupla de dados em paralelo, de forma a garantir a mesma quantidade de dados adicionados no grupo de treino e no grupo de teste.

### 3.6.4 Classificadores

Os classificadores baseados em Redes Neurais são do tipo Perceptron multi-camadas, com única camada oculta e treinamento pelo método do gradiente descendente conjugado, com minimização do erro quadrático médio e função de ativação Sigmoidal tanto na camada oculta quanto na camada de saída [48]. A Tabela 3 apresenta os parâmetros dos classificadores treinados.

**Tabela 3** – Tabela de parâmetros do Classificador tipo Rede Neural Artificial.

Configuração	Setup
Máquina	Rede Neural MLP
Treinamento	Back Propagation
Algoritmo	Gradiente descendente Conjugado
Performance	Mínimo erro quadrático Médio
Critério de Parada	Épocas: 800 / Erro: $10^{-7}$
Validação	Validação Cruzada e Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 10 a 100 neurônios na camada oculta

Os classificadores baseados em SVM são do tipo ECOC (*Error-Correct Output Codes*) um tipo de máquina de vetor de suporte para o caso de múltiplas classes [48] usando a função de base radial como núcleo. A Tabela 4 apresenta os parâmetros dos classificadores treinados.

**Tabela 4** – Tabela de parâmetros do Classificador tipo Máquina de Vetor de Suporte.

Configuração	Setup
Máquina	SVM - Máquina de Vetor de Suporte
Treinamento	ECOC - <i>Error Correcting Output Codes</i>
Núcleo	RBF - Função de Base Radial
Performance	–
Critério de Parada	–
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 1 a 10 cadeias de treinamento

Os classificadores baseados em probabilidade bayesiana, com variação da probabilidade das ocorrências das classes (índice de prioridade) em 10 grupos para 10 cadeias de treinamento de 100 classificadores [46]. A Tabela 5 apresenta os parâmetros dos classificadores treinados.

**Tabela 5** – Tabela de parâmetros do Classificador tipo Bayesiano.

Configuração	Setup
Máquina	Naive Baiyes
Treinamento	Probabilidade
Núcleo	–
Performance	–
Critério de Parada	–
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 1 a 10 o índice <i>prior</i>

Os classificadores com base na cadeia oculta de Markov, utilizam a cadeia de Markov com 32 níveis de símbolos de observação, 5 estados ocultos, variando de 10 a 100 o número de interações [46]. A Tabela 6 apresenta os parâmetros dos classificadores treinados.

**Tabela 6** – Tabela de parâmetros do Classificador tipo Cadeia Oculta de Markov.

Configuração	Setup
Máquina	HMM - Modelo Oculto de Markov
Treinamento	Transição de estados
Núcleo	Quantização em 32 Níveis
Performance	–
Critério de Parada	Número de Interações
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 1 a 10 o Número de Interações.

Os classificadores baseados em busca, tipo árvore de decisão, utilizaram a variação do número de folhas de 10 a 100 [46]. A Tabela 7 apresenta os parâmetros dos classificadores treinados.

**Tabela 7** – Tabela de parâmetros do Classificador tipo Árvore de Decisão.

Configuração	Setup
Máquina	DTREE - Árvore de Decisão
Treinamento	Algoritmo de Busca
Núcleo	–
Performance	–
Critério de Parada	–
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 10 a 100 a quantidade mínima de <i>Leafs</i> .

Os classificadores baseados em busca, do tipo árvore aleatória utilizaram a variação do número de folhas de 10 a 100 fixando o número de bolsas em 50 [46]. A Tabela 8 apresenta os parâmetros dos classificadores treinados.

**Tabela 8** – Tabela de parâmetros do Classificador tipo Floresta Aleatória.

Configuração	Setup
Máquina	RFST - Árvore Aleatória
Treinamento	Algoritmo de Busca
Núcleo	50 Bags
Performance	–
Critério de Parada	–
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 10 a 100 a quantidade mínima de <i>Leafs</i>

Os classificadores baseados em distâncias, tipo K-vizinhos mais próximos, utilizaram a distância euclidiana como padrão, variando o número de vizinhos de 10 a 100 para treinamento de 10 grupos de 100 classificadores [46]. A Tabela 9 apresenta os parâmetros dos classificadores treinados.

**Tabela 9** – Tabela de parâmetros do Classificador tipo K-Vizinhos Próximos.

Configuração	Setup
Máquina	K-Vizinhos Próximos
Treinamento	Distância Euclidiana
Núcleo	–
Performance	–
Critério de Parada	–
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, de 10 a 100 o número de vizinhos próximos.

Os classificadores baseados em distâncias tipo, 1-NN, 1 vizinho mais próximo, utilizaram 10 tipos diferentes de distâncias, mantendo a medição de 1 vizinho mais próximo, para treinamento de 10 grupos de 100 classificadores [46]. A Tabela 10 apresenta os parâmetros dos classificadores treinados.

**Tabela 10** – Tabela de parâmetros do Classificador tipo 1-Vizinho Próximos.

Configuração	Setup
Máquina	1-Vizinhos Próximos
Treinamento	Distâncias
Núcleo (Distâncias)	1. Cityblock; 2. Chebychev; 3. Correlation; 4. Cosine; 5. Euclidean; 6.Hamming; 7. jaccard; 8. Mincowski; 9. Seuclidean; 10. Spearman.
Performance	–
Critério de Parada	–
Validação	Validação Cruzada dupla em paralelo
Método	<i>K-fold / Leave-M-Out</i>
Treino / teste / validação	50 / 50 / 0
Figura de Mérito	AC (Acurácia)
Índice / Repetições	100 vezes, mantendo 1 vizinho próximo e variando o tipo da distância.

### 3.7 Métodos de avaliação de desempenho Utilizados

Os parâmetros utilizados para avaliar o desempenho de classificação foram a área sob a curva ROC, a matriz de confusão e a Acurácia [48]. A curva ROC é um gráfico que representa a relação entre a taxa de falsos positivos (TFP) e a taxa de falsos negativos (TVP) nos eixos  $X$  e  $Y$  respectivamente. A eficiência do classificador pode ser medida a partir da área sob a curva ROC.

A matriz de confusão é uma tabela utilizada para verificar com mais detalhes o desempenho de um classificador. Cada coluna da matriz representa as classes previstas enquanto as linhas representam as classes reais. Permite verificar com mais detalhes se o classificador está confundindo as classes. A diagonal principal da matriz, representa o percentual de acerto que o classificador obteve para cada isolador. Este acerto individual, pode ser definido como eficiência de detecção ( $ED_n$ ) de cada classe.

A Acurácia ( $A_{cu}$ ) é um coeficiente utilizado neste trabalho para avaliar a dispersão dos resultados de classificação para cada um dos métodos de extração de atributos [46], permitindo selecionar os classificadores que apresentaram o melhor resultado. Todos estes métodos são comumente empregados em trabalhos da área de aprendizagem de máquina, tais como problemas de classificação na área de física de altas energias [73].

A máquina de vetor de suporte é um classificador que foi utilizado neste trabalho no modo binário para, através do mapeamento das saídas de teste dos classificadores treinados, verificar graficamente o comportamento e a dificuldade do classificador em distinguir uma classe das demais classes, nos casos em que o classificador é treinado e testado com as imagens tanto do ambiente controlado, quanto do externo e o comportamento do classificador após a mistura de dados.

### 3.8 Técnicas de compressão da informação utilizadas

As técnicas de compactação utilizadas neste trabalho são a Análise de Componentes Principais (PCA) e a transformada discreta de Wavelet (DWT). No caso da PCA, o objetivo é reduzir a dimensionalidade dos sinais [48], identificando a melhor condição de preservação de energia que mantenha as curvas de erro com um comportamento similar ao do sinal original. Foram selecionados três fatores de compressão e para cada um deles foram treinadas novamente os classificadores, selecionando as mesmas quantidade e índices definidos anteriormente.

No caso da DWT, o objetivo é a simplificação o tamanho da amostra do sinal da assinatura de contorno da imagem, através do processamento com decomposição do sinal utilizando famílias de *wavelets* empregadas na literatura [74]. Também sendo utilizado com o objetivo de verificar a menor quantidade de informação que mantém as curvas de erro com um perfil similar ao do sinal original. Foram selecionados três níveis de decomposição e treinados classificadores para cada um deles, selecionando o classificador com melhor índice, anteriormente definido. Estas técnicas podem ser empregadas, por exemplo, em aplicações com processamento de imagem [58] e aplicação de extração de atributos para detecção de falhas em equipamentos [75].

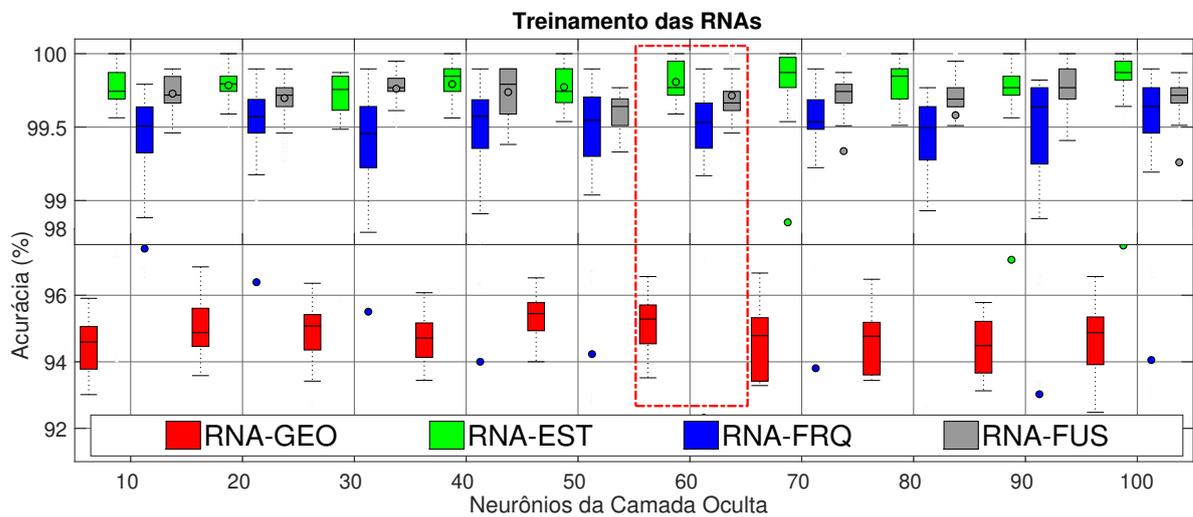
## 4 Resultados

Neste capítulo são mostrados os resultados relacionados a investigação dos dados do ambiente controlado.

### 4.1 Ambiente Controlado

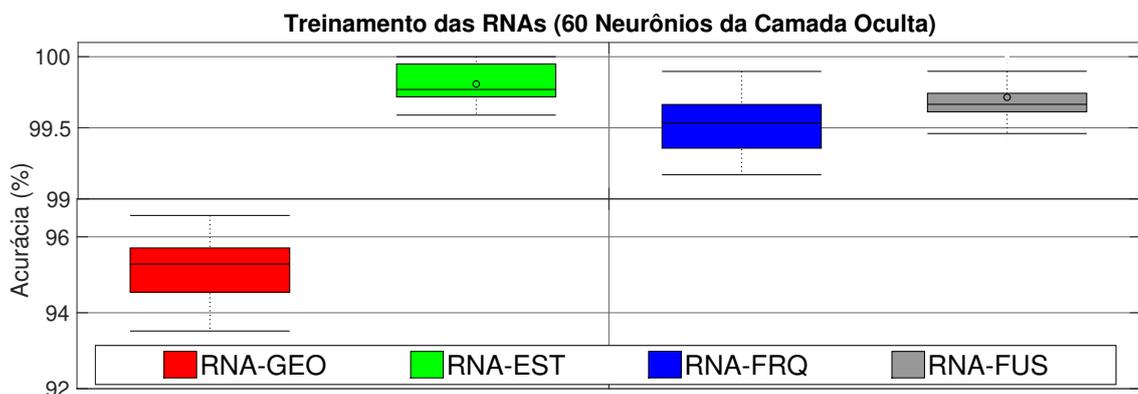
#### 4.1.1 Classificação para o caso sem inclinação: ( $\theta = 0^\circ$ )

Para a primeira etapa (sem inclinação) os resultados da avaliação da Acurácia para cada um dos quatro métodos estão apresentados na Figura 55, considerando 1000 treinamentos para cada método.



**Figura 55** – Resultado dos treinamentos das RNAs em  $\theta = 0^\circ$  .

Com estes resultados, foi verificado que o método EST apresentou na maioria dos casos, comparando com os outros dois métodos (GEO e FRQ) os maiores valores de acurácia e menor dispersão nos resultados, sendo selecionada a Rede Neural com 60 neurônios na camada oculta destacados na Figura 56.



**Figura 56** – Resultado dos treinamentos das RNAs em  $\theta = 0^\circ$  com 60 Neurônios na camada oculta.

Após a seleção do conjunto de Redes Neurais com 60 neurônios na camada oculta, foi realizada a análise da relação entre as probabilidades de detecção e de falso alarme, representadas pela curva ROC. A Figura 57 apresenta as curvas ROC do melhor resultado dentre os 100 treinamentos realizados com 60 neurônios, para cada método deste respectivo grupo de RNAs.

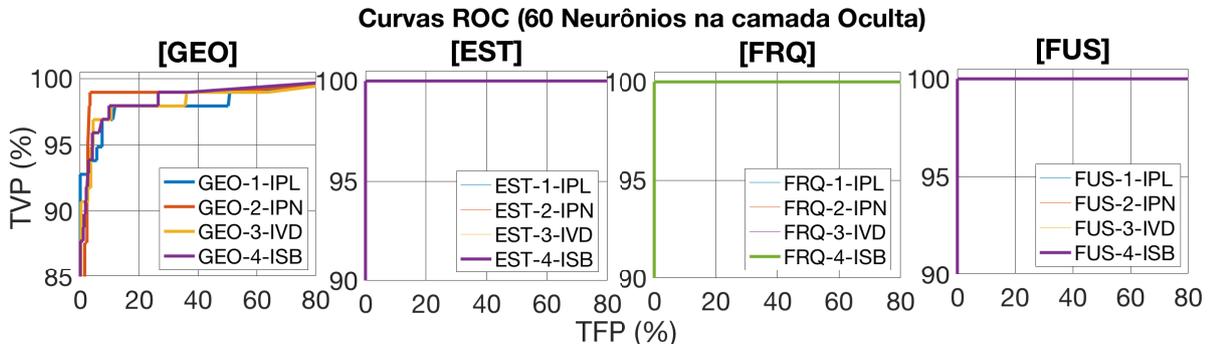


Figura 57 – Curvas ROC do melhor resultado com 60 neurônios na camada oculta em  $\theta = 0^\circ$ .

Por fim, foram construídas as matrizes de confusão destes melhores resultados descritos, considerando as 4 classes de isoladores, a fim de verificar o quanto os classificadores confundem uma classe por outra. A matriz de confusão destas redes treinadas com 60 neurônios na camada oculta estão apresentadas na Tabela 11.

Tabela 11 – Resultados: GEO x EST x FRQ x FUS com 60 Neurônios na camada oculta.

		GEO					EST					FRQ					FUS					
		Classe Real					Classe Real					Classe Real					Classe Real					
Classe Predita	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB		
	IPL	94	1	4	2	100	0	0	0	0	100	0	0	0	0	100	0	0	0	0	0	
	IPN	0	94	5	1	0	100	0	0	0	0	100	0	0	0	0	99	0	1	0	0	
	IVD	0	3	96	1	0	0	0	100	0	1	0	99	0	0	0	0	0	100	0	0	0
	ISB	2	4	4	90	0	0	0	0	100	0	0	0	0	100	0	0	0	0	100	0	0

#### 4.1.2 Inclinação Variável: ( $0^\circ < \theta < 90^\circ$ )

Para a segunda etapa (com inclinação), foram testadas as RNAs que haviam sido treinadas através do método EST, com o restante das imagens entre 10 e 90 graus. A Figura 58 Apresenta o resultado destes testes.

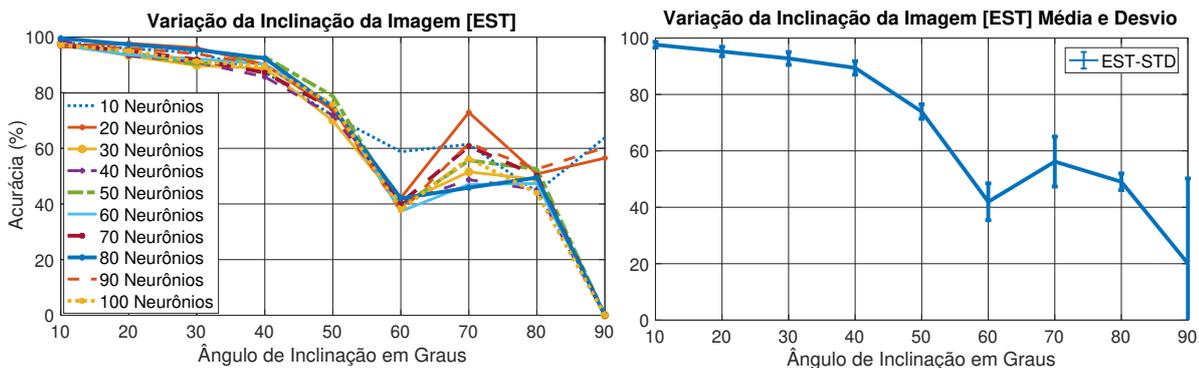


Figura 58 – Resultados dos testes das RNAs considerando a variação da inclinação  $\theta$  de 10 a 90 graus da esquerda para a direita.

A partir dos resultados apresentados na Figura 58, verificou-se a dificuldade para classificar o isolador em função de sua inclinação. Foi realizado um teste com 10 a 100 neurônios na camada oculta e foram obtidos média e desvio padrão destes dados. Estes resultados indicam que o classificador treinado com imagens sem inclinação foi capaz de reconhecer isoladores em uma estreita faixa com angulação entre 0 e 40 graus.

A seguir foram realizados estudos para verificar, dentre os atributos, a mínima informação necessária para classificação. Para tal, foram utilizadas compressões por Wavelet e por PCA (Análise de Componentes Principais).

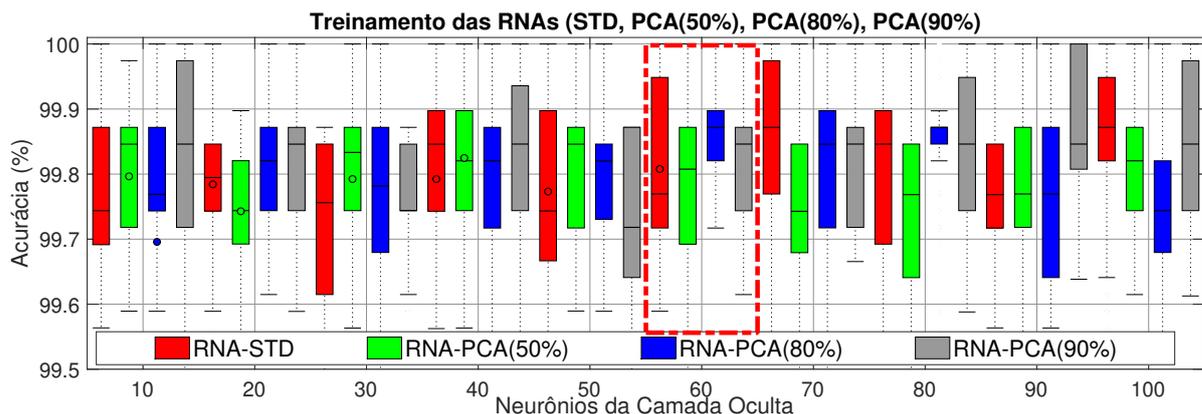
### 4.1.3 Compressão por PCA

Para o caso do PCA, a Tabela 15 apresenta o efeito da compressão na redução da quantidade de amostras do sinal EST.

**Tabela 12** – Fatores de compressão de sinais EST pelo método PCA

Sinal	ID	Compressão PCA	Atributos
Sem Compressão	STD	0%	1827
Compressão 1	$PCA_{10\%}$	10%	1644
Compressão 2	$PCA_{50\%}$	50%	912
Compressão 3	$PCA_{80\%}$	80%	383
Compressão 4	$PCA_{90\%}$	90%	45
Compressão 5	$PCA_{95\%}$	95%	15

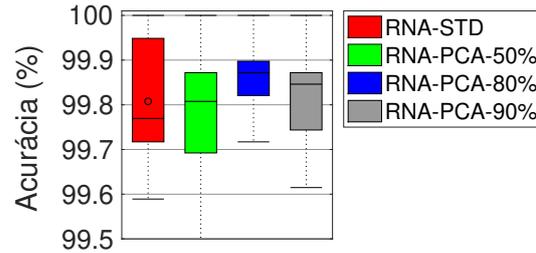
Assim, foram selecionados os fatores de compressão  $PCA_{50\%}$ ,  $PCA_{80\%}$  e  $PCA_{90\%}$  retirados da Tabela 15 e foram realizados treinamentos de Redes neurais com os sinais comprimidos. A Figura 59 apresenta os resultados destes treinamentos.



**Figura 59** – Resultados dos treinamentos das RNAs considerando o efeito da compressão por PCA.

A partir destes resultados, verifica-se que o grupo de classificadores com 60 neurônios na camada oculta apresentou as melhores acurácias de classificação, se comparado aos demais grupos. A Figura 60 apresenta o detalhe do grupo de Redes Neurais com 60 neurônios na camada oculta, considerando o efeito da compressão por PCA.

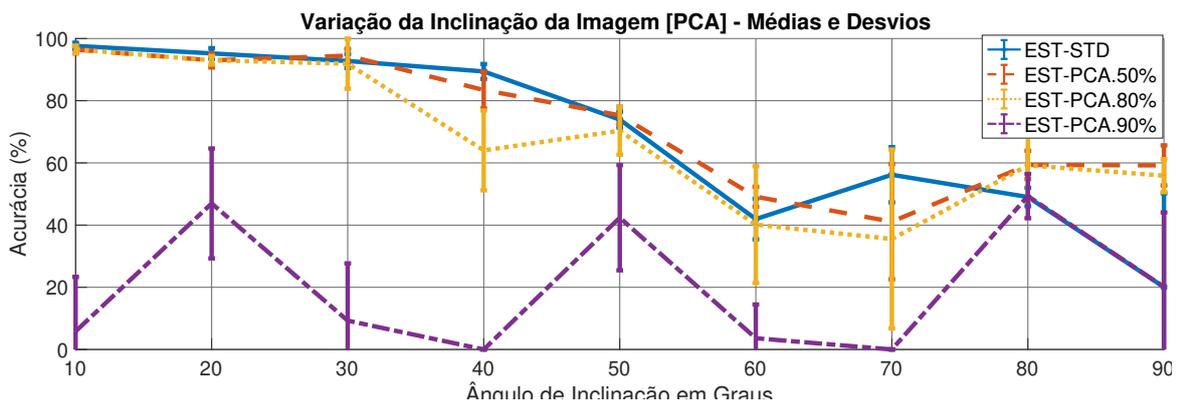
A partir dos resultados apresentados na Figura 60, foi possível identificar que neste grupo, o fator de compressão  $PCA_{80\%}$  apresenta uma menor dispersão dos resultados de classificação se



**Figura 60** – Resultados dos treinamentos das RNAs considerando o efeito da compressão por PCA e 60 Neurônios na camada oculta.

comparado aos fatores  $PCA_{50\%}$  e  $PCA_{90\%}$ , com os quartis distribuídos na faixa entre 99.9% e 99.8% de acurácia de classificação.

Com estes fatores de compressão e neurônios da camada oculta selecionados, foram realizados os testes de influência da inclinação. A Figura 61 apresenta os resultados dos testes com os fatores de compressão  $PCA_{50\%}$ ,  $PCA_{80\%}$  e  $PCA_{90\%}$ , utilizando o mesmo princípio apresentado na Figura 58.



**Figura 61** – Resultados dos testes considerando o efeito da compressão por PCA.

Os resultados apresentados pela Figura 61 indicam que o fator de compressão  $PCA_{80\%}$  apresentou um comportamento próximo ao do sinal original ao ser submetido aos mesmos testes de influência de inclinação, indicando que foram obtidos resultados próximos com uma quantidade reduzida de dados de treinamento. Por outro lado, os resultados mostram que o fator de compressão  $PCA_{90\%}$  acabou retirando partes da informação relevantes para classificação quando submetido aos mesmos testes do sinal original.

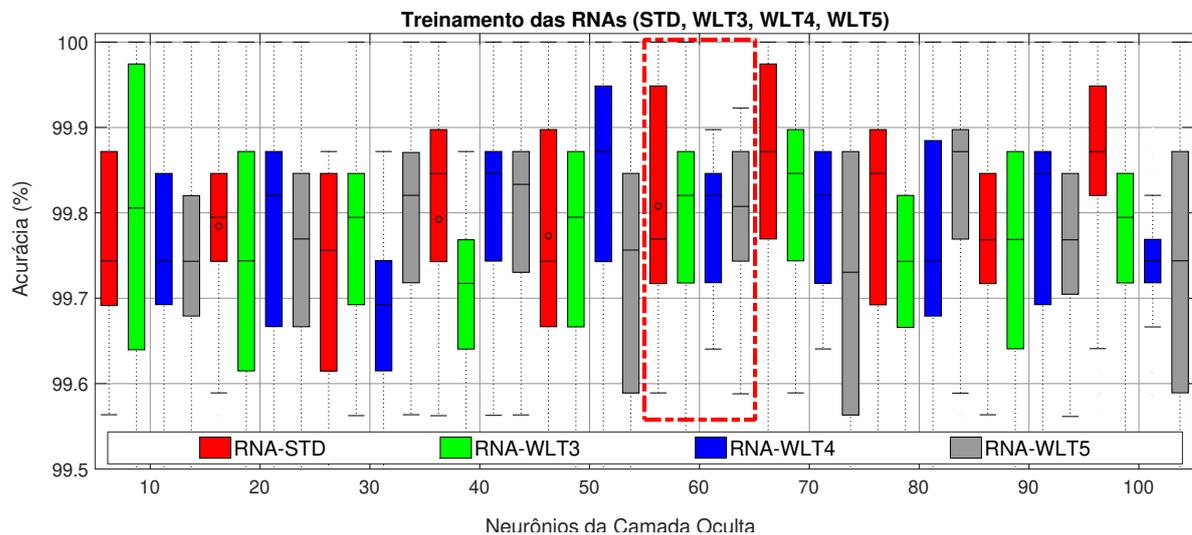
#### 4.1.4 Compressão por WLT

Para o caso da decomposição utilizando o método WLT, foi utilizada a família *Daubechies* em 5 níveis de decomposição. A Tabela 16 apresenta o efeito da decomposição na redução da quantidade de amostras do sinal.

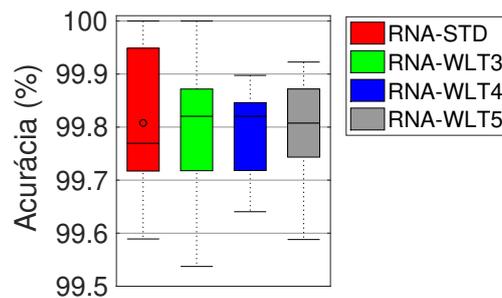
**Tabela 13** – Fatores de compressão de sinais EST pelo método WLT

Sinal	ID	Decomposição WLT	Atributos
Sem Decomposição	STD	0	1827
Decomposição 1	$WLT_1$	1	915
Decomposição 2	$WLT_2$	2	459
Decomposição 3	$WLT_3$	3	231
Decomposição 4	$WLT_4$	4	117
Decomposição 5	$WLT_5$	5	60

Assim, foram selecionados os fatores de decomposição  $WLT_3$ ,  $WLT_4$  e  $WLT_5$  retirados da Tabela 16 e foram realizados treinamentos de Redes Neurais com os sinais comprimidos. A Figura 62 apresenta os resultados destes treinamentos, considerando o efeito da decomposição através da transformada *Wavelet*.

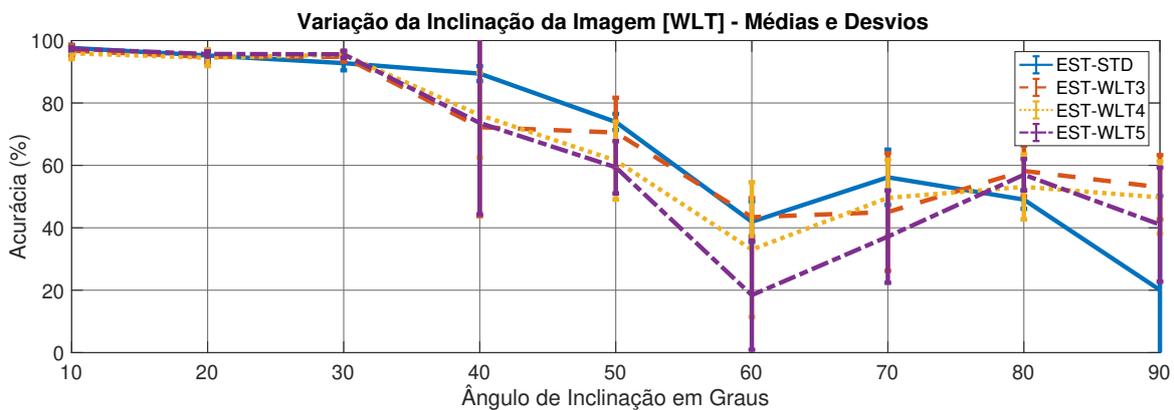
**Figura 62** – Resultados dos treinamentos das RNAs considerando o efeito da decomposição por *wavelet*.

Com base nos resultados apresentados na Figura 62, foi selecionado o grupo de melhor resultado com 60 neurônios na camada oculta. A Figura 63 apresenta o detalhe do grupo de Redes Neurais com 60 neurônios na camada oculta, considerando o efeito da decomposição por transformada *Wavelet*.

**Figura 63** – Resultados dos treinamentos das RNAs considerando o efeito da decomposição por *wavelet* considerando 60 neurônios na camada oculta.

A partir dos resultados apresentados na Figura 63, foi possível identificar que neste grupo, o fator de compressão  $WLT_5$  apresenta uma menor dispersão dos resultados de classificação se comparado aos fatores  $WLT_3$  e  $WLT_4$ , com os quartis distribuídos na faixa entre 99.92% e 99.58% de acurácia de classificação.

Com estes níveis de decomposição e neurônios da camada oculta selecionados, foram realizados os testes de influência da inclinação. A Figura 64 apresenta os resultados dos testes com os fatores de compressão  $WLT_3$ ,  $WLT_4$  e  $WLT_5$ , utilizando o mesmo princípio apresentado na Figura 58.



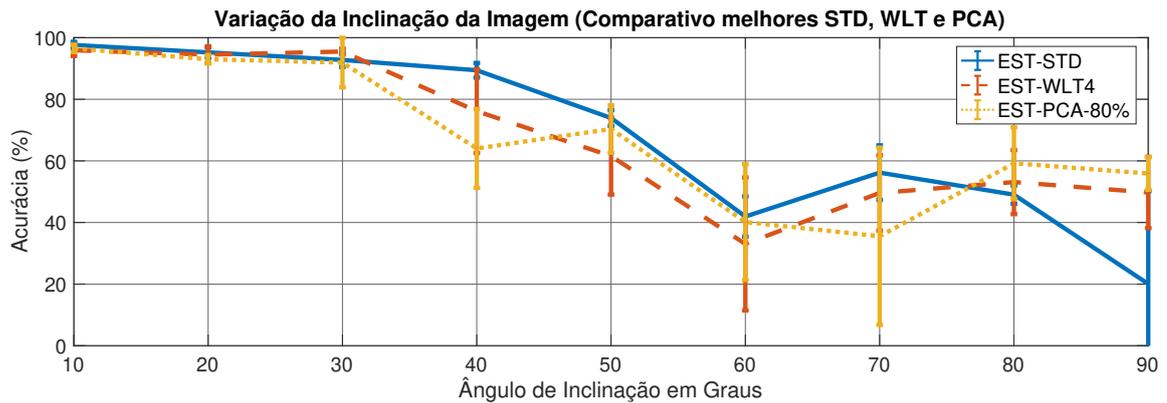
**Figura 64** – Resultados dos testes considerando o efeito da decomposição por WAVELET.

Os resultados apresentados pela Figura 64 indicam que o nível de decomposição  $WLT_4$  apresentou um comportamento próximo ao do sinal original ao ser submetido aos mesmos testes de influência de inclinação, indicando que foram obtidos resultados próximos com uma quantidade reduzida de dados de treinamento.

Os resultados mostram que o fator de compressão  $WLT_5$  apresenta um alto desvio padrão se comparado ao nível de decomposição  $WLT_4$  indicando que, apesar de apresentar um comportamento próximo do sinal original, quando submetido aos mesmos testes, o desvio padrão da média apresenta valores muito elevados variando da faixa de 40% a 100% de acurácia para o caso do ângulo de 40 graus.

#### 4.1.5 Análise Comparativa

A análise comparativa buscou uma relação entre os melhores índices de compressão PCA (383 coeficientes) e *Wavelet* (117 coeficientes) comparado com as 1827 amostras do sinal [EST]. O resultado está apresentado na Figura 65.



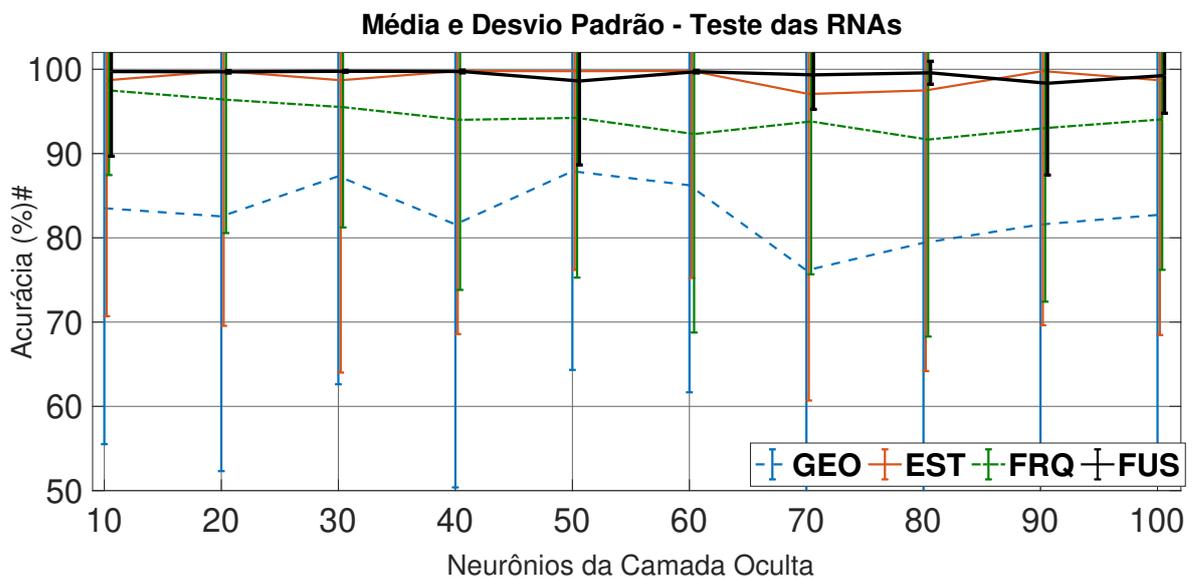
**Figura 65** – Comparação da análise da influência da inclinação da imagem com os melhores resultados de compressão por PCA e Wavelet.

O resultado apresentado pela Figura 65, indica que nos dois métodos de compressão selecionados, os sinais apresentaram um comportamento próximo do sinal original. O fator  $WLT_4$  apresenta um resultado superior ao fator  $PCA_{80\%}$  na faixa de 10 a 40 graus e o fator  $PCA_{80\%}$  apresenta um resultado superior ao fator  $WLT_4$  na faixa entre 50 a 60 graus.

## 4.2 Ambiente Externo

### 4.2.1 Fusão entre Atributos

O treinamento das redes neurais utilizando o método proposto da fusão entre atributos FUS, com a base de dados C1, demonstrou conforme a Figura 55, que ocorre uma menor dispersão dos resultados obtidos se comparado aos demais métodos. A Figura 66 apresenta a média e desvio padrão dos melhores resultados dos grupos de 100 treinamentos considerando as RNAs treinadas, variando de 10 a 100 os neurônios na camada oculta.



**Figura 66** – Comparação entre as médias e desvio padrão dos métodos GEO, EST, FRQ e FUS.

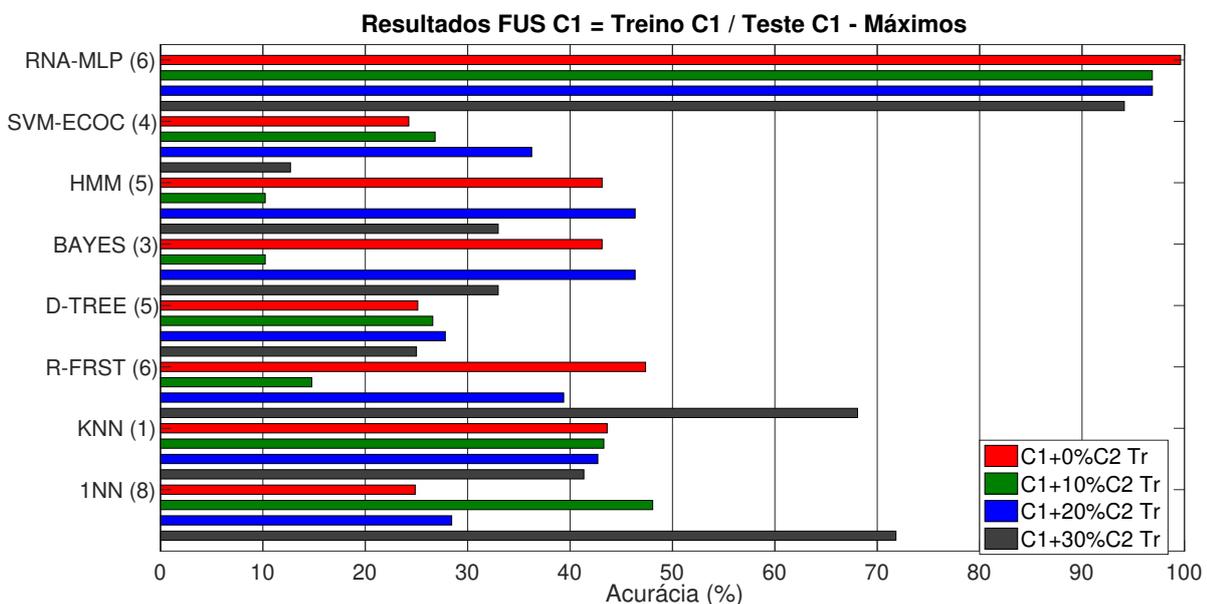
A partir dos resultados apresentados na Figura 66, para a análise da eficiência da classificação nas imagens do ambiente externo, foi selecionado o método de extração de atributos FUS, pelo mesmo ter apresentado menor dispersão nos resultados, se comparado aos demais métodos de extração de atributos individualmente em toda a faixa de 10 a 100 neurônios.

#### 4.2.2 Classificadores e Mistura de Dados

Nesta etapa do trabalho, foi realizado o treinamento de 8 tipos de classificadores (2 baseados em otimização, 2 baseados em probabilidade, 2 baseados em busca e 2 baseados em distâncias) considerando o método de extração de atributos FUS e a mistura gradual de dados de C2 no treinamento dos classificadores. As Figuras 67 a 69 apresentam os resultados desta cadeia de treino e teste descritos na metodologia.

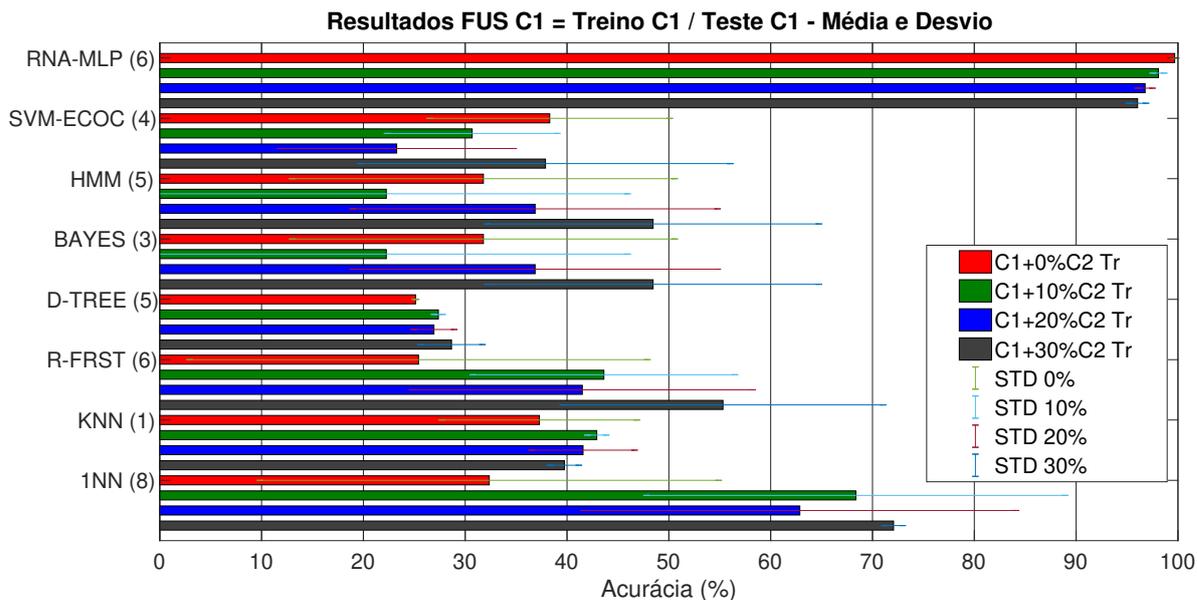
#### 4.2.3 Teste FUS C1

As Figuras 67 e 68 apresentam os mesmos resultados dos melhores classificadores em acurácia, média e desvio padrão respectivamente.



**Figura 67** – Resultados de melhor Acurácia de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C1, considerando a mistura gradual de dados de C2 no conjunto de treino.

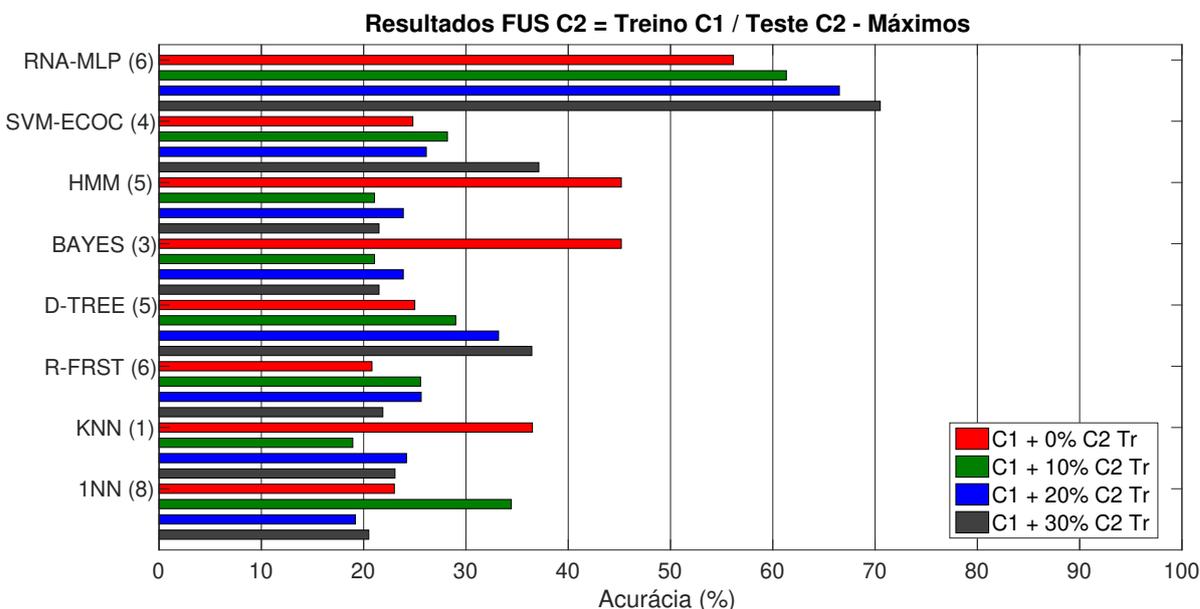
Pode-se observar que os classificadores se comportam de modo diferente de acordo com a mistura gradual de dados de C2. O classificador de melhor desempenho foi do tipo RNA o qual apresentou melhores valores de acurácia, ante uma leve piora em função da mistura dos dados.



**Figura 68** – Resultados de média e desvio padrão de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C1, considerando a mistura gradual de dados de C2 no conjunto de treino.

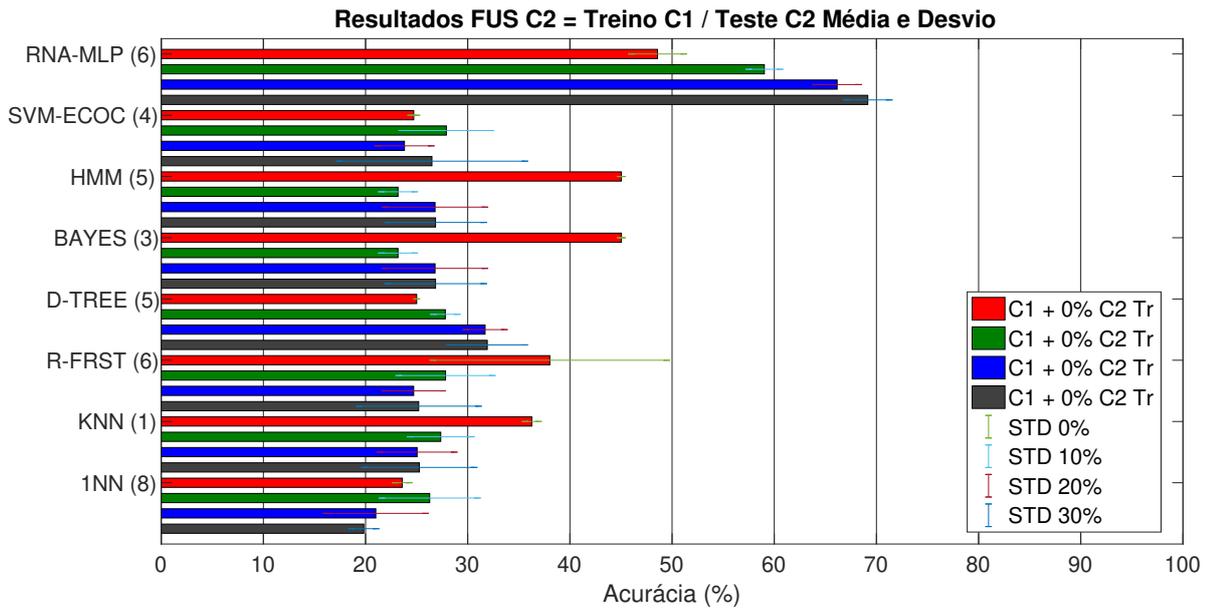
#### 4.2.4 Teste FUS C2

As Figuras 69 e 70 apresentam os mesmos resultados dos melhores classificadores em melhor Acurácia, média e desvio padrão respectivamente.



**Figura 69** – Resultados de melhor Acurácia de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C2, considerando a mistura gradual de dados de C2 no conjunto de treino.

Os resultados mostram que a msitura gradual de dados de C2 no treinamento, não



**Figura 70** – Resultados de média e desvio padrão de classificação das 10 cadeias de 100 treinamentos dos 8 tipos de classificadores treinados com C1 e testados com C2, considerando a mistura gradual de dados de C2 no conjunto de treino.

provocou uma melhoria na acurácia de todos os classificadores. O classificador de melhor desempenho foi do tipo RNA o qual apresentou melhores valores de acurácia, com máximos na faixa entre 50% e 70%.

#### 4.2.5 Sensibilidade dos Classificadores

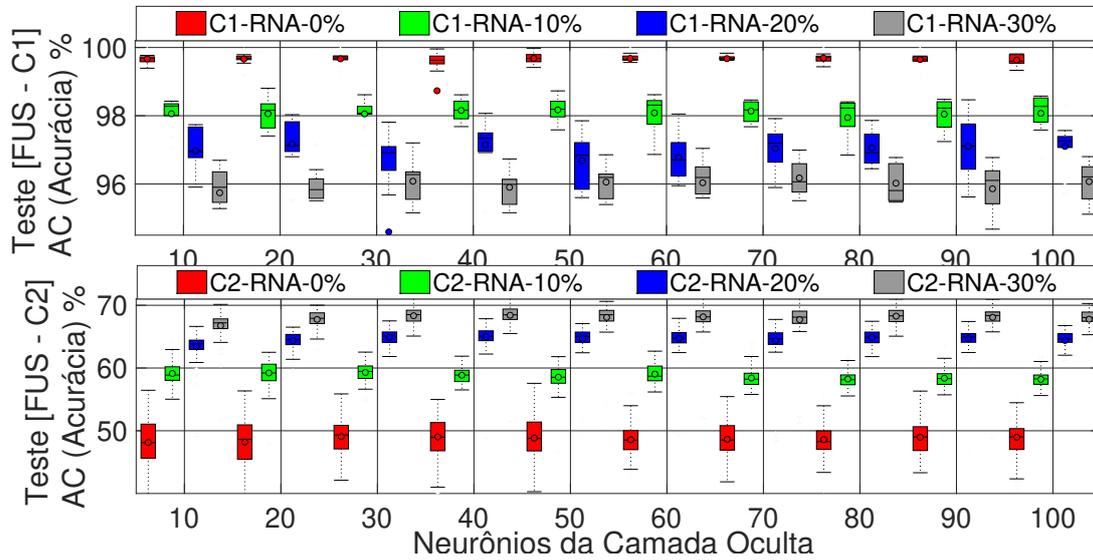
Na etapa complementar ao treino e teste de 8 tipos de classificadores, utilizando os testes (FUS-C1) e (FUS-C2) os resultados foram organizados comparando o treino e teste de C1 com o treino e teste com C2. Os resultados estão apresentados na Tabela 14.

**Tabela 14** – Resultados de melhor Acurácia dos 8 tipos de Classificadores utilizando o método FUS com a mistura de dados de treino entre C1 e C2.

Tipo	Tr C1 Te C1	Tr C1 Te C2	Tr C1+C2 <sub>(10%)</sub> Te C2	Tr C1+C2 <sub>(20%)</sub> Te C2	Tr C1+C2 <sub>(30%)</sub> Te C2
RNA-MLP	99,54	55,00	59,22	64,86	70,02
SVM-ECOC	97,36	25,10	30,07	27,11	32,05
D-TREE	65,24	33,21	39,06	44,11	45,18
R-FOREST	67,15	49,13	30,12	29,04	28,07
HMM	60,12	42,18	40,25	41,06	39,21
BAYES	55,34	25,11	29,33	34,81	36,07
KNN	57,08	28,19	33,02	32,10	31,06
1NN	43,70	31,23	33,70	32,67	42,19

Os resultados indicam que o RNA-MLP apresentou melhor acurácia para todos os casos. Além disso, era mais sensível à mistura de dados do que os outros classificadores, pois a eficiência de discriminação para C2 aumenta proporcionalmente à quantidade de informações desse conjunto incluída na fase de treinamento.

Uma vez que a RNA foi escolhida como classificador, é importante verificar a influência do número de neurônios ocultos na eficiência da discriminação. Considerando isso, o número de neurônios foi variado de 10 a 100 e os resultados obtidos estão ilustrados na Figura 71.



**Figura 71** – Resultados do treino e teste dos classificadores com o teste FUS-C1 e FUS-C2 variando de 10 a 100 o número de neurônios na camada oculta

Com essa análise, foram avaliadas a influência da mistura de dados na melhoria da acurácia de classificação da rede neural artificial, indicando que ocorre uma melhoria que varia da faixa de 50% a 70%.

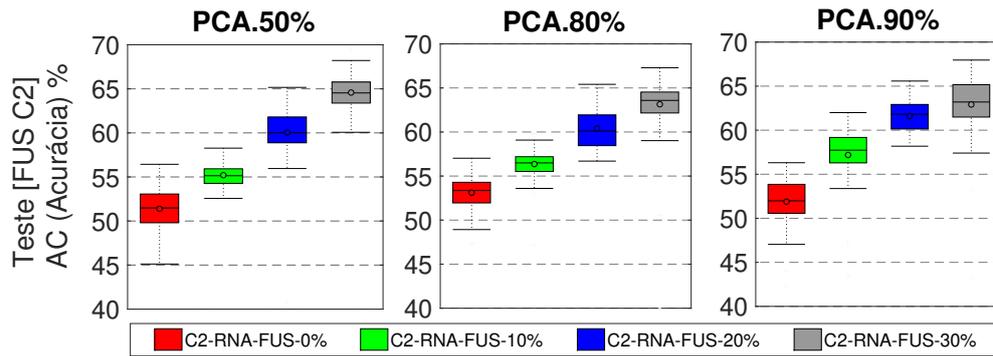
#### 4.2.6 Compressão por PCA

Novamente, para o caso das imagens do ambiente externo, foi verificada a mínima informação necessária para classificação. Para tal estudo, foram utilizadas compressões por Wavelet e por PCA (Análise de Componentes Principais). Para o caso do PCA, a Tabela 15 apresenta o efeito da compressão na redução da quantidade de amostras do sinal.

**Tabela 15** – Fatores de compressão de sinais FUS pelo método PCA

Sinal	ID	Compressão PCA	Atributos
Sem Compressão	STD	0%	1953
Compressão 1	$PCA_{10\%}$	10%	1720
Compressão 2	$PCA_{50\%}$	50%	912
Compressão 3	$PCA_{80\%}$	80%	383
Compressão 4	$PCA_{90\%}$	90%	45
Compressão 5	$PCA_{95\%}$	95%	15

A partir dos resultados de classificação da rede neural artificial, selecionando 60 neurônios na camada oculta, a Figura 72 apresenta os resultados desta cadeia de treino e teste descrita na metodologia, realizando um novo treinamento de um grupo de classificadores em 3 níveis de compressão  $PCA_{50\%}$ ,  $PCA_{80\%}$  e  $PCA_{90\%}$ .



**Figura 72** – Resultados dos treinamentos das RNAs considerando o efeito da compressão por PCA e 60 Neurônios na camada oculta.

Pode ser verificado que os resultados indicam que uma elevada redução de dimensionalidade manteve as acurácias em torno da faixa entre 65% a 70% no caso da adição de 30% de dados de C2 no treino dos classificadores.

#### 4.2.7 Compressão por WLT

Para o caso da decomposição dos sinais que formam os atributos de treinamento dos classificadores, utilizando o método WLT, a Tabela 16 apresenta o efeito da decomposição na redução da quantidade de amostras do sinal.

**Tabela 16** – Fatores de compressão de sinais FUS pelo método WLT

Sinal	ID	Decomposição WLT	Atributos
Sem Decomposição	STD	0	1953
Decomposição 1	$WLT_1$	1	915
Decomposição 2	$WLT_2$	2	459
Decomposição 3	$WLT_3$	3	231
Decomposição 4	$WLT_4$	4	117
Decomposição 5	$WLT_5$	5	60

A partir dos resultados de classificação da rede neural artificial, selecionando 60 neurônios na camada oculta, a Figura 73 apresenta os resultados desta cadeia de treino e teste descrita na metodologia, realizando um novo treinamento de um grupo de classificadores em 3 níveis de compressão  $WLT_3$ ,  $WLT_4$  e  $WLT_5$ .

Pode ser verificado que os resultados indicam que existe uma sensibilidade sobre a decomposição dos sinais, pois uma elevada redução de dimensionalidade também manteve como no PCA, as acurácias em torno da mesma faixa entre 65% a 70%. Ocorre também um deslocamento na mediana do quartil, no caso da compressão  $WLT_3$  parte da faixa em torno de 65% a 70% indo até à faixa de 60% a 65% no caso da compressão  $WLT_5$ , no caso em que ocorre a mistura de 30% de dados de C2 no treino dos classificadores com dados de C1.

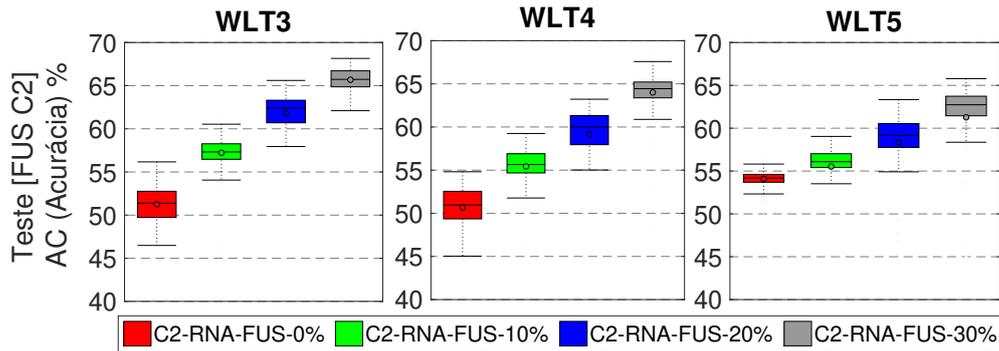


Figura 73 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por WLT e 60 Neurônios na camada oculta.

#### 4.2.8 Análise Comparativa - Compressão

O resultado da análise comparativa buscou uma relação entre a variação de 10 a 100 neurônios na camada oculta, comparando-a com os níveis de compressão  $WLT_3$ ,  $WLT_4$ ,  $WLT_5$ ,  $PCA_{50\%}$ ,  $PCA_{80\%}$ ,  $PCA_{90\%}$ , com o objetivo de comparar as acurácias sem a compressão dos dados, com as acurácias após o efeito da compressão dos dados. Os resultados estão apresentados na Figura 74.

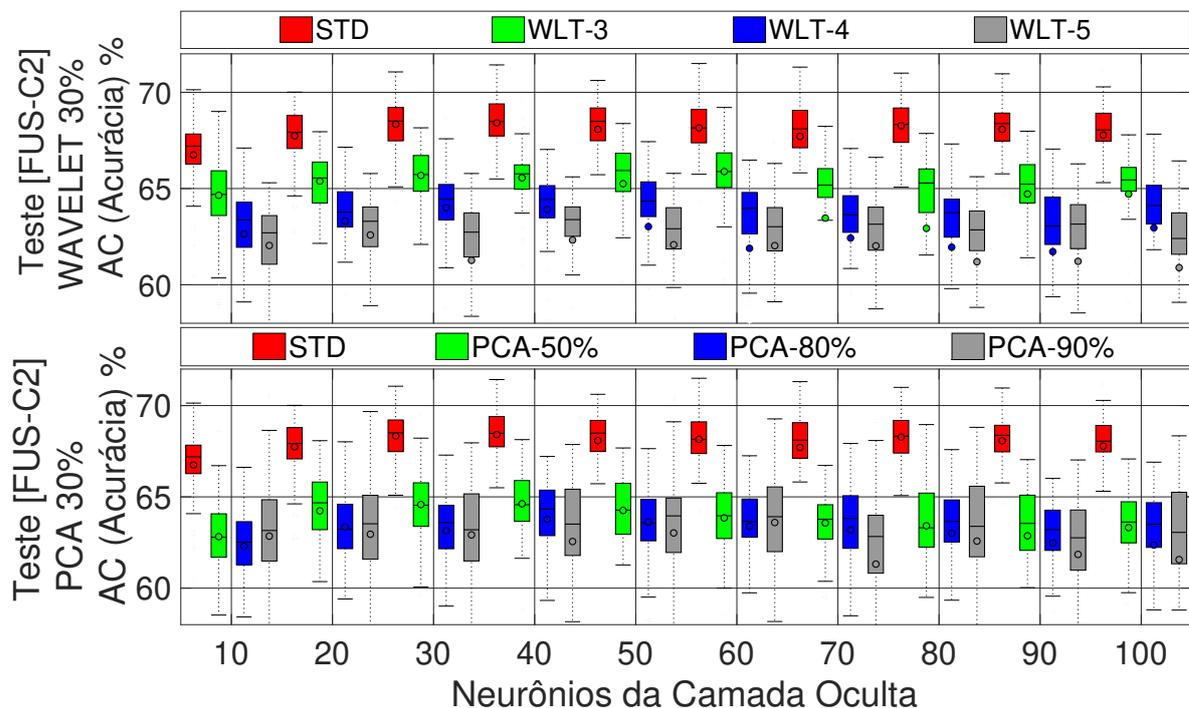
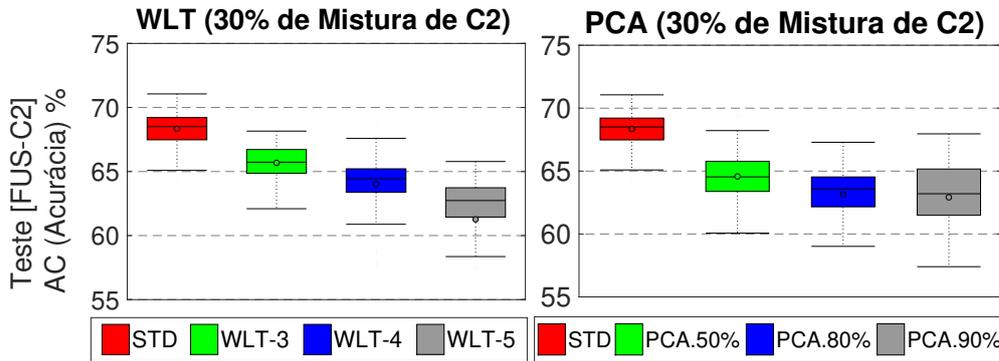


Figura 74 – Resultados dos treinamentos das RNAs considerando o efeito da compressão por WLT e por PCA variando de 10 a 100 o número de Neurônios na camada oculta no caso de 30% de mistura de dados de C2 no treino dos classificadores.

Os resultados indicam que ocorre uma leve piora na acurácia de classificação a partir da compressão dos dados, porém, mantendo os valores dentro de uma determinada faixa em torno de 65%. A figura 75 apresenta a comparação dos resultados selecionando 30 neurônios na

camada oculta.

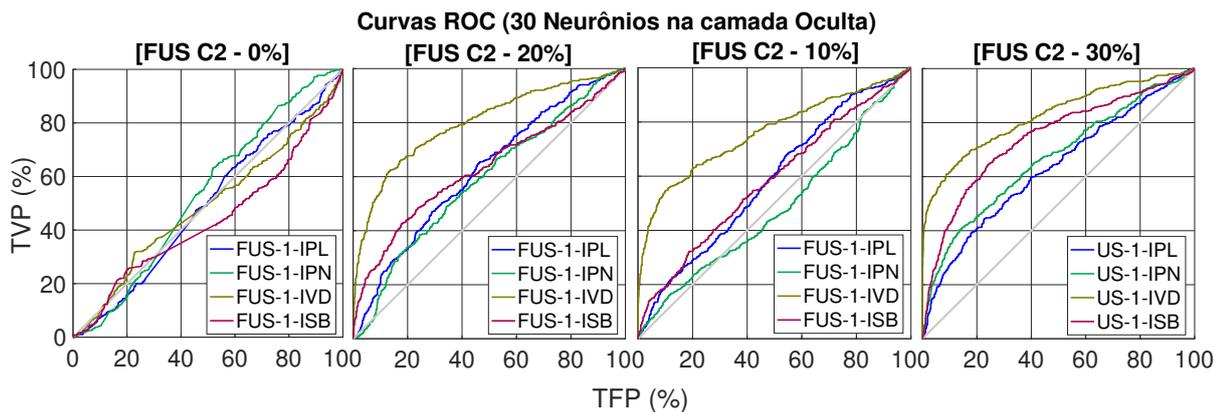


**Figura 75** – Comparação entre WLT e por PCA, considerando 30 neurônios na camada oculta e 30% de mistura de dados de C2 no treino dos classificadores

Os resultados indicam que tanto os métodos WLT quanto PCA apresentam elevada retenção de dados no caso com 30% de mistura de dados de C2 no treino dos classificadores. Os resultados indicam que o fator  $PCA_{90\%}$  apresentou resultado superior ao fator  $WLT_3$  considerando as mesmas condições de mistura de dados.

#### 4.2.9 Análise Comparativa - Confusão entre Classes

Após a seleção do conjunto de Redes Neurais com 30 neurônios na camada oculta, foi realizada a análise através das curvas ROC. A Figura 76 apresenta as curvas ROC do melhor resultado dentre o conjunto de treinamentos realizados com as RNAs, considerando o procedimento anteriormente descrito de mistura gradual de dados.



**Figura 76** – Curvas ROC do melhor resultado com 30 neurônios na camada oculta através do método FUS, dos testes com a base de dados C2 - FUS C2, considerando a adição de 0%, 10%, 20% e 30% de dados de C2 no treino das RNAs.

A Tabela 17 apresenta as respectivas matrizes de confusão dos respectivos classificadores.

Os melhores resultados de acurácia de classificação na faixa entre 60% e 70% ocorrem na condição máxima de mistura de 30% de dados de C2 no treino dos classificadores. Usando como

**Tabela 17** – Resultados: Método FUS com 0 % a 30% de mistura de dados de C2 no treino dos classificadores e 30 Neurônios na camada oculta, nos testes com a base de dados C1 - FUS-C1 e com a base de dados C2 - FUS C2.

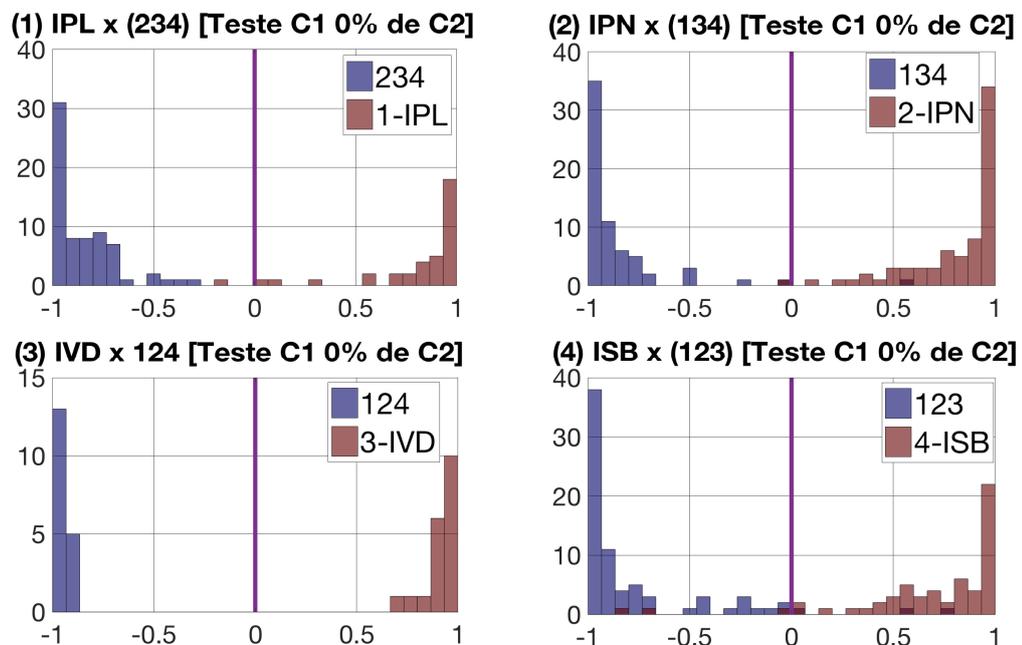
		FUS C1 0%					FUS C1 10%					FUS C1 20%					FUS C1 30%				
		Classe Real					Classe Real					Classe Real					Classe Real				
Classe Predita	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	
	IPL	100	0	0	0	99	0	0	1	99	0	0	1	98	0	0	2	98	0	0	0
	IPN	0	100	0	0	0	100	0	0	0	99	0	1	0	100	0	0	0	0	0	0
	IVD	2	0	98	0	2	0	98	0	2	0	98	0	2	0	98	0	2	0	98	0
	ISB	1	0	0	99	0	0	0	100	0	0	0	100	1	1	0	98	1	1	0	98

		FUS C2 0%					FUS C2 10%					FUS C2 20%					FUS C2 30%				
		Classe Real					Classe Real					Classe Real					Classe Real				
Classe Predita	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	%	IPL	IPN	IVD	ISB	
	IPL	35	49	4	12	39	12	20	30	47	41	3	20	77	6	0	18	77	6	0	18
	IPN	32	55	0	10	16	47	10	28	21	56	5	18	16	81	0	3	16	81	0	3
	IVD	13	29	43	15	19	11	57	14	11	23	51	16	33	6	61	0	33	6	61	0
	ISB	16	41	9	36	31	14	19	37	8,8	30	5,3	56	29	13	0	58	29	13	0	58

base as técnicas de processamento de imagem e de extração de atributos apresentados. Estes resultados indicam que os classificadores encontram algumas dificuldades em distinguir classes de isoladores quando os mesmos se encontram no ambiente externo.

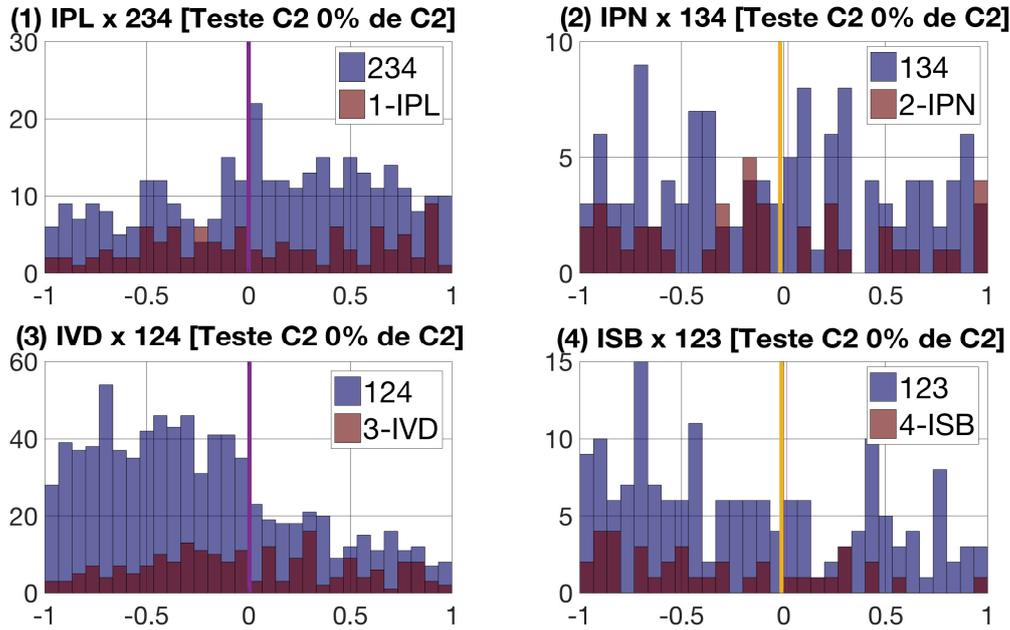
Uma maneira utilizada para verificar como a mistura dos dados pode ajudar na melhoria da classificação, foi o uso de uma máquina de vetor de suporte para uma classificação binária. Considerando 4 classificadores binários, onde para cada um deles a decisão pode ser entre uma classe e as outras 3 restantes. A Figura 77 apresenta os resultados destes testes para o caso do treino e testes realizados com a base de dados C1 sem mistura de dados no treinamento.



**Figura 77** – Resultados do histograma dos valores de saída de teste de C1 de 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino.

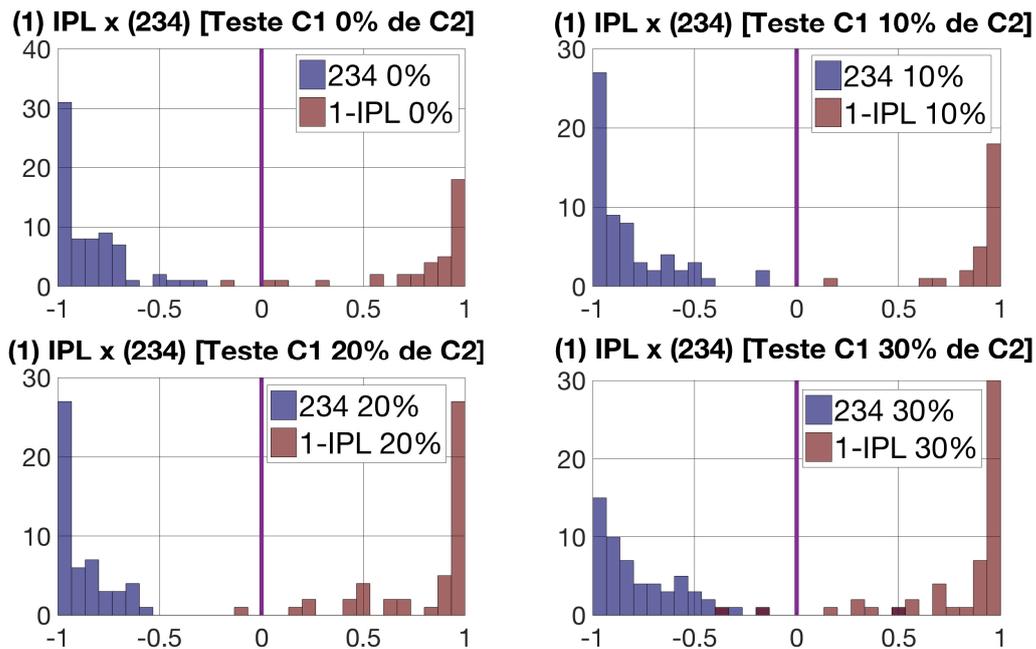
Os resultados indicam que ocorre uma facilidade maior para a máquina de aprendizado distinguir uma classe das demais, com um pouco mais de dificuldade para distinguir os atributos que identificam a classe 4 das demais classes. A Figura 78 apresenta os resultados destes testes

para o caso do treino com C1 e testes realizados com a base de dados C2 sem mistura de dados no treinamento.



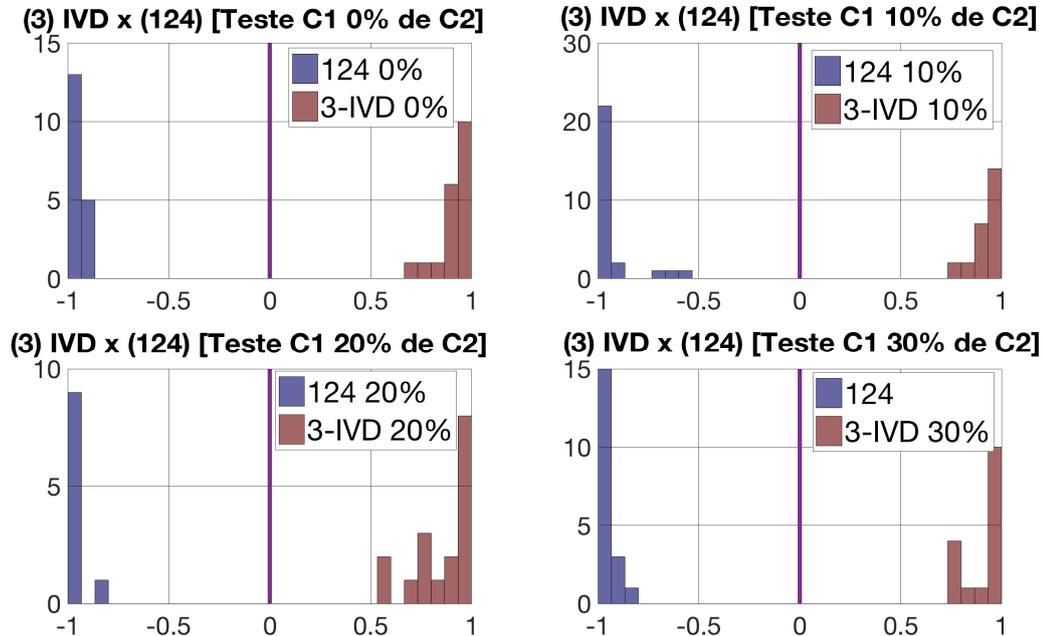
**Figura 78** – Resultados do histograma dos valores de saída de teste de C2 de 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino.

A partir destes resultados, pode-se identificar que as máquinas de aprendizado binárias tiveram dificuldade de distinguir uma classe das demais classes quando foram testadas as imagens do ambiente externo em todas as classes. A Figura 79 apresenta os histogramas dos casos em que a classe 1 foi submetida a um teste de classificadores binários considerando a variação gradual de 0 a 30% de dados de C2 no treino do classificador.



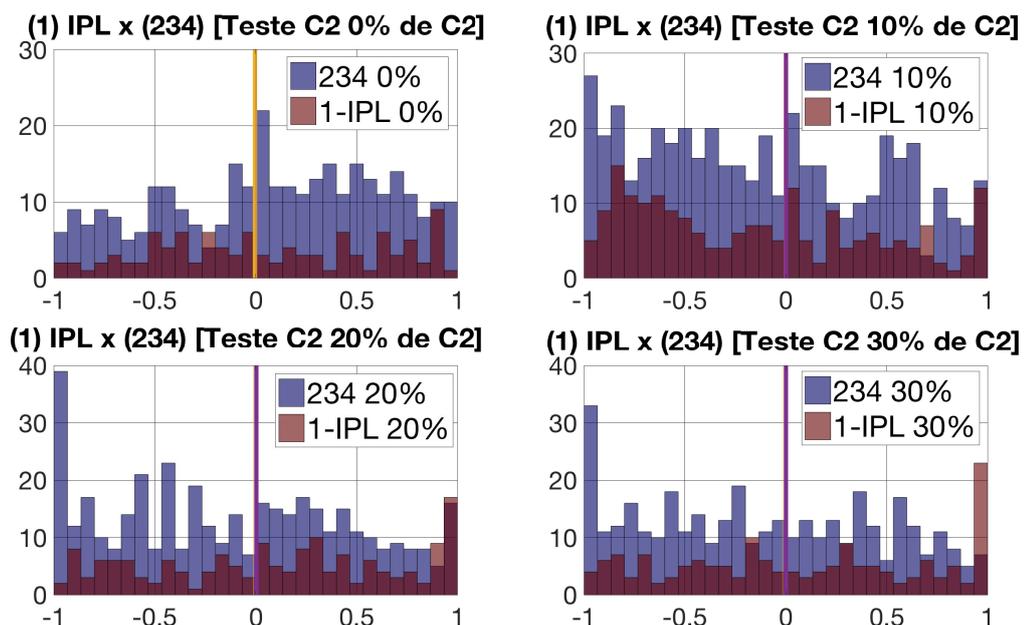
**Figura 79** – Resultados do histograma dos valores de saída de teste de C1 de classificadores SVM binários para a classe 1 (IPL) com mistura gradual de dados de C2 no treino.

A partir dos resultados, pode ser verificado que ocorre uma leve piora na capacidade do classificador distinguir a classe 1 das demais classes a partir da mistura de dados de C2 no treino e teste com C1. A Figura 80 apresenta o resultado de testes realizados de maneira similar considerando a avaliação da classe 3.



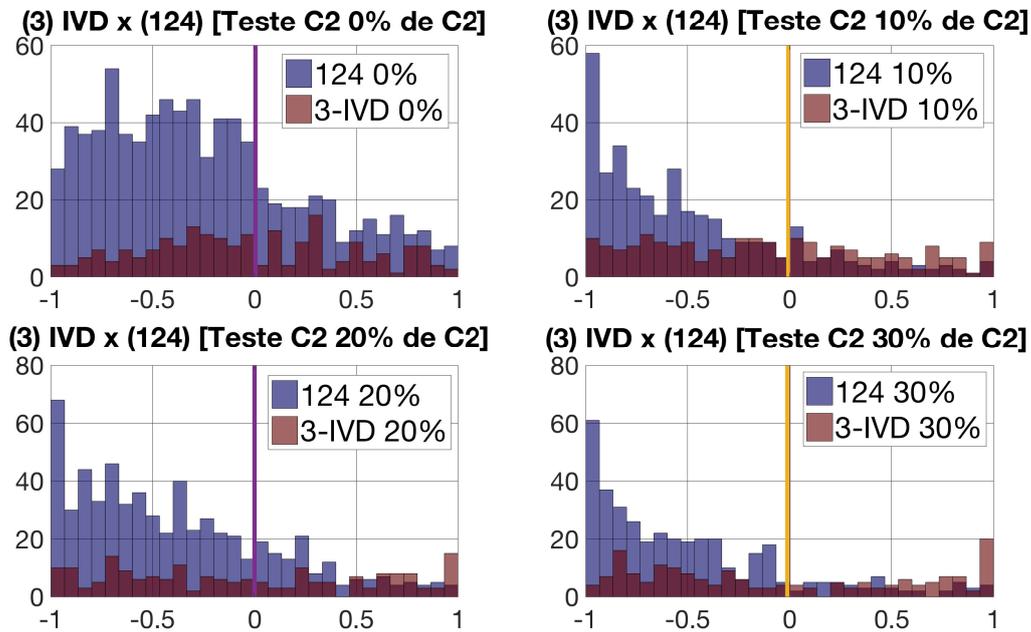
**Figura 80** – Resultados do histograma dos valores de saída de teste de C1 de classificadores SVM binários para a classe 3 (IVD) com mistura gradual de dados de C2 no treino.

Os resultados indicam que a mistura de dados de C2 e o consecutivo teste com C1 não influenciou negativamente a classe 3 se comparado com a influência da classe 1, indicando que os atributos da classe 3 são mais facilmente distinguíveis das demais classes do que os atributos oriundos da classe 1. A Figura 81 apresenta os resultados de testes realizados novamente com a classe 1, porém utilizando dados de C2 no teste, considerando a mistura gradual dos dados de C2 no treino dos classificadores.



**Figura 81** – Resultados do histograma dos valores de saída de teste de C2 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino.

Os resultados desta análise, indicam que mesmo a mistura de dados melhora a qualidade da classificação, a natureza dos dados do ambiente externo dificulta a separação entre a classe 1 e as demais classes. A partir deste resultado, foi realizado um teste similar para a classe 3, o qual ilustra A Figura 82.



**Figura 82** – Resultados do histograma dos valores de saída de teste de C2 4 classificadores SVM binários para cada classe sem mistura de dados de C2 no treino.

A partir do resultado apresentado, pode ser verificado que a mistura de dados no treino do classificador ajudou a máquina de aprendizado a distinguir melhor a classe 3 das demais classes, mesmo utilizando as imagens do ambiente externo nos testes.

## 5 Conclusões

As redes de distribuição de energia aéreas RDAs necessitam de inspeção e manutenção constantes. As falhas nos procedimentos de manutenção e no levantamento e identificação de componentes das redes, dificultam a gestão de ativos e o controle de custos e operacional, além de eventualmente gerar distúrbios para o consumidor final de energia. Neste contexto uma solução que pode ser implementada é a utilização de drones para inspeção e identificação de componentes nestas redes.

Neste trabalho é abordado um dos problemas associados a estes serviços que é a identificação automatizada de isoladores de média tensão nas redes de distribuição na faixa de 15 kV. Para tal, foram utilizados recursos de processamento digital de imagem simulando possíveis posições práticas de uma câmera de um drone, com o objetivo de estudar métodos para classificação eficiente destes componentes.

Entretanto, um dos principais desafios da área de processamento de imagem, encontra-se na complexidade da identificação de objetos e componentes quando os mesmos estão sob as condições do ambiente, com objetos diversos ao problema compondo o pano de fundo da imagem e informações que não são de interesse do aprendizado da máquina e que dificultam a classificação.

Além disso, a inspeção robótica com drones enfrenta o desafio do tempo de autonomia no voo em virtude do alto consumo de energia da bateria. Portanto, técnicas que implicam em alto custo computacional, podem influenciar negativamente nestes parâmetros, além do custo financeiro e peso total do equipamento.

Neste contexto, este trabalho propôs o uso de técnicas de inteligência computacional para a classificação inteligente de 4 tipos de isoladores presentes em redes de distribuição, aplicando as máquinas de aprendizado tipo RNA, SVM, HMM, *Naive Bayes*, árvore de decisão, árvore aleatória, k-vizinhos mais próximo e 1-vizinho mais próximo. Diversas técnicas de processamento de imagens e 4 conjuntos de técnicas de extração de atributos foram utilizadas com o objetivo de alimentar estes classificadores. Também foram utilizadas técnicas de compressão da informação para a simplificação do modelo de treinamento e verificação da informação mínima a ser inserida na máquina de aprendizado.

No ambiente controlado, com a execução do procedimento indicado anteriormente, foram analisados os resultados do desempenho de classificação das RNA (Redes Neurais Artificiais) projetadas. Verifica-se que os resultados apresentam redução no desempenho de classificação mediante o aumento do ângulo de inclinação das imagens. Em 40 graus, a classificação utilizando os atributos sem compactação obteve 81% de acurácia, 5 pontos percentuais abaixo do caso onde é utilizada a compactação por PCA e WLT.

Para a inclinação máxima de 90 graus, os resultados indicam uma diminuição da acurácia, onde o método de extração PCA, obteve melhor desempenho em relação aos atributos sem compactação STD e WLT, resultando em uma taxa de 55% de acurácia.

A compactação por PCA obteve o melhor resultado com grau de compactação de 80%. Todavia, o método WLT, obteve o melhor resultado com grau de decomposição 4. A aplicação destes métodos obteve o melhor desempenho em relação ao procedimento sem compactação na faixa angular de 40 até 90 graus, apresentando maior acurácia.

Na análise sem inclinação, o método EST apresentou aumento na acurácia de 2% e 3%, se comparado a GEO e FRQ, respectivamente. Na análise com inclinação, ocorre uma piora gradual no produto das eficiências de classificação, indicando que a partir de aproximadamente 40 graus, o erro aumenta e torna a classificação ruim, indicando uma faixa de operação para uma câmera em um drone de inspeção.

Na análise com compressão, foi verificado que os métodos PCA e WLT obtiveram melhores resultados na região dos 30 graus e na faixa entre 70 a 90 graus, indicando que as metodologias extraíram maior porção de informação invariante nestas regiões, se comparadas ao método sem compressão STD.

Foi verificado que a fusão entre atributos FUS reduz o desvio padrão da média do produto das eficiências, indicando que a união das informações proporcionou o treinamento de RNAs que apresentaram altos valores de Acurácia e menor dispersão dos resultados de classificação.

No ambiente externo, com a execução do procedimento indicado anteriormente, foram analisados os resultados do desempenho de classificação dos 8 tipos de classificadores treinados pelo método FUS. Foi verificado que o classificador tipo RNA-MLP foi o que apresentou maior sensibilidade à mistura gradual dos dados de C2 no treinamento dos classificadores, variando da faixa entre 50% até 70%.

Na análise com compressão, foi verificado que os métodos PCA e WLT obtiveram melhores resultados com 30 neurônios na camada oculta, e com 30% de dados de C2 no treino dos classificadores, indicando que ambos os métodos apresentam alta sensibilidade a compressão de dados, mantendo as acurácias de classificação com máximos na faixa entre 65% e 70% tanto no caso  $WLT_5$  quanto no caso  $PCA_{90\%}$ , com um desempenho levemente superior para o caso do PCA.

Ao treinar o classificador SVM binário com o intuito de analisar as características das classes, pode ser verificado que no ambiente controlado, o isolador correspondente à classe 3 (IVD - Isolador de vidro) apresenta atributos que o tornaram mais facilmente distinguível das demais classes. Por outro lado, o isolador correspondente à classe 4 (ISB- Isolador de saia baiana) foi identificado como sendo o que apresentou atributos com maior dificuldade de distinção, quando comparado aos demais.

Ao aplicar o mesmo procedimento e analisar as características no ambiente externo, foi verificado que ocorre dificuldade de distinção para todas as classes, entretanto o isolador correspondente à classe 3 (IVD - Isolador de vidro) obteve o melhor desempenho neste teste, indicando que o mesmo possui menos dificuldade para distinção.

Ao aplicar o procedimento da mistura de dados de C2 no treinamento dos classificadores com dados de C1, testando os dados com C1, foi verificado que no caso da classe 3 (IVD - Isolador de vidro) não houve decréscimo na capacidade de distinguir este isolador das demais classes,

fenômeno de piora que foi detectado quando foi realizado o mesmo teste para a classe 1 (IPL - Isolador polimérico).

No caso dos testes que envolvem a mistura de dados, porém sendo testados com dados de C2, para o caso da classe 1 (IPL - Isolador polimérico) foi verificado que a medida que ocorre a mistura de dados no treinamento, o classificador apresenta valores de saída dispersos, mantendo dificuldade na distinção entre a classe 1 e as demais classes. No caso em que é realizado o mesmo teste para a classe 3 (IVD - Isolador de vidro) foi verificado que o classificador apresenta maior tendência aos extremos máximo positivo e negativo na sua saída, demonstrando graficamente que ocorre uma melhoria na capacidade de distinção do classificador.

Com base nos estudos realizados, o arranjo de técnicas que oferece os melhores resultados para a classificação dos isoladores em um ambiente externo com base em imagens de laboratório pode ser obtido através da utilização do método FUS para extração de atributos, aplicando uma compressão  $PCA_{50\%}$ , utilizando um classificador RNA-MLP com 30 neurônios na camada oculta e considerando 30% de mistura de dados de C2 no treino dos classificadores.

## 5.1 Trabalhos Futuros

Com base na melhoria dos resultados de classificação dos isoladores do ambiente externo através da mistura de dados, novas técnicas podem ser testadas e implementadas.

Uma vez que os estudos têm como base a investigação sobre a qualidade da informação que é extraída da imagem a ser entregue ao classificador, podem ser realizados principalmente novos estudos e diversificadas as técnicas de extração de atributos e de segmentação das imagens, de modo a obter outras formas de extração da informação e compará-las entre si, de modo a obter um melhor modelo dos componentes, que ajude a classificar objetos no ambiente externo com base em imagens adquiridas em um ambiente de laboratório.



# Referências

- 1 PEREIRA, M. J. *Engenharia de manutenção: teoria e prática*. [S.l.]: Editora Ciência Moderna, 2009.
- 2 ELECTRIC, G. *Company Will use crawling flying Robots AI predictive analytics inspect hard reach-places*. 2018. Acesso em: 2018-05-30. Disponível em: <<https://www.ge.com/reports/new-company-will-use-crawling-flying-robots-ai-predictive-analytics-inspect-hard-reach-places>> Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 3 QI, C. Invited talk abstract: Challenges and solutions for embedding vision ai. In: IEEE. *2018 1st Workshop on Energy Efficient Machine Learning and Cognitive Computing for Embedded Applications (EMC2)*. [S.l.], 2018. p. 2–2. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 4 KUMAR, S. et al. The zeitgeist juncture of “big data” and its future trends. In: IEEE. *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*. [S.l.], 2019. p. 465–469. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 5 JOUPPI, N. et al. Motivation for and evaluation of the first tensor processing unit. *IEEE Micro*, IEEE, v. 38, n. 3, p. 10–19, 2018. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 6 TROJANOWSKA, J. et al. A methodology of improvement of manufacturing productivity through increasing operational efficiency of the production process. In: *Advances in Manufacturing*. [S.l.]: Springer, 2018. p. 23–32. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 7 SAMPEDRO, C. et al. A supervised approach to electric tower detection and classification for power line inspection. In: IEEE. *Neural Networks (IJCNN), 2014 International Joint Conference on*. [S.l.], 2014. p. 1970–1977. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 8 SOUZA, B. A. de; COSTA, E. G. da. Monitoramento e diagnóstico de isoladores poliméricos utilizando processamento digital de imagens de radiação infravermelha. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 9 LING ZENAN, Q. R. C. Accurate real-time sel-blast glass insulator location method based on faster r-cnn and u-net with aerial images. *Computational Systems and Computer Vision*, China, v. 0, p. 0, 2018. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 10 WANG, X.; ZHANG, Y. Insulator identification from aerial images using support vector machine with background suppression. In: IEEE. *2016 International Conference on Unmanned Aircraft Systems (ICUAS)*. [S.l.], 2016. p. 892–897. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 11 PRASAD, P. S.; RAO, B. P. Lbp-hf features and machine learning applied for automated monitoring of insulators for overhead power distribution lines. In: IEEE. *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. [S.l.], 2016. p. 808–812. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 12 ZHAO, Z. et al. Multi-patch deep features for power line insulator status classification from aerial images. In: IEEE. *2016 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2016. p. 3187–3194. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 13 NGUYEN, V. N.; JENSSEN, R.; ROVERSO, D. Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 99, p. 107–120, 2018. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 14 TIAN, Y.; GUODONG, Y.; JUNZHI, Y. Feature fusion based insulator detection for aerial inspection. In: IEEE. *2017 36th Chinese Control Conference (CCC)*. [S.l.], 2017. p. 10972–10977. Citado na página 31.6 Citado 1 vezes nas páginas 31.
- 15 VARGHESE, A. et al. Power infrastructure monitoring and damage detection using drone captured images. In: IEEE. *2017 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2017. p. 1681–1687. Citado na página 31.6 Citado 1 vezes nas páginas 31.

- 16 PINTO, M. d. O. *Energia Elétrica-geração, transmissão e sistemas interligados*. [S.l.]: Rio de Janeiro: LTC, 2014. Citado na página 35.6 Citado 1 vezes nas páginas 35.
- 17 ABNT, N. B. NBR-15688: Redes de distribuição aérea de energia elétrica com condutores nus. *ABNT - Associação Brasileira de Normas Técnicas*. Citado na página 35.6 Citado 1 vezes nas páginas 35.
- 18 ABNT, N. B. NBR-15992: Redes de distribuição aérea de energia elétrica com cabos cobertos fixados em espaçadores para tensões até 36,2 kv. *ABNT - Associação Brasileira de Normas Técnicas*. Citado na página 35.6 Citado 1 vezes nas páginas 35.
- 19 CEMAR. *NP-12306-2: Procedimento técnico*. 2018. Acesso em: 2018-05-30. Citado na página 35.6 Citado 1 vezes nas páginas 35.
- 20 COELBA. *VR01-02-01-015: Procedimento Técnico*. 2018. Acesso em: 2018-05-30. Citado na página 35.6 Citado 1 vezes nas páginas 35.
- 21 MINIPA. *lDetector de Alta tensão*. 2018. Acesso em: 2018-08-17. Disponível em: <<https://http://www.minipa.com.br/ferramentas-eletricas/detector-de-alta-tensao/17-ezhv>>. Citado na página 37.6 Citado 1 vezes nas páginas 37.
- 22 OLIVEIRA, R. G. D. d. et al. Equalização e segmentação de imagens termográficas aplicadas à metodologia de inspeção de isoladores poliméricos. Universidade Federal de Campina Grande, 2017. Citado na página 37.6 Citado 1 vezes nas páginas 37.
- 23 OLIMPUS. *lDetector de faltas em Compósitos em isoladores por inspeção de Ultrassom*. 2018. Acesso em: 2018-08-17. Disponível em: <<https://https://www.olympus-ims.com/pt/bond-testing-in-composite-power-line-insulators/>>. Citado na página 37.6 Citado 1 vezes nas páginas 37.
- 24 MOR, A. R. et al. A new design of a test platform for testing multiple partial discharge sources. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 94, p. 374–384, 2018. Citado na página 39.6 Citado 1 vezes nas páginas 39.
- 25 BRIZUELA, J. et al. Air-coupled ultrasound inspection of complex aluminium-cfrp components. In: IEEE. *2016 IEEE International Ultrasonics Symposium (IUS)*. [S.l.], 2016. p. 1–4. Citado na página 39.6 Citado 1 vezes nas páginas 39.
- 26 SILVA, G. C. d. Descargas parciais estimuladas por raios-x contínuo e pulsado em materiais dielétricos: similaridades e diferenças. UFPR Furitiba, 2005. Citado na página 39.6 Citado 1 vezes nas páginas 39.
- 27 DISTRIBUIÇÃO, P. de. Módulo 8—qualidade da energia elétrica. *Agência Nacional de Energia Elétrica-ANEEL*., 2010. Citado na página 39.6 Citado 1 vezes nas páginas 39.
- 28 JAISWAL, G. C.; BALLAL, M. S.; TUTAKNE, D. Impact of power quality on the performance of distribution transformer. In: IEEE. *2016 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*. [S.l.], 2016. p. 1–5. Citado na página 39.6 Citado 1 vezes nas páginas 39.
- 29 FILHO, J. M. *Manual de Equipamentos Elétricos*. [S.l.]: Rio de Janeiro: LTC, 2000. v. 2.
- 30 BOYLESTAD, R. L.; NASHELSKY, L. *Dispositivos eletrônicos e teoria de circuitos*. [S.l.]: Prentice-Hall do Brasil, 1984. v. 6. Citado na página 40.6 Citado 1 vezes nas páginas 40.
- 31 ANEEL. *Resolução Normativa 414*. 2017. Acesso em: 2018-05-30. Citado na página 40.6 Citado 1 vezes nas páginas 40.
- 32 CST. *Cerâmica Santa Terezinha*. 2018. Acesso em: 2018-05-30. Disponível em: <<http://www.cst-isoladores.com.br/produtos>>. Citado na página 40.6 Citado 1 vezes nas páginas 40.
- 33 GRANTEL. *Grantel Isoladores*. 2018. Acesso em: 2018-05-30. Disponível em: <<http://grantelequipamentos.com.br>>. Citado na página 40.6 Citado 1 vezes nas páginas 40.
- 34 SIKLOWATT. *Siklowatt Isoladores*. 2018. Acesso em: 2018-05-30. Disponível em: <<http://www.siklowatt.com.br>>. Citado na página 40.6 Citado 1 vezes nas páginas 40.
- 35 BALESTRO. *Balestro Isoladores*. 2018. Acesso em: 2018-05-30. Disponível em: <<http://www.balestro.com.br>>. Citado na página 40.6 Citado 1 vezes nas páginas 40.

- 36 GERMER. *Germer Isoladores*. 2018. Acesso em: 2018-05-30. Disponível em: <<http://www.germerisoladores.com.br>>. Citado na página 40.6 Citado 1 vez nas páginas 40.
- 37 DREAMSTIME. *Dreams time*. 2018. Acesso em: 2018-08-02. Disponível em: <<http://www.dreamstime.com>>. Citado na página 41.6 Citado 1 vez nas páginas 41.
- 38 NIXON, M. S.; AGUADO, A. S. *Feature extraction & image processing for computer vision*. [S.l.]: Academic Press, 2012. Citado na página 42.6 Citado 1 vez nas páginas 42.
- 39 WANG, X.; XU, Q. Multi-sensor optical remote sensing image registration based on line-point invariant. In: IEEE. *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. [S.l.], 2016. p. 2364–2367. Citado na página 42.6 Citado 1 vez nas páginas 42.
- 40 GAUTHIER, I. et al. Expertise for cars and birds recruits brain areas involved in face recognition. *Nature neuroscience*, Nature Publishing Group, v. 3, n. 2, p. 191, 2000. Citado na página 42.6 Citado 1 vez nas páginas 42.
- 41 AKSEBZECI, B. H.; KAYAALTI, Ö. Computer-aided classification of breast cancer histopathological images. In: IEEE. *2017 Medical Technologies National Congress (TIPTEKNO)*. [S.l.], 2017. p. 1–4. Citado na página 42.6 Citado 1 vez nas páginas 42.
- 42 MANOLAKIS, D.; MARDEN, D.; SHAW, G. A. Hyperspectral image processing for automatic target detection applications. *Lincoln laboratory journal*, v. 14, n. 1, p. 79–116, 2003. Citado na página 42.6 Citado 1 vez nas páginas 42.
- 43 THEOHARATOS, C. et al. Vision-based guidance of a robotic arm for object handling operations—the white'r vision framework. In: IEEE. *2016 IEEE 2nd International Forum on Research and Technologies for Society and Industry Leveraging a better tomorrow (RTSI)*. [S.l.], 2016. p. 1–6. Citado na página 42.6 Citado 1 vez nas páginas 42.
- 44 GONZALEZ, R. C.; WOODS, R. E. *Digital image processing*. [S.l.]: Upper Saddle River, NJ: Prentice Hall, 2012.
- 45 BACKES, A. R.; JUNIOR, S.; MESQUITA, J. J. de. *Introdução à Visão Computacional Usando MATLAB*. [S.l.]: Alta Books Editora, 2016.
- 46 LORENA, A. C.; GAMA, J.; FACELI, K. *Inteligência Artificial: Uma abordagem de aprendizado de máquina*. [S.l.]: Grupo Gen-LTC, 2000.
- 47 PAPOULIS, A.; PILLAI, S. U. *Probability, random variables, and stochastic processes*. [S.l.]: Tata McGraw-Hill Education, 2002. Citado na página 50.6 Citado 1 vez nas páginas 50.
- 48 HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007.
- 49 LUDWIG, O.; COSTA, E. *Redes neurais-fundamentos e aplicações com programas em C*. [S.l.]: Editora Ciência Moderna, 2007. Citado na página 54.6 Citado 1 vez nas páginas 54.
- 50 BOOK, D. L. *DLB*. 2018. Acesso em: 2018-08-06. Disponível em: <<http://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>>. Citado na página 54.6 Citado 1 vez nas páginas 54.
- 51 KUMAR, R.; SRIVASTAVA, R.; SRIVASTAVA, S. Detection and classification of cancer from microscopic biopsy images using clinically significant and biologically interpretable features. *Journal of medical engineering*, Hindawi, v. 2015, 2015. Citado na página 56.6 Citado 1 vez nas páginas 56.
- 52 SALEM, T. E.; IBITAYO, D.; GEIL, B. R. Calibration of an infrared camera for thermal characterization of high voltage power electronic components. In: IEEE. *Instrumentation and Measurement Technology Conference, 2005. IMTC 2005. Proceedings of the IEEE*. [S.l.], Ontario–Canada, 2005. v. 2, p. 829–833. Citado na página 56.6 Citado 1 vez nas páginas 56.
- 53 VIEIRA, F. H. A. *Image processing through machine learning for wood quality classification*. Universidade Estadual Paulista (UNESP), 2016. Citado na página 56.6 Citado 1 vez nas páginas 56.
- 54 CRISTIANINI, N.; SHAW-TAYLOR, J. et al. *An introduction to support vector machines and other kernel-based learning methods*. [S.l.]: Cambridge university press, 2000. Citado na página 56.6 Citado 1 vez nas páginas 56.

- 55 GAMA, J. Árvores de decisão. *Palestra ministrada no Núcleo da Ciência de Computação da Universidade do Porto, Porto*, 2002.
- 56 SCHARF, L. L.; DEMEURE, C. *Statistical signal processing: detection, estimation, and time series analysis*. [S.l.]: Addison-Wesley Reading, MA, 1991. v. 63.
- 57 OLIVEIRA, H. M. D. *Análise de sinais para engenheiros*. [S.l.]: Brasport, 2007. Citado na página 63.6 Citado 1 vezes nas páginas 63.
- 58 PRASAD, L.; IYENGAR, S. S. *Wavelet analysis with applications to image processing*. [S.l.]: CRC press, 1997.
- 59 SKODRAS, A.; CHRISTOPOULOS, C.; EBRAHIMI, T. The jpeg 2000 still image compression standard. *IEEE Signal processing magazine*, IEEE, v. 18, n. 5, p. 36–58, 2001. Citado na página 63.6 Citado 1 vezes nas páginas 63.
- 60 WELSTEAD, S. T. *Fractal and wavelet image compression techniques*. [S.l.]: SPIE Optical Engineering Press Bellingham, Washington, 1999. Citado na página 63.6 Citado 1 vezes nas páginas 63.
- 61 ANGARITA, J. A. C.; BERGER, P. D. A.; NASCIMENTO, F. A. D. O. Algoritmo híbrido de compressão de sinais de perturbações em sistemas de energia elétrica. UESP Júlio Mesquita Filho, Dissertação de Mestrado. São Paulo, 2015. Citado na página 63.6 Citado 1 vezes nas páginas 63.
- 62 VARANIS, M. V. M. et al. Detecção de falhas em motores elétricos através da transformada wavelet packet e métodos de redução de dimensionalidade. [sn], Tese de Doutorado. UNICAMP, 2014. Citado na página 63.6 Citado 1 vezes nas páginas 63.
- 63 FERREIRA, L.; FILHO, E. de S. A voltage regulator fault risk assessment method through discrete wavelet analysis of an acoustic vibration signal. In: IEEE. *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*. [S.l.], 2018. Citado na página 63.6 Citado 1 vezes nas páginas 63.
- 64 ASUS. *Asus Zen Phone*. 2018. Acesso em: 2018-08-08. Disponível em: [</https://www.asus.com/br/Phone/>](https://www.asus.com/br/Phone/). Citado na página 70.6 Citado 1 vezes nas páginas 70.
- 65 MOREIRA, V. de A. *Iluminação e fotometria: teoria e aplicação*. [S.l.]: E. Blucher, 1987. Citado na página 71.6 Citado 1 vezes nas páginas 71.
- 66 PRATES RICARDO M, E. F. d. S. F. A. P. M. R. P. R.; B., J. S. C. Insulator visual non-conformity detection in overhead power distribution lines using deep learning. *ELSELVIER*, v. 78, p. 343–355, 2019. Citado na página 71.6 Citado 1 vezes nas páginas 71.
- 67 APPLE. *Apple MacBook Pro*. 2018. Acesso em: 2018-08-08. Disponível em: [https://support.apple.com/kb/SP649?locale=pt\\_BR&viewlocale=en\\_US](https://support.apple.com/kb/SP649?locale=pt_BR&viewlocale=en_US)>. Citado na página 74.6 Citado 1 vezes nas páginas 74.
- 68 NVIDIA. *Nvidia Titan X*. 2018. Acesso em: 2018-08-08. Disponível em: <https://www.nvidia.com/pt-br/geforce/products/10series/titan-x-pascal/>>. Citado na página 74.6 Citado 1 vezes nas páginas 74.
- 69 AKTIO. *Aktio Node TB3 Enclosures*. 2018. Acesso em: 2018-08-08. Disponível em: <https://www.akitio.com/expansion/node>>. Citado na página 74.6 Citado 1 vezes nas páginas 74.
- 70 INTEL. *Thunderbolt 3 tecnologia*. 2018. Acesso em: 2018-08-08. Disponível em: <https://www.intel.com.br/content/www/br/pt/support/articles/000021752/mini-pcs.html>>. Citado na página 74.6 Citado 1 vezes nas páginas 74.
- 71 APPLE. *Thunderbolt 3 (USB-C) to Thunderbolt 2-1 adapter*. 2018. Acesso em: 2018-08-08. Disponível em: <https://www.apple.com/br/shop/product/MMEL2AM/A/adaptador-de-thunderbolt-3-usb-c-para-thunderbolt-2?fnode=/>>. Citado na página 74.6 Citado 1 vezes nas páginas 74.
- 72 GONZALEZ, R. C.; EDDINS, S. L. *Digital image processing using MATLAB*. [S.l.]: Gatesmark Publishing, 2017.
- 73 SOUZA, E. E. P. de. Pré-processamento eficiente para um sistema online de classificação baseado em redes neurais artificiais. In: UFBA. *Dissertação de Mestrado*. [S.l.], 2015. Citado na página 86.6 Citado 1 vezes nas páginas 86.

- 74 WEEKS, M. Processamento digital de sinais utilizando matlab e wavelets. *LTC, Rio de Janeiro*, 2012. Citado na página 86.6 Citado 1 vezes nas páginas 86.
- 75 CHENG, X. et al. A novel integrated pca and fld method on hyperspectral image feature extraction for cucumber chilling damage inspection. *Transactions of the ASAE*, American Society of Agricultural and Biological Engineers, v. 47, n. 4, p. 1313, 2004. Citado na página 86.6 Citado 1 vezes nas páginas 86.
- 76 KAGAN, N.; OLIVEIRA, C. C. B. D.; ROBBA, E. J. *Introdução aos sistemas de distribuição de energia elétrica*. [S.l.]: Edgard Blücher, 2005. Citado na página 119.6 Citado 1 vezes nas páginas 119.



# Apêndices



# APÊNDICE A – Trabalhos Publicados

Seguem abaixo os resumos dos trabalhos científicos publicados com os resultados encontrados da pesquisa, que fundamentou esta dissertação.

## A.1 Artigos em Congressos

1. *André Pinto Marotta, Eduardo F. Simas Filho, Ricardo M. Prates, Rodrigo P. Ramos. Estudo da Influência do Ângulo de Inclinação na Classificação de Isoladores Utilizando Redes Neurais e Processamento de Imagem. ENCOM - VIII CONFERÊNCIA NACIONAL EM COMUNICAÇÕES, REDES E SEGURANÇA DA INFORMAÇÃO.* Salvador - BA, Outubro de 2018.

### Resumo:

O presente trabalho apresenta uma metodologia para aquisição, processamento e classificação automatizada de imagens de cinco tipos de isoladores utilizados em redes de distribuição de média tensão simulando o que ocorre na prática com a aquisição de imagens usando um drone. Um banco de dados foi montado com diferentes ângulos de inclinação em relação ao eixo central dos isoladores. Foram utilizadas diferentes formas de extração de atributos das imagens para alimentar classificadores baseados em redes neurais artificiais. Por fim, foram realizados testes com a compressão por Análise de Componentes Principais (PCA) e Wavelet a fim de verificar a informação mínima necessária para classificação.

2. *André Pinto Marotta, Eduardo F. Simas Filho, Ricardo M. Prates, Rodrigo P. Ramos. Fusão Entre Técnicas de Extração de Atributos Na Classificação de Isoladores de Redes de Distribuição Usando Redes Neurais. SBAI - VIII SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE.* Ouro Preto - MG, Outubro de 2019.

### Resumo:

O presente trabalho apresenta uma metodologia para processamento automatizado de imagens e classificação de quatro tipos de isoladores utilizados em redes de distribuição aéreas de média tensão (RDAs). Para isso, foi desenvolvida uma rede de distribuição didática para coletar fotos dos isoladores em um ambiente externo e também um estúdio para aquisição de imagens em ambiente controlado. Posteriormente, os atributos de imagem foram extraídos e utilizados como entrada para diferentes classificadores treinados, como redes neurais, máquina de vetor de suporte, árvore de decisão, n-vizinhos próximos, *naive bayes* e modelo oculto de Markov, para uma mistura gradual entre as bases de dados (estúdio e imagens externas). As eficiências de classificação foram comparadas considerando a aplicação da análise de componentes principais (ACP) para identificar as informações mínimas necessárias para a classificação.

3. Ricardo M. Prates, André Pinto Marotta, Eduardo F. Simas Filho, Rodrigo P. Ramos. **Development of Statistical Model for Insulator Type Classification in Overhead Power Lines.** *ENCOM - IX CONFERÊNCIA NACIONAL EM COMUNICAÇÕES, REDES E SEGURANÇA DA INFORMAÇÃO.* Salvador - BA, Outubro de 2019.

#### **Resumo:**

Este artigo apresenta uma metodologia estatística para classificação de imagem dos tipos de isoladores geralmente encontrados em Overhead Linhas de distribuição de energia (OPDLs). O processo de classificação ocorre através do uso de aprendizagem profunda e de uma abordagem estatística, conhecido como Modelo de Markov Oculto (HMM). Essa metodologia pode ser descrito pelas seguintes etapas: segmentação de imagem por um tipo específico de Rede Neural Convolutiva (CNN), chamado UNet; extração de atributos dimensionais; projeto de vetor de parâmetro e desenvolvimento de uma cadeia HMM para classificação sequencial de dados. O modelo proposto alcançou 91% de identificação da classe de isoladores, superando outras soluções disponíveis, como Floresta aleatória e SVM (Support Vector Machine).

## A.2 Artigo em Periódico

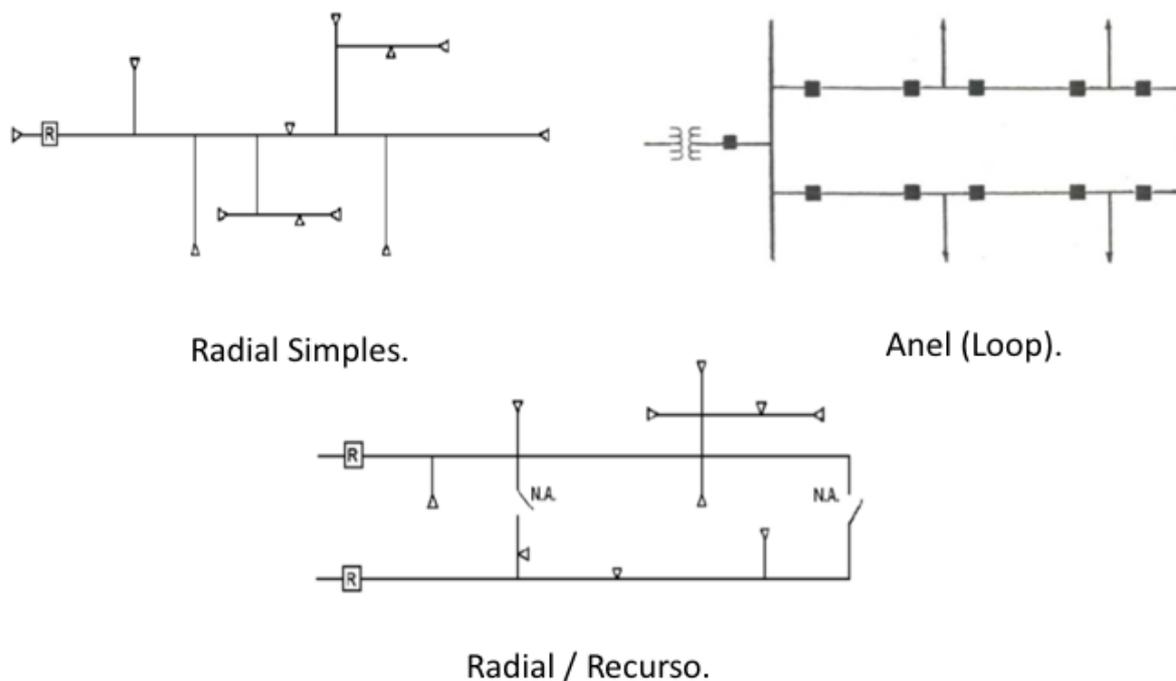
1. Ricardo M. Prates, Ricardo Cruz, André Pinto Marotta, Rodrigo P. Ramos, Eduardo F. Simas Filho, Jaime S. Cardoso **Insulator visual non-conformity detection in overhead power distribution lines using deep learning.** *Computers and Electrical Engineering.* 78 (2019) 343–355, Agosto de 2019.

#### **Resumo:**

Overhead Power Distribution Lines (OPDLs) correspond to a large percentage of the medium-voltage electrical systems. In these networks, visual inspection activities are usually performed without resorting to automated systems, requiring a significant investment of time and human resources. We present a methodology to identify the defect and type of insulators using Convolutional Neural Networks (CNNs). More than 2500 photographs were collected both from inside a studio and from a realistic OPDL. A classification model is proposed to automatically recognize the insulators conformity. This model is able to learn from indoors photographs by augmenting these images with realistic details such as top ties and real-world backgrounds. Furthermore, Multi-Task Learning (MTL) was used to improve performance of defect detection by also predicting the insulator class. The proposed methodology is able to achieve an accuracy of 92% for material classification and 85% for defect detection, with F1-score of 0.75, surpassing available solutions.

## APÊNDICE B – Topologia de Projeto de Redes de Distribuição

A configuração das redes de distribuição de energia elétrica podem ser fundamentalmente de três tipos distintos: radial simples, radial com recurso e em anel [76]. A Figura 83 apresenta os tipos de projetos.



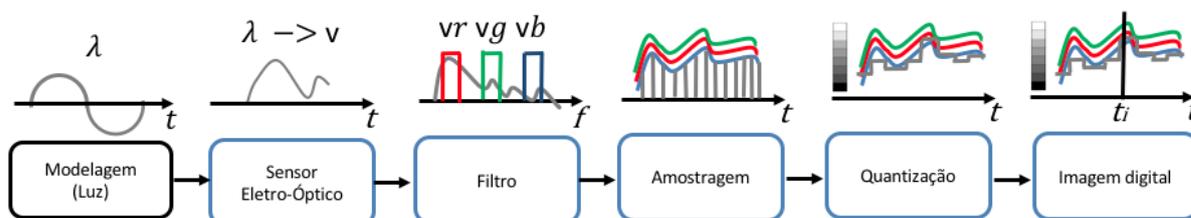
**Figura 83** – Tipos de Topologias comuns em redes de distribuição. Adaptado de [12].

Nos sistemas radiais simples, ocorre uma ramificação da malha de distribuição de energia. Já no sistema radial com recurso, existe a opção de manobrar chaves seccionadoras operadas local ou remotamente para que determinadas regiões da rede tenham recursos alternativos em caso de falta de energia. Por fim a distribuição em anel, possui um sistema fechado que garante que os ramos secundários não tenham interferência entre eles, ligando todos eles ao anel principal [76]. Em sistemas de distribuição complexos, pode ocorrer a combinação entre estas configurações.



## APÊNDICE C – Aquisição de imagem digital

Um sistema que tem por objetivo capturar uma imagem de uma cena e transformá-la em uma imagem digital que possa ser operado em um computador, normalmente segue as etapas na Figura 84.



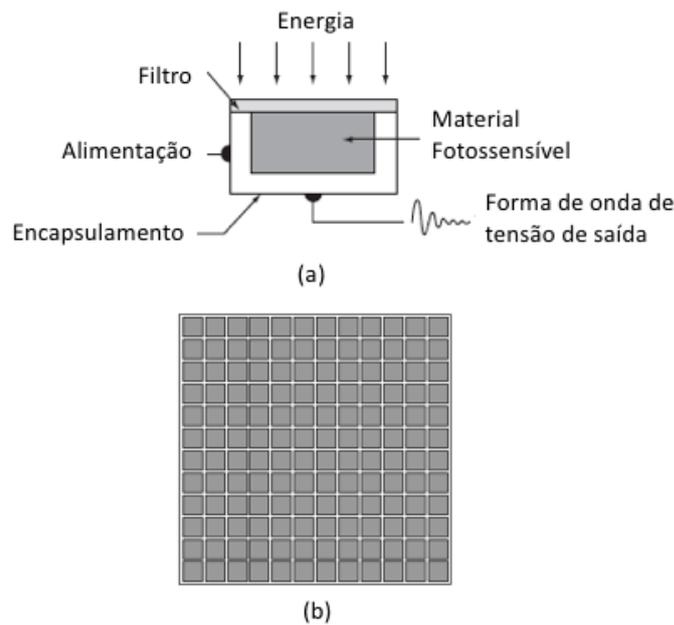
**Figura 84** – Diagrama Ilustrativo do processo de aquisição de uma imagem digital. Fonte: Próprio Autor.

Conforme apresenta a Figura 84, basicamente o sistema utiliza um modelo de uma fonte de luz refletida em determinados comprimentos de onda  $\lambda$  em determinadas intensidades. Esta luz incide em um sensor capaz de emitir uma forma de onda de tensão de saída  $v$  que seja proporcional a esta luminosidade incidente. Na etapa seguinte, o sinal passa por um processo de filtragem para garantir a sensibilidade nas regiões do espectro de luz visível  $v_r, v_g, v_b$ , gerando na saída um sinal contínuo. Posteriormente este sinal precisa ser amostrado e quantizado, o que torna a informação digital. No final do processo, esta informação, que varia ao longo do tempo, precisa ser registrada em um instante de tempo  $t_i$ . Este registro é a imagem digital.

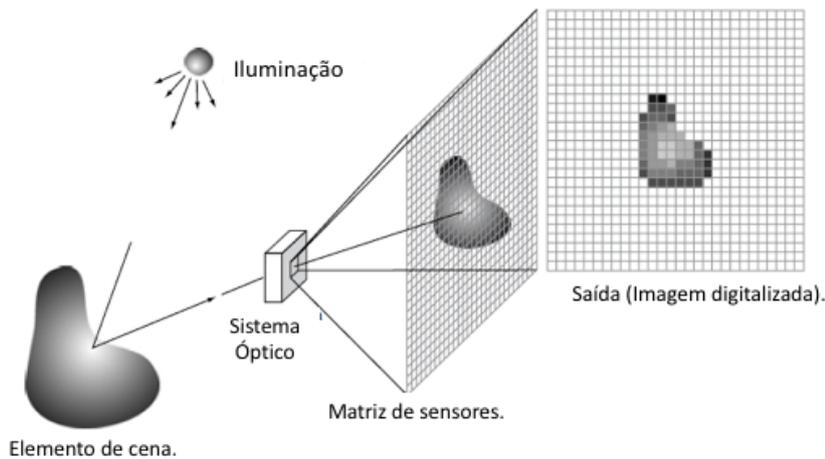
O processo de aquisição de imagens pode ser realizado através da construção de um dispositivo com base em matrizes de pequenos sensores eletro-ópticos [44]. A estrutura básica do dispositivo e o respectivo arranjo entre os sensores são apresentados na Figura 85.

Conforme [44], uma imagem pode ser definida como uma função bidimensional  $f_l(x, y)$ , onde  $x$  e  $y$  são coordenadas espaciais (planas) e a amplitude de  $f_l$  em qualquer par de coordenadas  $(x, y)$  é chamada intensidade ou nível de luminosidade da imagem naquele ponto. Ainda conforme [44], se  $x, y$ , e os valores de amplitude de  $f_l$  são todas as quantidades finitas e discretas, chamamos a imagem de uma imagem digital. A principal maneira na qual estes sensores são utilizados está apresentada na Figura 86.

Segundo [44], a Figura mostra a energia proveniente de uma fonte de luz sendo refletida em um elemento da cena. Neste exemplo, onde os sensores coincidem com o plano focal, a primeira função desempenhada pelo sistema consiste em coletar a energia de entrada proveniente da reflexão da luz sobre a cena e da porção da luz do ambiente e concentrá-la no plano da imagem. Conseqüentemente, os sensores respondem com uma forma de onda de tensão de saída proporcional à integral da luz recebida em cada sensor. Ainda segundo [44], após este processo, os circuitos analógicos e digitais efetuam uma varredura em todos estes sinais, convertendo-os em



**Figura 85** – Sensor eletro-óptico para aquisição de imagens. (a) Sensor (b) Matriz de sensores. Adaptado de [23]



**Figura 86** – Exemplo de um processo de aquisição de uma imagem digital. Adaptado de [23]

um sinal de vídeo, que são então amostrados e digitalizados por outra seção do sistema óptico de aquisição, tendo por fim, uma imagem digitalizada na saída do sistema.

Um modelo simples, considera que quando uma imagem é gerada por um processo físico, seus valores  $f_l(x, y)$  são proporcionais à energia irradiada por uma fonte física (ex: ondas eletromagnéticas). Como consequência,  $f_l(x, y)$  precisa assumir valores finitos e estritamente positivos [44], assim:

$$0 < f_l(x, y) < \infty \quad (\text{C.1})$$

Este modelo depende de duas componentes: uma é a quantidade de luminosidade sobre

a cena, a outra é a quantidade de luz refletida na cena. Estas características do modelo são descritas como a iluminação  $i(x, y)$  e a refletância  $r(x, y)$  respectivamente, como produto de  $f_l(x, y)$  [44]. Logo, a luminosidade  $l$  é definida como:

$$l = f_l(x, y) = r(x, y) \cdot i(x, y) \quad (\text{C.2})$$

onde,

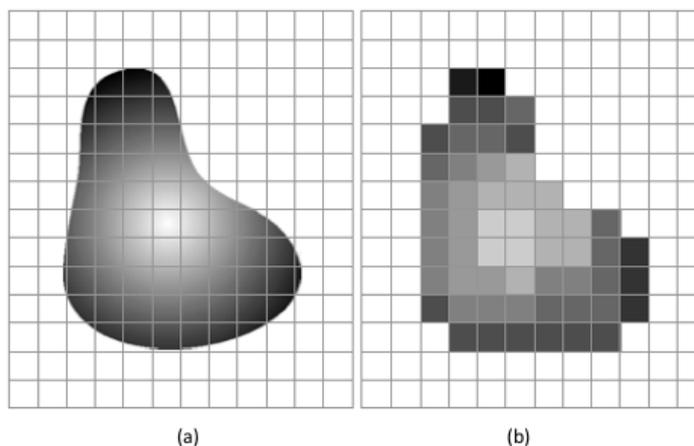
$$0 < r(x, y) < 1 \quad (\text{C.3})$$

$$0 < i(x, y) < \infty \quad (\text{C.4})$$

Ainda segundo [44], os valores de luminosidade em um sistema monocromático variam entre 10 e 1000, assim, alguns autores fazem com que o valor de intensidade varie entre 0 e  $L - 1$ , onde 0 é branco e  $L - 1$  é preto, e os valores intermediários são intensidades de cinza. Assim, o intervalo entre os valores mínimos e máximo de luminosidade são chamados de escala de cinza.

Na etapa final do processo de formação da imagem digital, esta faixa de valores analógicos passa por um processo de amostragem e quantização que torna a imagem digital. Segundo [44], quando uma matriz de sensores é utilizada para efetuar a aquisição de uma imagem digital, o número de sensores é o fator que delimita a amostragem em ambas as direções do plano da imagem. Já a quantização define-se pela discretização da faixa dos valores mínimo e máximo de luminosidade para cada sensor. Neste contexto, o pixel pode ser definido como a unidade mínima da imagem digital que carrega estas informações.

A Figura 87 apresenta a diferença entre a imagem contínua projetada sobre o plano da matriz de sensores e a imagem digital.



**Figura 87** – Digitalização de uma imagem. (a) Imagem analógica. (b) Imagem digital. Adaptado de [23]

As imagens também podem ser classificadas em imagens coloridas, em escala de cinza ou binárias. Em muitos casos, estas opções podem ser configuradas nos equipamentos que efetuam a aquisição das imagens. As imagens coloridas podem ser representadas por tabelas de cores ou

por modelos de cores. Nestes modelos de cor, cada pixel é representado por 3 bytes que carregam informações distintas e cuja informação da tonalidade resulta da combinação entre elas. Já as imagens em escala de cinza tem um valor limitado de 1 byte para cada pixel onde 0 indica a cor preta, 255 indica a cor branca e os números do intervalo são as variações de tons de cinza entre o branco e o preto. No caso das imagens binárias, o pixel é representado por um único bit, que pode assumir o valor 0 para a cor preta ou o valor 1 para a cor branca.

No caso do modelo de cores RGB (red, green, blue) o pixel é representado por 24 bits (3 bytes) no qual cada byte representa a intensidade de cor vermelha, verde e azul de cada respectivo pixel. No modelo de cores YCbCr (Luminância, crominância de verde, crominância de azul), o pixel é representado de forma similar, onde cada byte representa intensidade de luminância, crominância de verde e crominância de azul.