

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Alcides Andrade Neto

**Identificação de Mosquitos *Aedes aegypti* / *albopictus* Utilizando
Visão Computacional**

Fortaleza – CE

13 de abril de 2021

Alcides Andrade Neto

Identificação de Mosquitos *Aedes aegypti* / *albopictus* Utilizando Visão Computacional

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Processamento de Imagens e Sinais

Orientador: Francisco Nivando Bezerra

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

13 de abril de 2021

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

- A554i Andrade Neto, Alcides.
 Identificação de Mosquitos *Aedes aegypti* / *albopictus* Utilizando Visão Computacional / Alcides
Andrade Neto. - 2021.
 89 f. : il. color.
- Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus
Fortaleza, 2021.
 Orientação: Prof. Dr. Francisco Nivando Bezerra.
1. identificação de mosquitos. 2. *aedes aegypti*. 3. *aedes albopictus*. 4. visão computacional. I. Título.

CDD 004



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
Av. 13 de maio, 2081 - Bairro Benfica - CEP 60040-531 - Fortaleza - CE - www.ifce.edu.br

DECLARAÇÃO

ALCIDES ANDRADE NETO

Identificação de Mosquitos *Aedes aegypti* / *albopictus* Utilizando Visão Computacional

Dissertação submetida à Coordenação do Curso de Pós-graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para a obtenção do título de mestre em Ciência da Computação, área de concentração Sistemas de Computação.

Aprovada em 30/03/2021.

BANCA EXAMINADORA

Prof. Dr. Francisco Nivando Bezerra (Orientador)

Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. Guilherme de Alencar Barreto

Universidade Federal do Ceará - UFC



Documento assinado eletronicamente por **Guilherme de Alencar Barreto, Usuário Externo**, em 06/04/2021, às 15:42, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Francisco Nivando Bezerra, Professor do Ensino Básico, Técnico e Tecnológico**, em 06/04/2021, às 15:48, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Pedro Pedrosa Rebouças Filho, Professor do**



A autenticidade do documento pode ser conferida no site https://sei.ifce.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0 informando o código verificador **2498772** e o código CRC **5F4D7D59**.

*Este trabalho é dedicado ao meu avô Guido Ponte,
que infelizmente nos deixou precocemente no ano de 2020,
um ser humano maravilhoso o qual sempre terá meu respeito e admiração.
A ele, dedico todas as minhas conquistas.*

Agradecimentos

A conclusão deste trabalho somente foi possível devido a colaboração de algumas pessoas que direta ou indiretamente me apoiaram nesta trajetória. A estes, agradeço.

À minha noiva Dalva Azevedo, por ter me apoiado diariamente durante todo este trajeto de minha vida acadêmica e profissional, e pela grande ajuda na área de entomologia e manipulação dos espécimes de mosquitos, que foram fundamentais para a realização deste projeto de pesquisa.

Aos meus amigos Carlos Estevão e Mateus Alves, pela amizade e o tanto que contribuíram no desenvolvimento desta pesquisa e na publicação do artigo.

Ao Instituto Federal de Educação Ciência e Tecnologia do Ceará (IFCE) que me proporcionou a oportunidade de cursar este Mestrado, em especial, aos professores do IFCE - Campus Camocim, André Luiz e Gilson Soares que me apoiaram e viabilizaram o afastamento de minhas funções durante o curso.

Ao professor Nivando Bezerra que me orientou durante todo este período. Agradeço pelos ensinamentos e contribuições que foram valiosos para meu crescimento acadêmico, profissional e pessoal. Agradeço a paciência e toda serenidade, que me foi tão necessária para lidar com as dificuldades que tive durante esta etapa.

Aos professores do Programa de Pós-Graduação em Ciência da Computação (PPGCC) pela manutenção do curso e pelos conhecimentos transmitidos durante as disciplinas.

E por fim, agradeço aos profissionais da Unidade de Vigilância de Zoonoses da cidade de Sobral-CE, e do Núcleo de Controle de Vetores (NUVET) de Fortaleza-CE, nas pessoas de Nayara Amorim e Lindemberg Caranha, por terem fornecido todo material entomológico necessário para a realização desta pesquisa.

*“A lâmina mais forte é aquela que pode proteger o que você quer proteger
e cortar aquilo que você quer cortar.”
(Koushirou)*

Resumo

Segundo a Organização Mundial da Saúde estima-se que a dengue afeta 390 milhões de pessoas por ano. Somente no Brasil, no ano de 2020 foram notificados 979.764 casos prováveis de dengue. Os principais vetores responsáveis pela disseminação da dengue são os mosquitos *Aedes aegypti* e *Aedes albopictus*. Além da dengue eles também transmitem outras doenças como *chikungunya*, *zika* e febre amarela. Uma ferramenta que identifique as espécies de mosquitos, poderia ser uma forma de colaborar com os centros de zoonoses no controle dessas doenças. Nesta dissertação é proposta uma metodologia para classificar mosquitos através da espécie e sexo por intermédio do uso de imagens associadas às técnicas de processamento digital de imagens. Após a aquisição das amostras de mosquitos, são criadas três bases de dados utilizando uma câmera de smartphone, uma câmera macro, e uma câmera *digital single Lens reflex*. As técnicas *auto color correlogram* (ACC), *gray level co-occurrence matrix* (GLCM) e momentos de Hu são aplicadas para extrair características das imagens, e em seguida empregados os classificadores *support vector machine* (SVM), *random forest* (RF), *k-nearest neighbors* (KNN) e *multilayer perceptron* (MLP). Ao todo, são classificadas 800 imagens divididas em quatro classes e em três bases de dados. Como resultado, constatou-se que a melhor metodologia utiliza *gray level co-occurrence matrix* e *random forest*, no qual foi possível obter uma acurácia média de 97,55% nas três bases de dados.

Palavras-chave: *aedes aegypti*, *aedes albopictus*, identificação de mosquitos, visão computacional.

Abstract

According to the World Health Organization, dengue is estimated to affect 390 million people per year. In Brazil alone, in 2020, 979.764 probable dengue cases were reported. The main vectors involved in the spread of dengue are the mosquitoes of the species *Aedes aegypti* and *Aedes albopictus*. In addition to dengue they also transmit other diseases such as chikungunya, zika and yellow fever. A tool that identifies the species of mosquitoes could be a way to collaborate with the zoonosis centers in the control of these diseases. In this dissertation, a methodology is proposed to classify mosquitoes by species and sex, through the use of images associated with digital image processing techniques. After acquiring mosquito samples, three databases are created using a smartphone camera, a macro camera and a digital single lens reflex camera. The auto color correlogram, gray level co-occurrence matrix and Hu moments techniques are applied to extract characteristics from the images, and then are used the support vector machine, random forest, k-nearest neighbors and multilayer perceptron classifiers. In all, 800 images divided into four classes and three databases are classified. As a result, it was found that the best methodology uses gray level co-occurrence matrix and random forest, in which an average accuracy of 97,55% in the three databases could be obtained.

Keywords: mosquito identification, computer vision. *aedes aegypti*, *aedes albopictus*.

Lista de ilustrações

Figura 1 – Morfologia geral básica do mosquito fêmea. Na figura, asa e pernas esquerdas estão omitidas. Os oito segmentos abdominais não são visíveis em todas as espécies. Todos os tarsos têm cinco artículos denominados tarsômeros.	33
Figura 2 – <i>Aedes aegypti</i> macho e fêmea.	33
Figura 3 – Principal diferença morfológica de <i>Aedes aegypti</i> e <i>Aedes albopictus</i>	34
Figura 4 – Curva epidêmica dos casos prováveis de dengue no Brasil de 2019 e 2020.	35
Figura 5 – Gráfico de número de casos prováveis de dengue, <i>chikungunya</i> e <i>zika</i> , Brasil, 2015 a 2020.	36
Figura 6 – Etapas fundamentais em visão computacional	37
Figura 7 – Exemplo de construção da matriz de coocorrência	39
Figura 8 – Exemplo de hiperplanos do SVM.	42
Figura 9 – Exemplo ilustrativo de um classificador do tipo <i>random forest</i>	43
Figura 10 – Representação de uma rede <i>MultiLayer Perceptron</i>	44
Figura 11 – Fluxograma da metodologia proposta.	47
Figura 12 – Espécimes fornecidos pelo NUVET. As caixas são identificadas com a seguinte descrição: " <i>Aedes aegypti</i> (macho e fêmea). Laboratório de Vetores Reservatório e Animais Peçonhentos Dr. Thomaz Aragão NUVET/COVIG/SESA-CE"	48
Figura 13 – Base utilizada para apoiar os mosquitos.	50
Figura 14 – Metodologia de obtenção das imagens.	51
Figura 15 – Exemplo de imagens capturada com a câmera de <i>smartphone</i>	51
Figura 16 – Exemplo de imagens capturada com a câmera macro.	51
Figura 17 – Exemplo de imagens capturada com a câmera DSLR.	52
Figura 18 – Corte da imagem utilizando limiarização de Otsu.	53
Figura 19 – Exemplo de imagens capturada com a câmera de <i>smartphone</i> após pré-processamento.	53
Figura 20 – Exemplo de imagens capturada com a câmera macro após pré-processamento.	54
Figura 21 – Exemplo de imagens capturada com a câmera digital após pré-processamento.	54
Figura 22 – Imagem 01 do formulário apresentado aos especialistas.	57
Figura 23 – Especialista respondendo ao formulário no laboratório de entomologia da Unidade de Vigilância de Zoonoses da cidade de Sobral-CE.	58
Figura 24 – Matriz de confusão na base de imagens de câmera digital.	66
Figura 25 – Imagens 8 e 11 do formulário aplicado aos especialistas.	70
Figura 26 – Matriz de confusão da classificação dos especialistas.	71

Figura 27 – Gráficos de dispersão dos extratores GLCM e Momentos de Hu. As classes são definidas como: Classe 0 - *Aedes aegypti* Macho; Classe 1 - *Aedes aegypti* Fêmea; Classe 2 - *Aedes albopictus* Macho; e Classe 3 - *Aedes albopictus* Fêmea.72

Lista de tabelas

Tabela 1 – Características dos equipamentos de captura.	49
Tabela 2 – Distribuição das imagens.	52
Tabela 3 – Resultados da classificação da base de câmera macro.....	62
Tabela 4 – Resultados da classificação da base de câmera de <i>smartphone</i>	62
Tabela 5 – Resultados da classificação da base de câmera digital.	63
Tabela 6 – Tempo médio de treino e teste da base de imagens da câmera macro.....	64
Tabela 7 – Tempo médio de treino e teste da base de imagens da câmera de <i>smartphone</i>	65
Tabela 8 – Tempo médio de treino e teste da base de imagens da câmera digital.	65
Tabela 9 – Resultados da classificação binária da base de câmera de <i>smartphone</i>	67
Tabela 10 – Resultados dos testes em que o treinamento utiliza a base de câmera de <i>smartphone</i> e o teste utiliza a base de câmera digital.....	68
Tabela 11 – Apresentação dos dados de trabalhos relacionados à identificação de mosquitos.	73

Lista de abreviaturas e siglas

ACC	Auto Color Correlation
Ae	Aedes
CNN	Convolutional Neural Network
CoHOG	Co-occurrence HOG
C-SVC	C-Support Vector Classification
DSLR	Digital Single Lens Reflex
ECoHOG	Extended CoHOG
EM	Expectation-Maximization
FN	Falso Negativo
FP	Falso Positivo
GLCM	Gray-Level Cooccurrence Matrix
HOG	Histogram of Oriented Gradients
HSV	Hue Saturation Value
KNN	K-Nearest Neighbor
LBFGS	Limited-memory Broyden Fletcher Goldfarb Shanno
LBP	Local Binary Patterns
LDA	Linear Discriminant Analysis
MLP	Multilayer Perceptron
MS	Milissegundos
nu-SVC	nu-Support Vector Classification
NUVET	Núcleo de Controle de Vetores
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagens

RBF	Radial Basis Function
ResNet	Deep Residual Network
RF	Random Forest
RGB	Red Green Blue
SIFT	Scale-Invariant Feature Transform
SMZ	Smart Mosquito Zapper
SURF	Speeded-Up Robust Features
SVM	Support Vector Machine
TN	Verdadeiro Negativo
TP	Verdadeiro Positivo
VGGNet	Visual Geometry Group Network

Lista de símbolos

$\in$	Pertence - Indica que um elemento está em um conjunto
Θ	Theta - Representa a medida de um ângulo
$\geq$	Maior ou Igual - Define que um valor é maior ou igual a outro valor
$\leq$	Menor ou Igual - Define que um valor é menor ou igual a outro valor

Sumário

1	INTRODUÇÃO	25
1.1	Motivação para a Dissertação	26
1.2	Descrição do Problema	26
1.3	Objetivos Geral e Específicos	26
1.4	Produção Científica	26
1.5	Estrutura da Dissertação	27
2	FUNDAMENTAÇÃO TEÓRICA	29
2.1	Trabalhos Relacionados.....	29
2.2	Arboviroses.....	32
2.2.1	Morfologia dos Mosquitos.....	32
2.2.2	Contexto Atual	34
2.3	Visão Computacional	36
2.4	Extratores de Características e Classificadores	37
2.4.1	Extratores de Características	38
2.4.1.1	<i>Auto Color Correlogram</i>	38
2.4.1.2	<i>Gray Level Co-occurrence Matrix</i>	38
2.4.1.3	Momentos de Hu	40
2.4.2	Classificadores.....	40
2.4.2.1	<i>K-Nearest Neighbor</i>	40
2.4.2.2	<i>Support Vector Machine</i>	41
2.4.2.3	<i>Random Forest</i>	43
2.4.2.4	<i>Multilayer Perceptron</i>	44
3	MATERIAIS E MÉTODOS	47
3.1	Aquisição das Imagens	48
3.2	Pré-Processamento.....	52
3.3	Extração de Características	54
3.4	Classificação.....	55
3.4.1	Classificação Única	55
3.4.2	Classificação Binária.....	55
3.4.3	Classificação Composta	56
3.5	Classificação Visual por Especialistas	56
3.6	Avaliação de Desempenho	58
3.7	Ambiente de Pesquisa.....	59

4	RESULTADOS E DISCUSSÕES	61
4.1	Resultados Obtidos na Classificação Única	61
4.1.1	Resultados de Tempo	64
4.1.2	Matriz de Confusão	65
4.2	Resultados Obtido pela Classificação Binária.....	67
4.3	Resultados Obtido pela Classificação Composta.....	68
4.4	Resultados Obtido pela Classificação Visual dos Especialistas.....	69
4.4.1	Matriz de Confusão	71
4.5	Análise Geral dos Resultados	72
5	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS .	75
5.1	Conclusões.....	75
5.2	Sugestões para Trabalhos Futuros	75
	REFERÊNCIAS	77
	ANEXOS	81
	ANEXO A – FORMULÁRIO DE IDENTIFICAÇÃO DE MOSQUI- TOS ATRAVÉS DE IMAGENS	83

1 Introdução

Estima-se que bilhões de pessoas estejam vivendo em áreas com risco de infecção pela dengue. Considerada pela Organização Mundial da Saúde (OMS) uma doença negligenciada, a dengue afeta quase 120 países, tendo alta incidência em alguns deles (HALSTEAD, 2007). Uma estimativa mundial indica 390 milhões de infecções por vírus da dengue por ano, dos quais 96 milhões se manifestam clinicamente com alguma gravidade da doença (WHO et al., 2020). De acordo com o estudo sobre a prevalência da dengue (BRADY et al., 2012), acredita-se que, 3,9 bilhões de pessoas estão em risco de infecção por este vírus.

No Brasil, um país tropical onde a temperatura e umidade facilitam a proliferação do mosquito vetor, os primeiros casos foram registrados e identificados no ano de 1986 na cidade do Rio de Janeiro (SCHATZMAYR et al., 1986). Somente em 2020 foram notificados 979.764 casos prováveis de dengue (Ministério da Saúde, 2020a). Além da dengue, a *chikungunya*, *zika* e febre amarela são transmitidas por duas espécies de mosquitos do gênero *Aedes*, sendo eles, *Aedes aegypti* e *Aedes albopictus*.

O *Aedes aegypti* é um mosquito de ambiente urbano e intradomiciliares que utiliza recipientes artificiais para se reproduzir, e se alimenta preferencialmente de sangue humano. O *Aedes albopictus* por sua vez pode ser localizado mais comumente em ambientes periurbanos e rurais, alimentando-se do sangue de uma variedade de espécies de mamíferos, incluindo humanos e aves (KRAEMER et al., 2015).

As fêmeas adultas destes mosquitos desenvolvem seus ovos se alimentando de sangue humano (NETO, 1997), fazendo com que elas sejam as responsáveis por transmitir doenças às pessoas. Além disto, uma vez infectada, a fêmea é capaz de transmitir o vírus para seus descendentes que também serão capazes de infectar seres humanos quando forem fêmeas adultas (BARRETO; GUEDES; SOUZA, 2008).

Identificar as espécies e o sexo destes mosquitos pode ajudar a melhor compreender os aspectos ecológicos e epidemiológicos dos vetores, auxiliar na vigilância e controle de doenças, além de contribuir com estudos e trabalhos que lidam com essas espécies de mosquitos. Equipamentos de captura de imagens, como *smartphones* e câmeras digitais, unidos à visão computacional são capazes de auxiliar nesta tarefa.

Alguns trabalhos encontrados na literatura realizam a classificação de espécies de mosquitos como no trabalho de Minakshi, Bharti e Chellappan (2018) e Huang et al. (2018), enquanto em outro trabalho como o de Fuchida et al. (2017) propõe distinguir mosquitos de outros insetos como abelhas e moscas. O presente trabalho diferencia-se dos demais encontrados na literatura, além dos resultados, pela classificação do sexo desses mosquitos, fator importante, pois a fêmea é a responsável pela transmissão de doenças.

1.1 Motivação para a Dissertação

Para diminuir a propagação de doenças como dengue, *chikungunya*, *zika* e febre amarela é necessário combater os vetores que as transmitem. Uma fase crucial deste objetivo é identificar as espécies de mosquitos existentes na região de interesse.

Atualmente, os mosquitos são capturados através de armadilhas e posteriormente identificados. Profissionais treinados realizam a identificação visualmente com ajuda de um microscópio. Centenas de mosquitos podem ser capturados em um único dia, fazendo com que o trabalho de identificação possa durar várias horas, desta forma, a classificação deles se torna uma tarefa exaustiva e propensa ao erro.

1.2 Descrição do Problema

Construir bases de imagens de mosquitos das espécies *Aedes aegypti* e *Aedes albopictus* do sexo masculino e feminino utilizando diferentes equipamentos de captura. Propor uma metodologia capaz de classificar os espécimes fotografados, distinguindo-os entre espécie e sexo. Objetivando identificar quais são os mosquitos capazes de transmitir doenças para os seres humanos.

1.3 Objetivos Geral e Específicos

O objetivo geral deste estudo é criar um sistema de visão computacional capaz de analisar imagens de mosquitos das espécies *Aedes aegypti* e *Aedes albopictus* e classificá-las corretamente em espécie e sexo.

Em seu sentido mais particular, os objetivos específicos estão listados abaixo:

- Construir três bases de imagens utilizando diferentes equipamentos de captura.
- Adquirir os conjuntos de dados das imagens a partir de extratores de características.
- Utilizar algoritmos de aprendizado de máquinas com o intuito de classificar os dados obtidos.
- Analisar a influência da qualidade de imagem dos equipamentos de captura na classificação das imagens de mosquitos.

1.4 Produção Científica

Durante este projeto de pesquisa, o seguinte trabalho científico foi aceito e publicado.

- Neto, A. A., Bezerra, F. N., Sousa, C. E. B., Neto, M. A. V., e Silva, J. H. A., de Azevedo, D. A. A. Identification of the *Aedes aegypti*/*albopictus* Mosquito

Using Digital Image Processing Techniques. In 2020 IEEE 5th International Conference on Signal and Image Processing (ICSIP), p. 518-523, 2020.

1.5 Estrutura da Dissertação

O restante desta dissertação está dividido em 5 capítulos distribuídos da seguinte forma:

- **Capítulo 2:** São apresentados os conceitos fundamentais da arte que envolvem este estudo. Serão explanados a morfologia dos mosquitos estudados e as doenças que eles transmitem. Serão abordados os conceitos de visão computacional que apoiam este trabalho. E por fim, será apresentada a fundamentação teórica dos extratores e classificadores utilizados neste estudo.
- **Capítulo 3:** Apresenta a metodologia utilizada neste trabalho.
- **Capítulo 4:** Apresenta os resultados obtidos a partir da metodologia proposta.
- **Capítulo 5:** Serão apresentadas as conclusões obtidas e inseridas novas propostas para trabalhos futuros.

2 Fundamentação Teórica

Neste capítulo será abordada a teoria dos principais assuntos que compõe esta dissertação. Inicialmente será versado sobre alguns trabalhos recentes encontrados na literatura que tratam de classificação de mosquitos. Em seguida, será mostrado as principais características morfológicas dos mosquitos e os casos atuais de incidência de arboviroses no Brasil. Por fim, será mostrado um olhar geral sobre visão computacional e a definição dos extratores de características e classificadores utilizados neste trabalho.

2.1 Trabalhos Relacionados

Minakshi, Bharti e Chellappan (2017) propõem um trabalho para identificação de espécies de mosquitos no qual foi criado uma base de 60 imagens, capturadas através de um *smartphone*, contendo 7 espécies de mosquito, sendo elas: *Culex nigripalpus*, *Anopheles quadrimaculatus*, *Mansonia titillans*, *Psorophora columbiae*, *Anopheles crucians*, *Psorophora ferox* e *Coquillettidia perturbans*.

A partir das imagens, os autores aplicaram filtros de mediana para remover os ruídos das imagens e preservar as bordas e limites. Além disso cada imagem teve seu tamanho reduzido para evitar sobrecarga de processamento. Para os autores, alguns aspectos importantes para a identificação das espécies de mosquitos trabalhados são as cores das asas e das pernas dos espécimes. Desta forma, as características das imagens foram extraídas através dos valores das cores vermelha, verde e azul (RGB, do inglês *red, green, blue*) de cada imagem.

Para limitar o número de atributos utilizados na fase de classificação, foi utilizada a seleção de atributos do algoritmo *information gain* aplicado a cada vetor de atributos. Para classificar as imagens, foi utilizado *random forest* nos atributos selecionados e posteriormente para avaliar o modelo foram utilizadas as métricas de validação cruzada *k-fold*, cujo valor de *K* é igual a 10, e com as métricas *recall*, precisão e *f1-score*.

O resultado do experimento gerou um *recall* médio de 83,3% e a média de precisão foi de 84,5%. Das sete espécies classificadas, o *f1-score* para cinco delas foi acima de 83%. O tempo de treino do modelo foi menor do que 5 segundos e o tempo de teste foi menor do que 1 segundo.

Um segundo trabalho de Minakshi, Bharti e Chellappan (2018) é uma melhoria do estudo anterior. Neste, a quantidade de espécies de mosquitos aumentou para 9 e foram utilizadas 303 imagens. As espécies trabalhadas neste estudo são: *Aedes aegypti*, *Aedes infirmatus*, *Aedes taeniorhynchus*, *Anopheles crucians*, *Coquillettidia perturbans*, *Culex*

nigripalpus, *Mansonia titillans*, *Psorophora columbiae* e *Psorophora ferox*.

Assim como o trabalho anteriormente apresentado dos autores, estas novas imagens foram redimensionadas e submetidas ao filtro de mediana para remoção de ruído. Uma nova etapa acrescentada foi a segmentação do objeto de interesse da imagem. Para a segmentação, o contorno do mosquito foi identificado na imagem, e posteriormente foi aplicado o filtro de Sobel para categorizar a região do fundo e do mosquito que estiver dentro do contorno inicialmente encontrado. O ajuste final para a remoção do fundo da imagem consiste em um modelo probabilístico que pressupõe que os *pixels* de fundo são gerados a partir de uma mistura gaussiana, desta forma utilizou-se um limiar para determinar se o *pixel* analisado é ou não pertencente ao fundo da imagem.

Para a extração de características das imagens, foi utilizado o espaço de cor CIELAB, diferentemente do RGB anteriormente apresentado pelos autores. Foram utilizados em conjunto os extratores *local binary patterns* (LBP) e *gray level co-occurrence matrix* (GLCM) para geração dos vetores de atributos.

Para seleção dos atributos, foi utilizado *linear discriminant analysis* (LDA), que reduziu a quantidade de atributos utilizados em 79,5%. A classificação ocorreu em duas etapas, a primeira utiliza um algoritmo de aprendizagem não supervisionado chamado *expectation-maximization* (EM) para agrupar amostras de imagens ainda não rotuladas. Com isso foi possível identificar dois grupos, o das imagens do *Aedes aegypti* e *Psorophora columbiae*. As outras 7 classes foram identificadas utilizando *support vector machines* (SVM).

A classificação utilizando o algoritmo de aprendizagem não supervisionado obteve uma taxa de 100%. Enquanto o SVM, utilizando a técnica de validação cruzada *k-fold* com o valor de *K* igual a 10, conseguiu uma precisão de 71,07% para identificação das sete espécies. Combinando a classificação do SVM com 100% de precisão para duas outras espécies, é possível alcançar a uma acurácia geral de 90,03% para todas as nove espécies.

Um outro estudo de autoria de Okayasu et al. (2019) classifica mosquitos de três espécies utilizando 12 extratores de características em conjunto com o classificador SVM e o compara com a classificação utilizando três arquiteturas de *deep learning*. A base de imagens utilizada é composta por 14.400 imagens, capturadas com dois equipamentos diferentes e divididas em três classes, sendo elas *Aedes albopictus*, *Anopheles stefensi* e *Culex pipiens pallens*.

Para as características de forma foram utilizados os extratores *speeded-up robust features* (SURF), *scale-invariant feature transform* (SIFT), *dense SIFT*, *histogram of oriented gradients* (HOG), *co-occurrence HOG* (CoHOG), *extended CoHOG* (ECoHOG), e *local binary pattern* (LBP). Para características de cor, foram calculados os histogramas coloridos em cada sistema de cor RGB, *hue saturation value* (HSV) e CIELAB. Para

características de textura foi utilizado GLCM e para frequência foi utilizado GIST. Para a classificação dos dados obtidos através dos extratores citados, foi empregado o SVM.

O uso de *deep learning* foi baseado na *convolutional neural network* (CNN) e utilizou três arquiteturas, a AlexNet, a *visual geometry group network* (VGGNet) e a *deep residual network* (ResNet). Os autores aplicaram transformações de rotação, brilho, contraste, saturação e tonalidade nas imagens para evitar *overfitting* devido aos ruídos na área de fundo. A classificação convencional obteve acurácia máxima de 82,4% ao utilizar o extrator SIFT. Já com *deep learning* foi possível obter acurácia de 95,5% com a arquitetura ResNet.

Fuchida et al. (2017) propõem uma metodologia para distinguir mosquitos de outros insetos, como abelhas e moscas, através de extração de características morfológicas, como tamanho do corpo e pernas, e classificação utilizando três variáveis do SVM. As imagens foram adquiridas através de uma câmera digital e em *sites* de imagens, totalizando 400 imagens divididas em 3 classes, sendo elas: mosquitos, moscas e abelhas. O primeiro passo é realizar a segmentação dela utilizando o algoritmo de corte gráfico juntamente com o filtro de Sobel, isolando assim, o objeto de interesse do fundo da imagem.

Os autores propõem um método de extração de características que representa tanto a cor quanto as características morfológicas das imagens adquiridas dos insetos. Inicialmente os autores extraem o histograma de cor de cada imagem, posteriormente segmentam as imagens nas regiões de tronco e perna. Algoritmos para calcular a distância são utilizados para determinar a largura do tronco até as pernas dos mosquitos. Essas distâncias em conjunto com o histograma de cor irão compor o vetor de atributos das imagens. Os autores pressupõem que os insetos pertencentes as mesmas classes tem o mesmo tamanho nas imagens.

Os atributos extraídos são rotulados e inseridos em três variantes do classificador SVM. Foi utilizado o *c-support vector classification* (C-SVC) e o *nu-support vector classification* (nu-SVC). Com o módulo C-SVC, foi realizada a classificação utilizando a função base linear e *radial basis function* (RBF) como funções do *kernel*, para a variante nu-SVC foi utilizado o *kernel* RBF.

Para a identificação de mosquitos, foi obtida uma acurácia de 98,9% ao utilizar a variante nu-SVC com *kernel* RBF. Já para a identificação de outros insetos a acurácia chegou a 97,6% quando utilizada a variante C-SVC com *kernel* RBF.

Huang et al. (2018) criaram um estrutura própria para capturar imagens de mosquitos, chamada de *smart mosquito zapper* (SMZ). Neste trabalho eles classificaram duas espécies de mosquitos. Parte das imagens foi obtida em ambiente controlado (laboratório) e a outra parte foi adquirida em uma zona rural através do dispositivo próprio de captura.

O equipamento construído pelos autores é composto por um microprocessador

Raspberry Pi 3 modelo B e uma câmera Sony IMX219, todos acoplados a uma estrutura de plástico construída em uma impressora 3D. O dispositivo funciona como uma armadilha que filma o momento em que os mosquitos entram no artefato. As imagens capturas pelo SMZ tem seu fundo removido subtraindo da imagem do *frame* anterior e é aplicado um limiar para detectar os mosquitos nas imagens. Posteriormente as imagens são enviadas para um servidor que irá aplicar filtros de suavização de ruídos. O sistema classifica dois gêneros de mosquitos, sendo elas *Aedes* e *Culex*.

A classificação ocorreu utilizando CNN em dois conjuntos de dados, o primeiro utilizando uma base de imagens mista, em que parte das imagens utilizadas são fornecidas pelo SMZ e o restante são imagens obtidas em laboratório. O segundo conjunto de dados utiliza apenas imagens de mosquitos em laboratório. Desta forma foi possível obter 98% de acurácia nos dados de validação e 90,5% nos dados de teste.


2.2 Arboviroses

A dengue, *chikungunya*, *zika* e febre amarela, chamadas de arboviroses, são doenças causadas por vírus transmitidas aos humanos por mosquitos, essencialmente *Aedes aegypti* e *Aedes albopictus*. Esses insetos fazem parte da família *Culicidae*, subfamília *Culicinae* a qual engloba várias espécies que desempenham o papel de vetores de diferentes organismos parasitários, portanto, importantes para a saúde pública (JONES et al., 2020).

2.2.1 Morfologia dos Mosquitos

O corpo dos mosquitos adultos é dividido em cabeça, tórax e abdome. Órgãos dos sentidos como olhos, antenas e palpos encontram-se na cabeça. No tórax, as patas e asas e no abdome encontram-se grande parte dos órgãos internos como o de digestão e o de reprodução (Figura 1). Os últimos segmentos do abdome são modificados para formar as genitálias e são fundamentais para a identificação (CONSOLI; OLIVEIRA, 1998).


Figura 1 – Morfologia geral básica do mosquito fêmea. Na figura, asa e pernas esquerdas estão omitidas. Os oito segmentos abdominais não são visíveis em todas as espécies. Todos os tarsos têm cinco artículos denominados tarsômeros.



Fonte: Marcondes (2011).

Para diferenciar mosquitos machos e fêmeas, utiliza-se convencionalmente as seguintes características: o tamanho, o tipo da antena e os palpos maxilares. Os machos são menores do que as fêmeas e possuem antenas plumosas, além disso os palpos maxilares têm o comprimento igual ou maior do que o da probóscida. As fêmeas possuem antenas pilosas e seus palpos maxilares são curtos, como exibido na Figura 2 (MARCONDES, 2011).


Figura 2 – *Aedes aegypti* macho e fêmea.



Fonte: Göldi (1905).

A principal diferença morfológica entre *Ae. aegypti* e *Ae. albopictus* está no dorso (escudo) dos mosquitos. O primeiro apresenta um desenho de uma lira no dorso e o segundo uma única listra branca longitudinal (Figura 3). Além disso o *Ae. Albopictus* possui clipeo com escamas escuras ao contrário do *Ae. Aegypti* que possui clipeo com escamas brancoprataeadas e unhas tarsais femininas denteadas, pelo menos nas pernas anteriores e médias (CONSOLI; OLIVEIRA, 1998), (MARCONDES, 2011).

Figura 3 – Principal diferença morfológica de *Aedes aegypti* e *Aedes albopictus*.



Fonte: Planeta Invertebrados Brasil¹.

Atualmente para identificar as diferentes espécies de mosquitos os especialistas utilizam as chaves de identificação. Em geral, as chaves de identificação são construídas segundo o método da divisão lógica, em que duas alternativas mutuamente exclusivas sobre as características morfológicas de um exemplar são apresentadas ao leitor.

2.2.2 Contexto Atual


O Brasil se caracteriza como um local adequado para a existência desses vetores e consequentemente a ocorrência das arboviroses, visto que a maior parte do país possui clima tropical (LOPES; NOZAWA; LINHARES, 2014).

No ano de 2020, foram notificados 979.764 casos prováveis de dengue, destes 541 vieram a óbito. Observa-se que até a segunda semana do mês de março de 2020 a curva epidêmica dos casos prováveis é maior que o número de casos do mesmo período para o ano de 2019 (Figura 4). Entretanto, a partir da terceira semana de março ocorreu uma redução dos casos prováveis comparando com o ano de 2019. Provavelmente essa redução se deve

¹ Disponível em: <http://www.planetainvertebrados.com.br/index.asp?pagina=artigos_ver&id=119>; Acesso em setembro. 2020.

ao atraso ou subnotificação para os casos de arboviroses devido ao empenho das equipes de vigilância epidemiológica estaduais no enfrentamento emergencial da pandemia do coronavírus (Covid-19). Quanto a *chikungunya* e *zika*, no ano de 2020, o Brasil apresentou 80.914 e 7.119 casos prováveis, respectivamente (Ministério da Saúde, 2020a).

Figura 4 – Curva epidêmica dos casos prováveis de dengue no Brasil de 2019 e 2020.




Fonte: Ministério da Saúde (2020a).

A febre amarela possui dois ciclos de transmissão: silvestre (quando há transmissão em área rural ou de floresta) e urbano. De acordo com o Ministério da Saúde a febre amarela silvestre é endêmica no Brasil (região amazônica). No restante do país ocorrem ocasionalmente períodos epidêmicos, caracterizando a reemergência do vírus. No período de monitoramento de julho de 2019 a junho de 2020, foram confirmados 19 casos de febre amarela, o primeiro caso humano ocorreu no Pará, posteriormente outro caso foi confirmado no Acre. Na região sul, em Santa Catarina os primeiros casos humanos foram detectados a partir de janeiro de 2020. Ressalta-se que os casos ocorreram em pessoas que não eram vacinadas ou que foram vacinadas na infância, mas não receberam o reforço da vacina (Ministério da Saúde, 2020b).

O gráfico demonstrado na Figura 5 apresenta o número de casos prováveis anuais de dengue, *chikungunya* e *zika* nos últimos cinco anos de acordo com os boletins epidemiológicos divulgados pelo Ministério da Saúde.

Figura 5 – Gráfico de número de casos prováveis de dengue, *chikungunya* e *zika*, Brasil, 2015 a 2020.



Fonte: Autor.

Como visto no gráfico, apesar dos casos sub-notificados no ano de 2020, ainda houve grande incidências de arboviroses em comparação aos anos anteriores.


2.3 Visão Computacional

Visão computacional é a área da computação que trabalha na análise de informações a partir de imagens digitais e algumas vezes é confundida com a área de Processamento de Imagens (PDI). De acordo com Gonzalez e Woods (2009), não existe um acordo geral entre os autores em que o processamento de imagens se diverge de outras áreas relacionadas.

Um conceito utilizado para separar estas duas disciplinas é considerar que no processamento de imagens a entrada de um processo é uma imagem, e a saída é um conjunto de valores que podem ou não compor outra imagem. Ao ponto que, na visão computacional os dados adquiridos são resultados obtidos através de imagens. Logo, a visão computacional é a análise de imagens por computadores com o objetivo de interpretá-las e agir de acordo com parâmetros pré-estabelecidos.

Os sistemas típicos de visão computacional podem ser divididos em etapas de acordo com a Figura 6.

Figura 6 – Etapas fundamentais em visão computacional



Fonte: Gonzalez e Woods (2009).

A aquisição de imagem digital consiste na captura da cena real através de um sensor. De acordo com Gonzalez e Woods (2009), a maioria das imagens digitais são geradas pela combinação de uma fonte de iluminação e a reflexão ou absorção de energia dessa fonte pelos objetos da cena.

No pré-processamento da imagem, a ideia é melhorar a imagem removendo imperfeições geradas pelos equipamentos de captura de imagem ou realçando características relevantes. Com isso várias técnicas de processamento de imagens podem ser utilizadas como recorte da área de interesse, utilização de filtros, redimensionamento, alteração de brilho e contraste, dentre outros (KHIRADE; PATIL, 2015).

Conforme Solomon e Breckon (2000), segmentação em uma imagem é o processo de subdividi-la em múltiplas regiões com o intuito de simplificar sua representação e facilitar a análise. Neste processo, a imagem é dividida em regiões mutuamente exclusivas e que poderão ser associadas a objetos de interesse do problema. A finalidade principal é obter através do contexto da imagem, apenas os objetos relevantes para que estes possam ter suas características identificadas.

Na fase de extração de características, o objetivo é obter características relevantes da imagem para que seja possível identifica-la ou classifica-la. Segundo Lippmann (1989), as características das imagens devem conter informações necessárias para distinguir entre classes, desconsiderar variáveis irrelevantes na entrada e também devem ser limitados em número, para permitir o cálculo eficiente de funções.

Por fim, a Classificação ou Reconhecimento de Padrões é a fase na qual o sistema computacional consegue reconhecer e classificar objetos de interesse na imagem. Segundo Solomon e Breckon (2000), o objetivo da classificação é identificar propriedades, padrões ou características nas imagens e rotula-las em uma classe específica.

2.4 Extratores de Características e Classificadores

Nesta seção, serão apresentados os extratores de características e os classificadores utilizados neste estudo.

2.4.1 Extratores de Características

A extração de atributos das imagens tem o objetivo de obter uma representação relevante das imagens para ser usada na fase de classificação. A representação pode ser feita através de forma, quando o interesse é embasado em características externas como cantos e pontos de inflexão, ou através de regiões, na qual se obtém características dos *pixels* que compõe aquela região sendo possível representar parâmetros estatísticos, cor e textura (ERPEN, 2004).

2.4.1.1 Auto Color Correlogram

O *auto color correlogram* (ACC) foi inicialmente proposto por Huang et al. (1997) e representa um histograma de três dimensões, em que as cores de um par de *pixels* são representadas na primeira e segunda dimensão, e a distância espacial entre estes *pixels* fica representado na terceira dimensão (SILVA et al., 2007). É muito utilizado para indexação e recuperação de imagens.

Este extrator considera a correlação espacial da cor de *pixels* em distâncias variadas. Um correlograma de cores é uma tabela indexada por um conjunto binário de cores, em que uma entrada K para o par (i,j) caracteriza a probabilidade de descobrir um pixel de cor j , na distância K do *pixel* de cor i .

De acordo com Malviya e Ladhake (2016), o ACC leva em consideração todos os *pixels* da cor C_j a uma distância específica de todos os *pixels* da cor C_i para calcular a cor média. A propriedade do ACC inclui a correlação espacial de cores, é utilizado para descrever a distribuição global com a correlação espacial local das cores, e é fácil de processar (HUANG et al., 1997). Este extrator foi concebido com uma variação da distância L_1 , na qual é considerado a diferença absoluta entre os valores, ou seja, a diferença recebe maior relevância se está próxima dos valores iniciais.

Segundo Martins (2016), o principal benefício deste extrator é o fato deste ser tolerante à modificações com relação à aparência e forma causadas por transformações na posição de visualização, aproximação de câmera e oclusão parcial, por exemplo. Também possui alta efetividade na recuperação de imagens baseada em conteúdo, considerando grandes bases de imagens.


2.4.1.2 Gray Level Co-occurrence Matrix

Gray level co-occurrence matrix (GLCM) é um método estatístico para descrição de texturas proposto por Haralick, Shanmugam e Dinstein (1973). A GLCM armazena a probabilidade de que dois valores de intensidade de cinza estejam associados por uma determinada relação espacial. A partir desta matriz de probabilidades, diferentes medidas estatísticas podem ser extraídas.

Considera-se uma imagem como uma matriz de coordenadas com cada célula desta matriz sendo correspondente a um *pixel* da imagem. Este método analisa as coocorrências entre dois pares de *pixels* (duas coordenadas na matriz) através de uma distância d e uma determinada direção Θ . Essa direção Θ por sua vez, pode assumir os valores de 0° , 45° , 90° e 135° . Desta forma, cada célula (i,j) da matriz GLCM representa a quantidade de vezes que dois pixels aparecem na imagem separados por uma distância d .

Na Figura 7 é apresentada um exemplo de construção de uma matriz de coocorrência cuja distancia d é igual a 1. A subfigura a esquerda representa a imagem de entrada e a subfigura a direita representa a matriz de coocorrência equivalente.

Figura 7 – Exemplo de construção da matriz de coocorrência



Fonte: Sheha, Sharwy e Mabrouk (2016).

Após calculada a GLCM, é possível obter 14 medidas estatísticas, porém, de acordo com Baraldi e Pannigiani (1995), apenas seis delas são de fato pertinentes, são elas:

1. **Energia:** Também chamada de segundo momento angular: esta medida determina a uniformidade da textura da imagem.
2. **Entropia:** Representa o grau de desordem de uma imagem.
3. **Contraste:** Calcula a variação de nível de cinza em uma imagem.
4. **Variância:** Representa a heterogeneidade da textura. A variância será maior conforme a diferença entre os valores dos tons de cinza e sua média.
5. **Homogeneidade:** Calcula o quanto a distribuição dos elementos da GLCM está próxima da diagonal principal.
6. **Correlação:** Representa a medida de quão correlacionado está um *pixel* com o seu vizinho.

2.4.1.3 Momentos de Hu

Hu (1962) propôs uma combinação linear de momentos invariantes para figuras geométricas planas utilizadas no processamento de imagens e reconhecimento de padrões. Este conceito utiliza sete momentos, também conhecidos como Momentos Invariantes ou Momentos de Hu, que são invariantes à escala, rotação e translação para descrever formas em objetos das imagens.

Nem sempre os sete momentos irão formar um conjunto de descritores completo para reconhecer um padrão de entrada. Além disso, há uma dificuldade em se implementar o cálculo de momentos em *hardware*, devido a necessidade de calcular operações complexas (MOLZ, 2001). Desta forma, momentos podem ser melhor aproveitados em imagens nas quais o objeto de interesse possua uma forma bem característica.

De acordo com Rodriguez et al. (2016) os sete momentos de Hu estão relacionados à: distribuição no eixo horizontal e vertical, similaridade na variação horizontal, inclinação para cima ou para baixo, inclinação para a esquerda ou direita, tamanho, rotação e translação e inclinação da imagem.

2.4.2 Classificadores

A classificação tem por objetivo identificar a qual grupo pertence um conjunto de características. Para isso, é necessário ter um processo de aprendizagem para que o sistema possa inferir como categorizar os dados. Um algoritmo classificador cria uma fórmula para prever e classificar os dados, que chamamos de Modelo.

Apresenta-se a seguir os classificadores utilizados neste estudo.

2.4.2.1 *K-Nearest Neighbor*

O *k - nearest neighbors* (KNN) (COVER; HART, 1967) é um dos classificadores não paramétricos baseados em distância mais comumente utilizados por gerar bons resultados e ter uma implementação simples.

KNN é um algoritmo que classifica um determinado elemento de acordo com as respectivas classes dos K ($k \geq 1$) vizinhos mais próximos, pertencentes a uma base histórica de treinamento. O algoritmo calcula a distância do elemento de interesse para cada elemento da base de treinamento e então ordena os elementos da base de treinamento do mais próximo ao mais distante. Dos elementos ordenados selecionam-se apenas os K primeiros, que servem como modelo para a regra de classificação (EBRAHIMPOUR; KOUZANI, 2007).

Existem várias funções para calcular a distância entre dois elementos, pode-se destacar algumas delas:

- **Distância Euclidiana:** Correspondente a distância de uma linha reta entre dois pontos em um espaço euclidiano. É a distância mais utilizada.
- **Distância de Manhattan:** Representa a distância entre dois pontos medida ao longo dos eixos em ângulos retos.
- **Distância de Minkowski:** É uma generalização das duas distâncias anteriores. Quando $p = 1$ torna-se uma distância de Manhattan e para $p = 2$ tem-se a distância euclidiana.
- **Distância de Mahalanobis:** É um tipo de distância ponderada que os elementos da matriz de covariância para como coeficientes dos termos da distância.
- **Distância de Hamming:** Encontra a distância simétrica entre as duas *strings*, calculando os caracteres desiguais em todas as posições.

O valor escolhido para representar K dependerá do problema a ser estudado. Em geral quando se trabalha com imagens que possuam muitos ruídos, um valor pequeno de K poderá sofrer muita influência pelos ruídos da imagem. O valor de K interfere diretamente no desempenho do KNN, quanto maior for este valor, maior será o consumo de recurso que o KNN usará para classificar (COSTA et al., 2014).

O KNN obtém bons resultados em vários cenários e comumente se porta bem quando cada classe possui diversos objetos e a superfície de decisão é irregular. Este classificador é baseado em instâncias, já que ele define a classe de um elemento embasado na classes de outros elementos. Desta forma, a princípio, ele não é treinado, pois sua saída é calculada apenas quando se deseja saber a classe de algum novo objeto (CASTRO; FERRARI, 2016).

2.4.2.2 Support Vector Machine

O *support vector machine* (SVM) ou máquina de vetores de suporte é um classificador supervisionado apoiado na teoria do aprendizado estatístico (VAPNIK, 1995). Este classificador objetiva encontrar o melhor hiperplano como superfície de decisão para separar os grupos a serem classificados.

O treinamento de SVM envolve a otimização de uma função quadrática convexa, contém poucos parâmetros livres que necessitam ser ajustados pelo usuário e não há uma dependência na dimensão do espaço de entrada do problema, o que indica que SVM pode ser adequado em problemas com uma grande quantidade de entradas (SANTOS et al., 2002).

De acordo com Gevert et al. (2010) dado um grupo de pontos pertencentes a duas classes, uma SVM define o hiperplano capaz de separar os pontos de cada grupo, objetivando posicionar o maior número de pontos de uma classe do mesmo lado enquanto maximiza a distância de cada classe a esse hiperplano. A menor distância entre o hiperplano e os pontos da classe é chamada de margem de separação, enquanto o hiperplano gerado


pela SVM é definido por um subconjunto dos pontos das duas classes, chamados de vetores de suporte.

Desta forma, o objetivo principal do SVM é definir o melhor hiperplano para separar duas classes de dados com a maior distância possível. O problema é achar uma função paramétrica, linear ou não, para uma classificação de duas classes. Na situação em que o problema seja separável por um hiperplano linear com um grupo de N classes $x_i = (x_{i1}, \dots, x_{im})$ e respostas binárias $y_i \in \{-1, 1\}$ têm-se três hiperplanos:

- **Hiperplano de Separação:** $H_0 : y = w^t x + b = 0$ que separa as classes.
- **Hiperplano Superior:** $H_1 : y = w^t x + b = +1$ que é determinado por pelo menos 1 ponto pertencente ao grupo com $y = +1$.
- **Hiperplano Inferior:** $H_1 : y = w^t x + b = -1$ que é definido por pelo menos 1 ponto pertencente ao grupo com $y = -1$.

São exibidos na figura 8 os hiperplanos de separação, superior e inferior no espaço $m = 2$. Em que os hiperplanos superior e inferior são chamados de vetores de suporte e a orientação do hiperplano de separação é definida de maneira que a distância entre os hiperplanos superior e inferior seja máxima.

Figura 8 – Exemplo de hiperplanos do SVM.



Fonte: Adaptado de Gevert et al. (2010).

Em problemas não linearmente separáveis é criado um novo espaço de características, em que o problema será linearmente separável, ou quase linearmente separável, a ideia é deixar em uma dimensão que seja mais fácil a resolução do problema.

Os *kernels* servem para promover uma transformação não linear, na expectativa de que, nesse novo espaço, o problema se torne linearmente separável. Estes *kernels* podem ser: linear, polinomial, gaussiano, sigmoide.


2.4.2.3 Random Forest

Random forest (RF) é definido formalmente por Breiman (2001) e baseia-se na construção de árvores de decisão, técnica da disciplina de mineração de dados. Este classificador cria aleatoriamente um conjunto de árvores de decisão em que há um mecanismo de votação chamado *bagging* que elege a classificação (conjunto de árvores) mais votada. Desta forma é possível obter uma predição com maior acurácia.

De acordo com Teloken et al. (2016), a RF é formada pela criação de várias árvores de decisão utilizando um subconjunto de atributos selecionados aleatoriamente a partir do conjunto original, em que os mesmos são aplicados nos nós de cada uma das árvores criadas. Em seguida, classifica-se qual subconjunto possui o melhor ganho de conhecimento para a solução do problema. Desta forma, cada subconjunto recebe um voto sobre qual classe o atributo chave deve pertencer, este voto possui um peso valorado pela igualdade entre as árvores, em que, quanto menor a semelhança entre as árvores, maior será o peso.

No topo da árvore, temos o nó raiz seguido de seus nós internos, de acordo com a Figura 9. Todos os nós são nós de decisão, cada qual possuindo um teste sobre um atributo e o resultados destes testes formam os ramos da árvore. Os algoritmos que constroem Árvores de Decisão almejam achar os atributos e valores que obtém maior discriminação dos registros de dados, com respeito ao atributo que se quer classificar, a cada nível da árvore (NETO, 2018).

Figura 9 – Exemplo ilustrativo de um classificador do tipo *random forest*.



Fonte: Cínthia Pessanha².

Segundo Gómez (2012), RF consiste em uma coleção de classificadores estruturados em árvores $\{h(X, \Theta_k), k = 1, \dots\}$, em que $\{\Theta_k\}$ são vetores independentemente e igualmente distribuídos, e cada árvore vota pela classe mais popular em X . A partir de uma distribuição de probabilidade fixa sobre os dados de entrada, é possível gerar vetores aleatórios. Cada árvore de decisão é gerada a partir de um novo conjunto de atributos selecionado aleatoriamente por uma técnica de amostragem com reposição chamada *bootstrap*.

² Disponível em: <<https://link.medium.com/Vsr8PnTj2db>>; Acesso em fevereiro. 2021.


Algumas vantagens do algoritmo do RF são listadas a seguir: trabalha com uma grande quantidade de atributos; possui boa taxa de acerto quando testado em diferentes conjuntos e dados; evita *overfitting*; é pouco sensível a ruídos; e classifica as árvores sem interação humana.

2.4.2.4 Multilayer Perceptron

O *multiLayer perceptron* (MLP) é uma popular rede neural artificial que aplica um processo de treinamento supervisionado usando exemplos de dados com saídas já conhecidas. Este processo gera um modelo de função não linear que possibilita a previsão de dados de saída com base nos dados de entrada fornecidos (OLMEDO et al., 2018).

O MLP pode ser representado pela Figura 10, na qual a primeira e a última camadas são chamadas de camadas de entrada e saída, respectivamente, enquanto as outras são as camadas ocultas da rede neural. O MLP é uma rede neural em que a informação flui unidirecionalmente a partir da camada de entrada, passando pelas camadas ocultas e terminando na camada de saída (BISHOP et al., 1995).

Figura 10 – Representação de uma rede *MultiLayer Perceptron*.



Fonte: Adaptado de CASTRO e FERRARI (2016).

O MLP é uma rede neural formada por mais de um *Perceptron* e que pode ser dividida em três partes:

- Camada de Entrada: É uma camada que não possui processamento e é responsável pela recepção dos dados de entrada e encaminhamento desses dados para a camada seguinte.
- Camadas Ocultas ou Intermediárias: Há uma ou mais camadas ocultas formadas por nós, na qual efetuam o processamento não linear do conjunto de dados.

- Camada de Saída: Responsável por fornecer a resposta do cálculo da rede.

Cada ligação entre as camadas possui peso próprio. *Perceptrons* para a mesma camada têm a mesma função de ativação. Normalmente, é um sigmóide para as camadas ocultas. Conforme a aplicação, a camada de saída também pode ser uma sigmóide ou uma função linear.

O algoritmo de aprendizado mais aplicado em modelos MLP é o algoritmo de retropropagação do erro, que é uma generalização da regra do mínimo quadrado médio. De acordo com (AFFONSO et al., 2010), este algoritmo é do tipo de aprendizado supervisionado, a princípio valores aleatórios são atribuídos aos pesos da rede e o treinamento é iniciado. O processamento ocorre camada por camada até que seja gerada a resposta na camada de saída. O erro é calculado no valor de saída caso a resposta não seja o valor esperado, então seus valores são retro-propagados da camada de saída para a camada de entrada. Neste momento, haverá reajuste dos pesos e os valores são recalculados. Este processo se repete até que os valores de saída sejam próximo dos valores desejados.

Segundo (SOUZA, 2012), ao se considerar a eficiência de uma MLP no trabalho com um determinado problema, dois aspectos devem ser avaliados no projeto da rede, que são, a definição do número de camadas ocultas e do número de neurônios em cada camada. A escolha destes aspectos é importante para a estabilidade da rede, visto que, um número muito alto para a quantidade de camadas e neurônios pode gerar uma sobrecarga no hardware, não permitindo o término do processamento.


O próximo capítulo apresenta a aplicação dos conceitos, vistos até o momento, de forma prática para resolver o problema proposto por este estudo. Posteriormente os resultados gerados serão analisados e discutidos.

3 Materiais e Métodos

Com o objetivo de classificar as imagens de mosquitos entre espécie e sexo, a metodologia proposta neste estudo procura resolver este problema utilizando técnicas de PDI.

A metodologia deste trabalho é sintetizada de acordo com o fluxograma da Figura 11.

Figura 11 – Fluxograma da metodologia proposta.



Fonte: Autor.

Inicialmente os espécimes dos mosquitos foram adquiridos e fotografados para criar três bases de imagem divididas em quatro classes. A classificação dessas imagens representou o problema a ser solucionado pela metodologia.

Após a criação das bases, as imagens foram pré-processadas com o objetivo de obter melhores resultados de classificação e melhorar o desempenho computacional. A extração de características utilizou três extratores para obter os vetores de atributos das imagens. Posteriormente estes vetores foram utilizados pelos quatro classificadores para identificar a espécie e sexo do mosquitos.

Os experimentos de classificar as imagens utilizando técnicas de PDI ocorreram de três formas: classificação única, em que cada base de imagens foi unicamente classificada; classificação binária, na qual utilizou-se apenas duas classes; e classificação composta, em que foram utilizadas duas bases de imagens, uma para treinamento do modelo e outra para teste, aumentando assim a complexidade do problema. Além disso, foi realizado uma classificação por especialistas humanos na qual usou-se as bases de imagens da câmera de *smartphone* e câmera macro, a fim de comparar com as demais classificações. Por fim, também é abordado como a metodologia será avaliada assim como o ambiente onde ocorreu a pesquisa.

3.1 Aquisição das Imagens

Espécimes dos mosquitos foram fornecidos pelo Núcleo de Controle de Vetores (NUVET), órgão vinculado à Secretária de Saúde de Estado do Ceará (SESA) e responsável por assessorar e supervisionar ações de controle de endemias e zoonoses transmitidas por vetores, em mais de 100 municípios do estado do Ceará (BARAKAT, 2019).

O material doado é constituído por mosquitos da espécie *Aedes aegypti*, distribuídos entre machos e fêmeas, e mosquitos da espécie *Aedes albopictus*, igualmente distribuídos entre machos e fêmeas. Cada espécime foi individualmente armazenado em um tubo de eppendorf, como ilustrado na Figura 12.

Figura 12 – Espécimes fornecidos pelo NUVET. As caixas são identificadas com a seguinte descrição: "*Aedes aegypti* (macho e fêmea). Laboratório de Vetores Reservatório e Animais Peçonhentos Dr. Thomaz Aragão NUVET/COVIG/SESA-CE"



Fonte: Autor.

Objetivando manter os espécimes com a aparência natural, as amostras estavam inteiras e secas, não foi utilizado nenhum líquido para conservação do corpo e também não foram utilizadas agulhas entomológica para prender o mosquito a uma base.

Dois especialistas do NUVET, pertencentes ao Laboratório de Vetores Reservatório e Animais Peçonhentos, foram responsáveis pela separação e classificação das espécies e do sexo dos espécimes de mosquitos fornecidos. Os especialistas utilizaram um microscópio e uma lupa para ajudar na visualização dos mosquitos e os classificaram de acordo com as chaves de identificação de cada espécie.

A partir dos mosquitos adquiridos, foram construídas três bases de imagens utilizando uma câmera de *smartphone*, uma câmera macro com zoom óptico de até 1.600x, e uma câmera digital single lens reflex (DSLR). Com estas bases de imagens vislumbramos ser possível validar a metodologia em imagens de qualidades distintas, e analisar por exemplo se imagens mais detalhadas do mosquito são relevantes ou não para a classificação. Os detalhes dos equipamentos de captura utilizados são exibidos na Tabela 1.


Tabela 1 – Características dos equipamentos de captura.

	SM-A705MN	Microscópio Digital 1.600x	Nikon D720
Tamanho da imagem (pixel)	4896x6528	640x480	1708x1139
Resolução (dpi)	96	96	240
Foco	Auto	Manual	Manual

Fonte: Autor.

Para fotografar individualmente cada mosquito utilizando a câmera de *smartphone* e a câmera macro, foi utilizada uma base circular de altura aproximada de 3 cm (Figura 13). O fundo da base possui uma superfície branca e o topo foi coberto com papel filme transparente. Desta forma, ao posicionar o mosquito em cima do papel filme foi possível fotografá-lo sem a projeção de sombra decorrente da fonte de luz. Os equipamentos de captura de imagem foram posicionados em um ângulo aproximado de 45° com relação a base.

Figura 13 – Base utilizada para apoiar os mosquitos.



Fonte: Autor.

Cada mosquito foi posto na base com a cabeça para a esquerda e suas patas para baixo. Ao ser fotografado a base era rotacionada em um ângulo de 90° e uma nova imagem era registrada, a rotação e a captura continuam até completar 360° . Posteriormente o mosquito era posicionado com a cabeça no lado direito e as patas viradas para baixo, e novas imagens eram registradas. A rotação permite capturar todos os detalhes do corpo do mosquito possibilitando visualizar detalhes que diferenciem a classe dos espécimes.


Para as imagens obtidas com o *smartphone* o equipamento foi sustentado por um tripé, e uma fonte de luz de led branco foi utilizada para iluminar o objeto a ser fotografado. No *smartphone*, foi aplicado um zoom digital de 2,5x e foco automático.

A câmera macro foi ajustada em uma base suspensa, a iluminação em led branco da própria câmera foi utilizada como fonte de luz, e o ajuste do foco manual objetivou dar maior nitidez ao corpo do mosquito.

Uma terceira base de imagens foi criada utilizando um critério mais aleatório e menos controlado para fotografar os mosquitos. Desta forma pretende-se averiguar se a metodologia de classificação proposta é eficaz também com imagens arbitrária dos mosquitos. Esta base de imagens fez uso de uma câmera digital DSLR com foco manual posicionada em um tripé em um ângulo aproximado de 45° . Uma estrutura de superfície branca foi utilizada para posicionar o mosquito enquanto luzes de leds foram dispostas na parte superior e frontal da estrutura.


Diferentemente da captura de imagens utilizando *smartphone* e a câmera macro, nesta base de imagens os mosquitos foram acomodados em posições aleatórias, não foram rotacionados e não foi utilizado nenhum artifício para se evitar sombras. A obtenção das imagens utilizando os três equipamentos de captura podem ser verificados na Figura 14.

Figura 14 – Metodologia de obtenção das imagens.




Fonte: Autor.

Nas Figuras 15, 16 e 17, são exibidos exemplos das imagens capturadas com a câmera de *smartphone*, câmera macro e com a câmera digital, respectivamente.

Figura 15 – Exemplo de imagens capturada com a câmera de *smartphone*.


Fonte: Autor.

Figura 16 – Exemplo de imagens capturada com a câmera macro.



Fonte: Autor.

Figura 17 – Exemplo de imagens capturada com a câmera DSLR.



Fonte: Autor.

O total de imagens obtidas com as três bases de dados é de 800. Cada base de imagens está distribuída de acordo com a Tabela 2.

Tabela 2 – Distribuição das imagens.

	<i>Ae. aegypti</i> Macho	<i>Ae. aegypti</i> Fêmea	<i>Ae. albopictus</i> Macho	<i>Ae. albopictus</i> Fêmea
Classe	0	1	2	3
Total imagens de câmera de smartphone	80	80	80	80
Total imagens de câmera macro	80	80	80	80
Total imagens de câmera digital	40	40	40	40
Total de imagens: 800				


Fonte: Autor.

3.2 Pré-Processamento


Como visto na Seção 3.1, as imagens obtidas através das câmera de *smartphone* e câmera DSLR possuem uma grande área de fundo, e o mosquito representa apenas uma pequena parte no centro da imagem. Desta forma, visando selecionar apenas o objeto de interesse, foi feito um corte da imagem apenas na área na qual o mosquito está localizado.

Para o corte da imagem foi realizada uma limiarização utilizando o método proposto por Otsu (1979), no qual um limiar ideal é encontrado para separar o objeto do fundo da imagem, com isso, pôde-se obter apenas a representação do mosquito na imagem. Posteriormente os limites da imagem a qual está contido o mosquito são identificadas para realizar o corte da imagem. Este processo pode ser verificado na Figura 18.

Figura 18 – Corte da imagem utilizando limiarização de Otsu.



(a) Limiarização da imagem utilizando o método de Otsu.



(b) Identificação do limite (retângulo verde) do objeto de interesse.




(c)

Imagem recortada.


Fonte: Autor.

Este método foi executado para todas as 800 imagens. A saída deste processamento são as imagens coloridas cortadas, e as imagens limiarizadas cortadas. O tamanho médio das imagens é de 76 kB. O resultado das imagens coloridas pós processamento podem ser verificadas nas Figuras 19, 20 e 21.

Figura 19 – Exemplo de imagens capturada com a câmera de *smartphone* após pré-processamento.(a) *Ae. aegypti* macho.(b) *Ae. aegypti* fêmea.(c) *Ae. albopictus* macho.(d) *Ae. albopictus* fêmea.


Fonte: Autor.

Figura 20 – Exemplo de imagens capturada com a câmera macro após pré-processamento.



Fonte: Autor.

Figura 21 – Exemplo de imagens capturada com a câmera digital após pré-processamento.



Fonte: Autor.

3.3 Extração de Características

Após o pré-processamento, a extração de atributos das imagens tem o objetivo de obter uma representação relevante para que seja possível classificar com exatidão a espécie e o sexo dos mosquitos.

Neste trabalho, foram utilizados dois extratores de textura, ACC e GLCM, que foram aplicados diretamente nas imagens coloridas. Um extrator de forma, o Momentos de Hu, também foi utilizado e aplicado nas imagens limiarizadas com o método de Otsu na etapa de pré-processamento.

A extração de características das imagens gerou vetores de atributos que são utilizados para identificar a espécie e o sexo das imagens dos mosquitos na fase de classificação. A quantidade de atributos gerados por extrator é de 768 atributos para o ACC, 14 atributos para o GLCM e 7 atributos para os Momentos de Hu.

Todos os vetores de atributos foram normalizados. Desta forma, passam a ter a mesma ordem de grandeza, sem distorcer as diferenças nos intervalos de valores ou perder

informações. Nesta perspectiva, a consequência desejada é a melhora da performance e estabilidade do treinamento do modelo.

3.4 Classificação

A partir dos atributos obtidos das imagens, foram utilizados os classificadores SVM, RF, KNN e MLP para classificar as espécies e o sexo dos mosquitos. A classificação foi aplicada a cada base de imagens.

Os classificadores foram parametrizados da seguinte forma: O SVM utilizou *kernel* linear com no máximo 200 iterações e o número base para a geração de números aleatórios foi definido como zero. O RF foi executado com a construção de 10 árvores. O KNN utilizou a distância euclidiana e o K número de vizinhos mais próximos foi sucessivamente de 1, 3 e 5. E por fim, o MLP utilizou o algoritmo LBFGS para otimização dos pesos, o valor de penalidade foi ajustado em 10^{-5} e a quantidade de camadas foi definida em 50. Os parâmetros foram encontrados utilizando busca em grade, na qual há uma busca exaustiva em um subconjunto de dados possíveis afim de se obter os melhores valores.

3.4.1 Classificação Única

Três experimentos de classificação foram realizados, a classificação única, que classifica cada base de imagens separadamente, a classificação binária que possui apenas duas classes, e a classificação composta que usa duas bases distintas para treinar e testar. Na classificação única, cada base de imagens foi classificada individualmente. Desta forma pretende-se avaliar a eficácia geral da metodologia em imagens de características distintas.

Foram utilizadas 320 imagens nas bases de imagens de câmera de *smartphone* e câmera macro, e 160 imagens na base da câmera digital, cada base de imagens foi dividida em quatro classes. Para o treinamento foi utilizado 80% da base, enquanto o teste utilizou 20% da base. Com isso, para as bases com 320 imagens, 256 foram usadas para treinamento e 64 imagens para teste. Para a base com 160 imagens, 128 foram usadas para treinamento e 32 para teste.

3.4.2 Classificação Binária

A classificação binária objetiva identificar os mosquitos que transmitem doenças. Desta forma as classes se dividem entre mosquitos que não transmitem doenças e mosquitos que transmitem doenças. Como visto no Capítulo 1, as fêmeas dos mosquitos são as responsáveis por transmitir doenças às pessoas, já que elas se alimentam de sangue humano para desenvolver seus ovos.

Logo, nesta classificação as classes utilizadas são: Classe 0 - *Aedes aegypti* e *Aedes albopictus* Machos (não transmitem doenças) e Classe 1 - *Aedes aegypti* e *Aedes albopictus* Fêmeas (transmitem doenças).

A base de imagens de câmera de *smartphone* foi utilizada para realizar esta classificação. Cada classe possui 160 imagens, totalizando 320 imagens. Para treino, foram utilizados 80% das imagens e 20% foram aplicados para teste.

3.4.3 Classificação Composta

Por fim procura-se avaliar a metodologia usando bases de imagens diferentes. Das três bases de imagens construídas, pode-se utilizar apenas duas nesta classificação, já que os mesmos espécimes foram utilizados para criar a base de imagens de câmera de *smartphone* e a base de imagens de câmera macro. Desta forma um mesmo espécime poderia estar nas imagens de treinamento e de teste ao mesmo tempo, o que poderia causar *overfitting* ao modelo.

Para o treinamento, foi utilizada a base de imagens de câmera de *smartphone* contendo 320 imagens. Esta base foi escolhida por possuir uma boa quantidade de imagens que capturam todos os ângulos dos mosquitos, fornecendo assim, mais informações para o treinamento do modelo.

Para o teste, foi usada a base de imagens de câmera digital contendo 160 imagens. Esta base contém imagens dos mosquitos em posições aleatórias, em que não houve preocupação em se obter detalhes do mosquitos em posições específicas.

3.5 Classificação Visual por Especialistas

Com o objetivo de comparar a eficácia da identificação de um especialista humano com a metodologia proposta, um formulário foi aplicado a três profissionais com experiência em identificação de mosquitos na Unidade de Vigilância de Zoonoses da cidade de Sobral-CE.

O formulário é composto por 20 imagens aleatórias retiradas das bases de imagens construídas na Seção 3.1. Para cada imagem, há uma questão de múltipla escolha composta de quatro alternativas, tendo apenas uma resposta correta que representa a espécie e o sexo do mosquito. As alternativas de cada questão são formadas por: a) *Aedes aegypti* macho; b) *Aedes aegypti* fêmea; c) *Aedes albopictus* macho; e d) *Aedes albopictus* fêmea. Além disto, para cada imagem também pergunta-se o grau de certeza da resposta do especialista, este grau é dividido em três níveis, no qual 1 representa pouca certeza sobre a resposta, 2 representa dúvida sobre a resposta e 3 representa muita certeza sobre a resposta.

No final do formulário, também há uma pergunta subjetiva no qual questiona o especialista sobre a dificuldade em se identificar os mosquitos através das imagens.

As imagens escolhidas para compor o formulário foram retiradas da base de imagens construídas com a câmera macro e com a câmera de *smartphone*. Essas bases foram preferidas por conter imagens que exibem melhor os detalhes dos mosquitos, desta forma os especialistas teriam menos dificuldade em responder o formulário.

As 20 imagens do formulário foram constituídas da seguinte forma; três imagens de cada espécie/sexo da base de imagens de câmera macro, totalizando 12 imagens, e duas imagens de cada espécie/sexo da base de imagens de câmera de *smartphone*, totalizando 8 imagens. Há mais imagens da base de câmera macro devido ao fato delas terem uma melhor definição, pois, conseqüentemente poderiam ser visualmente mais simples de serem identificadas pelos especialistas.

As imagens foram ordenadas de forma aleatória, possuindo apenas um rótulo no formato: "Imagem X", no qual X representa a ordem da imagem dentro do formulário, como mostra a Figura 22.

Figura 22 – Imagem 01 do formulário apresentado aos especialistas.



Imagem 01

Fonte: Autor.

A aplicação do formulário foi realizada individualmente para cada especialista, que opcionalmente, pode utilizar as chaves de identificação como auxílio para facilitar o reconhecimento das espécies. As imagens dos mosquitos foram disponibilizadas em um notebook para que o especialista pudesse rotacionar, aumentar e diminuir o tamanho das imagens. Cada profissional teve seu tempo de resposta cronometrado, e o local da aplicação do formulário foi no laboratório de entomologia da Unidade de Vigilância de Zoonoses.

Figura 23 – Especialista respondendo ao formulário no laboratório de entomologia da Unidade de Vigilância de Zoonoses da cidade de Sobral-CE.



Fonte: Autor.

O formulário completo pode ser visto no anexo A.

3.6 Avaliação de Desempenho

A avaliação da classificação única e binária foram medidas empregando a técnica de validação cruzada *K-Fold*, que implica em dividir o conjunto total de dados do treinamento em *K* subconjuntos de mesmo tamanho. Foi escolhido *K* igual a 10, no qual as métricas são obtidas através da média das 10 iterações da validação cruzada.

As métricas utilizadas para medir a qualidade da classificação são derivadas da matriz de confusão. Esta matriz é uma forma de representação da qualidade obtida de uma classificação, determinada através da correlação de informações dos dados de referência (compreendido como verdadeiro) com os dados classificados (PRINA; TRENTIN, 2015).

A matriz de confusão possui quatro categorias, sendo elas: verdadeiro positivo (*true positive* — TP), são as classes que foram previstas corretamente; verdadeiro negativo (*true negative* — TN), classes que não pretende-se prever e foram previstas corretamente; falso positivo (*false positive* — FP), a classe que pretende-se prever e foi prevista incorretamente; falso negativo (*false negative* — FN), a classe que não pretende-se prever e foi prevista incorretamente.

Com base na matriz de confusão, é possível obter as métricas para avaliar a classificação. Estas métricas são:

- Acurácia: Mede a eficiência geral do modelo, indicando o índice de classificação correta.

$$\text{acc} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.1)$$

- Precisão: Avalia a efetividade do modelo, mostrando a proporção de identificações

positivas realmente correta.

$$\text{pre} = \frac{TP}{TP + FP} \quad (3.2)$$

- *Recall*: É a frequência em que o classificador encontra os exemplos de uma classe.

$$\text{rec} = \frac{TP}{TP + FN} \quad (3.3)$$

- *F1-Score*: Determina a qualidade geral do modelo combinando os valores de precisão e *recall*.

$$f1 = 2 * \frac{\text{pre} * \text{rec}}{\text{pre} + \text{rec}} \quad (3.4)$$

Para a classificação composta que utiliza bases de imagens distintas para treinamento e teste, a avaliação foi realizada em 10 ciclos de execução utilizando sempre toda base de *smartphone* para treino e sempre toda base de câmera digital para teste.

3.7 Ambiente de Pesquisa

Este trabalho foi desenvolvido no seguinte ambiente:

- *Hardware*
 - *Smartphone* modelo SM-A705MN.
 - Câmera macro modelo Microscópio Digital 1600x.
 - Câmera DSLR modelo Nikon D720.
 - Notebook modelo Inspiron 15 Gaming 7567, Core i7-7700HQ 2.80 GHz, 16 GB de RAM, SSD 256 GB, SSD 960 GB, GTX 1050 Ti.
- *Software*
 - Sistema Operacional: Windows 10 Home Single Language
 - Linguagens de programação: Python 3.7 (64 bit) e Java 1.8.0
 - Ambientes de Desenvolvimento: JetBrains PyCharm Community Edition 2020.3, Apache NetBeans 12.2
 - Principais bibliotecas: OpenCV 4.4.0 e Scikit-Learn 0.23.2.

4 Resultados e Discussões

Apresentam-se a seguir os resultados das classificações das imagens de mosquitos das três bases de imagens criadas na Seção 3.1. As classificações são subdivididas em classificação única, classificação binária e classificação composta. Cada base de imagens está dividida em quatro classes sendo elas: Classe 0 - *Aedes aegypti* Macho; Classe 1 - *Aedes aegypti* Fêmea; Classe 2 - *Aedes albopictus* Macho; e Classe 3 - *Aedes albopictus* Fêmea. Já para a classificação binária, utiliza-se apenas duas classes sendo elas Classe 0 - *Aedes aegypti* e *Aedes albopictus* Machos (não transmitem doenças) e Classe 1 - *Aedes aegypti* e *Aedes albopictus* Fêmeas (transmitem doenças).

As classificações fazem uso dos extratores de características ACC, GLCM e Momentos de Hu descritos na Seção 2.4.1 e dos classificadores SVM, RF, KNN e MLP relacionados na Seção 2.4.2.

Também são exibidos os resultados da classificação visual realizada por especialistas. A avaliação das classificações foi realizada de acordo com as métricas explanadas na Seção 3.6.

4.1 Resultados Obtidos na Classificação Única

As Tabelas 3, 4 e 5 exibem os valores de qualidade das classificações das 4 classes, realizadas nas bases de imagens com a câmera macro, câmera de *smartphone* e a câmera digital respectivamente. Os melhores resultados de cada tabela foram destacados de verde enquanto os piores resultados foram destacados de vermelho.

De acordo com os resultados, a técnica que obteve melhor fruto em identificar as espécies e sexo dos mosquitos foi o extrator GLCM em conjunto com o classificador RF, chegando a uma acurácia de 99,38% na base de dados produzida utilizando a câmera macro, esses dados podem ser vistos na Tabela 3. Por sua vez, o extrator Momentos de Hu teve o menor desempenho chegando ao máximo de 40,63% de acurácia ao trabalhar com o classificador KNN1 e com o RF, podendo ser visto na Tabela 5 .

Extratores de forma como o Momentos de Hu se mostram inadequados para descrever características do problema trabalhado neste estudo. O extrator poderia se utilizar de algumas características da anatomia do mosquito como por exemplo a antena e os palpos maxilares, porém estas partes do corpo representam apenas uma pequena área da imagem, e o corpo, que ocupa uma maior área na imagem, não possui características de forma que sejam relevantes para diferenciar cada classe. Outro complicador ao se lidar com imagens desses tipo é a posição na qual os mosquitos são fotografados, mesmo ao

Tabela 3 – Resultados da classificação da base de câmera macro.

	Acurácia	Precisão	Recall	F1-Score
KNN₁ + ACC	67,97 ± 5,47	65,76 ± 4,12	67,60 ± 4,03	65,28 ± 4,04
KNN₁ + GLCM	94,06 ± 2,19	93,83 ± 2,14	93,90 ± 2,43	93,70 ± 2,26
KNN₁ + HU	34,69 ± 6,62	35,08 ± 5,84	34,69 ± 6,74	34,04 ± 6,56
KNN₃ + ACC	68,75 ± 6,37	67,72 ± 4,35	67,95 ± 4,77	65,44 ± 4,94
KNN₃ + GLCM	94,84 ± 2,43	94,53 ± 2,40	94,73 ± 2,52	94,43 ± 2,47
KNN₃ + HU	35,00 ± 6,49	35,47 ± 7,01	34,29 ± 6,83	33,06 ± 6,34
KNN₅ + ACC	66,09 ± 6,17	65,53 ± 5,21	65,20 ± 4,70	62,71 ± 4,99
KNN₅ + GLCM	94,84 ± 2,97	94,82 ± 2,98	94,49 ± 3,06	94,44 ± 2,99
KNN₅ + HU	36,09 ± 6,42	37,15 ± 7,63	35,66 ± 6,80	34,46 ± 6,67
SVM + ACC	73,75 ± 6,04	72,28 ± 6,50	73,33 ± 6,11	72,06 ± 6,13
SVM + GLCM	97,66 ± 1,26	97,46 ± 1,28	97,71 ± 1,29	97,49 ± 1,28
SVM + HU	19,69 ± 4,26	6,68 ± 4,51	26,86 ± 4,20	10,09 ± 5,16
RF + ACC	69,06 ± 5,96	68,73 ± 5,39	69,01 ± 5,53	67,73 ± 5,54
RF + GLCM	99,38 ± 0,77	99,22 ± 0,99	99,46 ± 0,68	99,32 ± 0,86
RF + HU	38,28 ± 7,30	38,41 ± 8,12	37,99 ± 7,15	36,78 ± 7,28
MLP + ACC	73,59 ± 5,20	72,28 ± 4,80	73,14 ± 4,99	71,96 ± 5,00
MLP + GLCM	97,66 ± 1,88	97,67 ± 1,78	97,48 ± 2,21	97,43 ± 2,10
MLP + HU	19,38 ± 3,71	6,69 ± 4,53	26,47 ± 3,44	9,53 ± 4,19

Fonte: Autor.

Tabela 4 – Resultados da classificação da base de câmera de *smartphone*.

	Acurácia	Precisão	Recall	F1-Score
KNN₁ + ACC	65,63 ± 5,32	65,59 ± 4,74	65,26 ± 4,55	64,58 ± 4,47
KNN₁ + GLCM	97,34 ± 1,98	97,47 ± 1,96	97,09 ± 1,96	97,13 ± 2,09
KNN₁ + HU	25,78 ± 3,84	26,60 ± 5,00	26,45 ± 4,74	25,42 ± 4,30
KNN₃ + ACC	63,44 ± 5,00	61,42 ± 4,29	63,25 ± 3,61	61,03 ± 4,05
KNN₃ + GLCM	97,50 ± 2,23	97,53 ± 2,15	97,34 ± 2,22	97,34 ± 2,27
KNN₃ + HU	28,91 ± 4,49	27,25 ± 3,88	28,22 ± 4,20	26,59 ± 3,75
KNN₅ + ACC	65,94 ± 6,12	64,73 ± 5,19	65,75 ± 3,89	63,87 ± 4,94
KNN₅ + GLCM	97,66 ± 1,75	97,71 ± 1,67	97,37 ± 1,74	97,43 ± 1,76
KNN₅ + HU	29,69 ± 4,36	26,10 ± 4,36	29,65 ± 4,30	26,56 ± 3,98
SVM + ACC	80,63 ± 3,84	80,48 ± 2,85	80,33 ± 2,85	79,99 ± 2,84
SVM + GLCM	99,22 ± 1,26	99,22 ± 1,23	99,27 ± 1,18	99,22 ± 1,25
SVM + HU	18,75 ± 3,63	6,12 ± 5,10	25,50 ± 1,50	8,52 ± 3,11
RF + ACC	72,97 ± 3,70	72,93 ± 4,16	73,09 ± 4,81	72,04 ± 4,27
RF + GLCM	98,91 ± 1,22	98,83 ± 1,24	98,83 ± 1,26	98,78 ± 1,30
RF + HU	32,66 ± 5,91	32,07 ± 6,94	32,92 ± 6,89	31,17 ± 6,36
MLP + ACC	78,28 ± 4,71	78,21 ± 4,14	77,87 ± 4,32	77,41 ± 4,07
MLP + GLCM	98,59 ± 1,30	98,57 ± 1,37	98,47 ± 1,49	98,46 ± 1,48
MLP + HU	18,44 ± 2,86	6,24 ± 3,88	25,17 ± 0,50	8,99 ± 3,26

Fonte: Autor.

fotografar exemplares mortos, é bastante difícil manipular as asas e patas para mantê-los sempre em uma mesma posição.

Os extratores de textura GLCM e ACC conseguiram obter melhores resultados nas imagens trabalhadas. Ao analisar a textura das imagens, é possível identificar as características de cada classe de mosquitos, aspectos como antena, palpos maxilares e

Tabela 5 – Resultados da classificação da base de câmera digital.

	Acurácia	Precisão	Recall	F1-Score
KNN₁ + ACC	71,88 ± 11,27	71,32 ± 15,63	72,78 ± 14,41	68,85 ± 15,03
KNN₁ + GLCM	90,63 ± 5,76	90,04 ± 6,75	90,73 ± 6,99	89,33 ± 7,06
KNN₁ + HU	40,63 ± 9,78	45,99 ± 8,36	41,88 ± 9,03	39,65 ± 8,82
KNN₃ + ACC	60,63 ± 6,28	62,03 ± 11,18	62,57 ± 10,17	56,35 ± 9,49
KNN₃ + GLCM	96,25 ± 5,00	96,38 ± 5,09	96,67 ± 4,58	96,01 ± 5,54
KNN₃ + HU	39,38 ± 14,54	43,38 ± 13,19	38,24 ± 14,83	37,21 ± 14,31
KNN₅ + ACC	64,38 ± 4,88	72,42 ± 7,65	67,08 ± 6,96	62,07 ± 6,18
KNN₅ + GLCM	96,25 ± 4,15	96,29 ± 4,37	96,25 ± 4,04	95,69 ± 4,78
KNN₅ + HU	35,63 ± 10,84	40,79 ± 14,73	33,99 ± 12,54	33,65 ± 11,81
SVM + ACC	76,25 ± 9,19	76,46 ± 10,14	77,37 ± 9,61	74,26 ± 10,00
SVM + GLCM	91,25 ± 4,15	92,42 ± 3,51	91,14 ± 3,97	89,94 ± 5,17
SVM + HU	15,00 ± 5,73	3,75 ± 1,43	25,00	6,41 ± 2,19
RF + ACC	76,25 ± 7,29	78,39 ± 9,37	77,38 ± 9,09	75,66 ± 8,08
RF + GLCM	94,38 ± 5,90	94,96 ± 5,88	94,67 ± 5,92	94,34 ± 6,39
RF + HU	40,63 ± 14,59	41,60 ± 17,58	40,70 ± 13,87	37,47 ± 15,23
MLP + ACC	75,00 ± 10,08	77,06 ± 9,46	76,28 ± 9,62	73,85 ± 9,68
MLP + GLCM	96,25 ± 4,15	95,83 ± 4,66	95,88 ± 4,95	95,02 ± 5,92
MLP + HU	14,38 ± 7,42	5,25 ± 5,00	23,96 ± 5,53	7,28 ± 4,42

Fonte: Autor.

coloração do dorso são melhores representadas ao usar um extrator de textura. Estes extratores conseguem, a partir da variação dos tons dos *pixels* da imagem, identificar um padrão de uma região e distinguir aquelas que apresentam as mesmas características, identificando com mais sucesso os grupos de cada classe.

Ao analisar os resultados das tabelas, considera-se que as imagens obtidas com a câmera de *smartphone* possuem a resolução necessária para a identificação das espécies e sexo dos mosquitos, obtendo acurácia de até 99,22%, mesmo este equipamento tendo uma qualidade fotográfica inferior aos outros dois equipamentos utilizados. Apesar da câmera digital gerar imagens mais detalhadas, ainda obteve uma acurácia máxima menor que a da base de dados criada com câmera de *smartphone*, chegando a 96,25% de acurácia. Isso se deve, provavelmente, ao fato de que a base de imagens da câmera digital foi criada com um critério aleatório, já que os mosquitos não foram rotacionados e as sombras não foram removidas, desta forma nem todos os aspectos, que diferenciam cada classe dos mosquitos, puderam ser representados nas imagens.

Ao calcular a média dos melhores resultados das três bases de dados, conclui-se que o extrator GLCM junto ao classificador RF é combinação mais efetiva para identificar os mosquitos, cuja média da acurácia das três bases é de 97,55%. Além disso, as imagens geradas a partir da câmera digital possuem uma maior complexidade por possuírem imagens de posições aleatórias dos espécimes, e neste cenário o GLCM junto com o RF atingiu a acurácia de 94,38%.

4.1.1 Resultados de Tempo

A avaliação de tempo de classificação é importante quando a metodologia for aplicada em alguns cenários específicos. Por exemplo em sistema embarcado que possui um poder de processamento bastante reduzido, ou quando for aplicada em um *stream* de vídeo o qual o sistema deverá indicar em tempo real cada espécie de mosquito que aparece no *frame*. Desta forma é interessante se buscar a metodologia que classifique no menor tempo possível com uma acurácia mínima aceitável. Quando utilizada para auxiliar um especialista a identificar apenas um mosquito por vez, o tempo máximo obtido já se torna aceitável por ser menor a 1 segundo.

Nas Tabelas 6, 7 e 8 estão disponíveis os resultados referentes ao tempo de treino e de teste nas combinações dos extratores ACC e GLCM com os classificadores utilizados. Os dados do extrator Momentos de Hu foram omitidos por considerar que o mesmo não apresenta uma acurácia aceitável para classificação. O tempo é medido em milissegundos e os valores são referentes à execução utilizando uma máquina com configuração descrita na Seção 3.7. Os melhores resultados de cada tabela são definidos pelo menor valor entre a média do tempo de treino e teste, e são destacados com a cor verde, enquanto os piores resultados, definidos pelo maior valor entre a média do tempo de treino e teste, são destacados em vermelho.

Tabela 6 – Tempo médio de treino e teste da base de imagens da câmera macro.

	Tempo de Treino (ms)	Tempo de Teste (ms)
KNN₁ + ACC	36,03 ± 10,78	34,86 ± 5,18
KNN₁ + GLCM	1,20 ± 0,39	5,24 ± 0,79
KNN₃ + ACC	33,35 ± 5,64	36,12 ± 2,76
KNN₃ + GLCM	1,20 ± 0,41	5,78 ± 0,89
KNN₅ + ACC	43,46 ± 11,06	41,03 ± 7,68
KNN₅ + GLCM	1,70 ± 0,65	8,48 ± 0,67
SVM + ACC	70,36 ± 10,36	7,36 ± 0,90
SVM + GLCM	11,08 ± 1,75	5,98 ± 1,00
RF + ACC	26,24 ± 2,95	3,99 ± 0,96
RF + GLCM	13,44 ± 1,79	4,40 ± 0,61
MLP + ACC	446,90 ± 150,23	4,28 ± 1,62
MLP + GLCM	54,84 ± 22,24	4,28 ± 0,47

Fonte: Autor.

Os piores tempos são registrados ao utilizar o extrator ACC. Quando comparado o ACC com o GLCM utilizando o mesmo classificador há uma diferença de tempo de quase 40 vezes, como verificado na Tabela 6 nas linhas do classificador KNN₅. O tempo de processamento ao utilizar o ACC é proporcional a quantidade de atributos utilizados no vetor de características, quanto mais atributos o vetor tiver, maior será o tempo para treinar e testar o modelo.

Tabela 7 – Tempo médio de treino e teste da base de imagens da câmera de *smartphone*.

	Tempo de Treino (ms)	Tempo de Teste (ms)
KNN₁ + ACC	27,89 ± 0,63	30,84 ± 1,04
KNN₁ + GLCM	1,70 ± 0,64	8,68 ± 1,18
KNN₃ + ACC	36,26 ± 12,76	34,50 ± 6,11
KNN₃ + GLCM	1,12 ± 0,33	4,84 ± 1,12
KNN₅ + ACC	51,16 ± 3,72	41,21 ± 1,57
KNN₅ + GLCM	1,52 ± 0,47	8,76 ± 1,72
SVM + ACC	49,14 ± 2,86	7,24 ± 0,53
SVM + GLCM	11,17 ± 1,33	6,18 ± 1,16
RF + ACC	36,80 ± 2,21	5,79 ± 0,98
RF + GLCM	16,26 ± 4,74	4,40 ± 1,57
MLP + ACC	436,02 ± 55,86	4,09 ± 1,71
MLP + GLCM	63,43 ± 40,97	3,81 ± 1,23

Fonte: Autor.

Tabela 8 – Tempo médio de treino e teste da base de imagens da câmera digital.

	Tempo de Treino (ms)	Tempo de Teste (ms)
KNN₁ + ACC	6,28 ± 0,90	7,98 ± 1,61
KNN₁ + GLCM	0,82 ± 0,41	3,78 ± 1,08
KNN₃ + ACC	4,09 ± 0,55	5,78 ± 1,54
KNN₃ + GLCM	0,80 ± 0,40	5,38 ± 0,49
KNN₅ + ACC	6,38 ± 1,11	8,08 ± 1,13
KNN₅ + GLCM	0,77 ± 0,42	3,43 ± 0,70
SVM + ACC	16,56 ± 1,28	7,19 ± 0,87
SVM + GLCM	4,96 ± 0,78	3,71 ± 0,43
RF + ACC	16,39 ± 4,23	5,18 ± 1,48
RF + GLCM	16,16 ± 3,24	5,07 ± 1,16
MLP + ACC	129,07 ± 28,24	3,05 ± 1,07
MLP + GLCM	17,77 ± 1,46	4,40 ± 1,42



Fonte: Autor.

O GLCM obteve o melhor desempenho de tempo utilizando o classificador KNN₁ cuja média dos tempos de treino, das três bases de imagens, foi de 1,24 ms e a média do tempo de teste foi de 5,9 ms. A combinação do GLCM com o RF, a qual gerou a melhor acurácia para o problema trabalho, teve tempo de treino médio de 15,28 ms, e tempo de teste médio de 4,62 ms.

4.1.2 Matriz de Confusão

A matriz de confusão nos permite analisar melhor o modelo e identificar em quais imagens houve mais ou menos erros de previsão. Na Figura 24 são apresentadas as matrizes de confusão de teste dos melhores resultados de cada extrator utilizado. A base de imagens escolhida para gerar as matrizes de confusão foi a da câmera digital, já que esta base capturou as imagens utilizando um critério menos rígido.

Figura 24 – Matriz de confusão na base de imagens de câmera digital.



Fonte: Autor.

A matriz de confusão do extrator ACC com classificador SVM representada na Figura 24a exibe que as classes 0, 1 e 3 tiveram uma assertividade média de 95,23%, enquanto a classe 2 teve apenas 60%, sendo confundida com a classe 1. Percebe-se também que esta combinação obteve 100% de acerto ao identificar os mosquitos *Aedes aegypti* (classe 0 e 1). Os erros se deram com as classes *Aedes albopictus*, no qual a classe 2 (*Aedes albopictus* macho) foi confundida com a classe 1 (*Aedes aegypti* fêmea), e com a classe 3 (*Aedes albopictus* fêmea) que foi confundida com a classe 2 (*Aedes albopictus* macho).

Na matriz de confusão da combinação GLCM com KNN3 é apresentada na Figura 24b. Esta é a melhor combinação de extrator e classificador para esta base de imagens, no qual a matriz gerada mostra 100% de acerto em todas as previsões. Apesar do valor de acurácia do GLCM com o KNN3 ter sido de 96,25%, é possível obter um valor maior devido ao desvio padrão de 5.

A matriz de confusão da Figura 24c representa a combinação Hu com RF. Nesta matriz, a maior assertividade foi ao tentar prever a classe 3, com 28,57%. Enquanto as piores previsões foram das classes 0 e 1, com 0% cada. Desta forma, o Momentos de Hu não conseguiu gerar dados satisfatórios para agrupar corretamente as imagens, sendo que apenas uma das classes teve boa assertividade na previsão.

4.2 Resultados Obtido pela Classificação Binária

A classificação binária é útil quando se deseja que a metodologia classifique os mosquitos entre os que transmitem ou não doenças para os seres humanos. Desta forma, as duas classes que compõe esta classificação são: Classe 0 - *Aedes aegypti* e *Aedes albopictus* Machos (não transmitem doenças) e Classe 1 - *Aedes aegypti* e *Aedes albopictus* Fêmeas (transmitem doenças). A base de imagens utilizada para esta classificação foi a de câmera de *smartphone*. A tabela 9 exibe os valores da classificação binária.

Tabela 9 – Resultados da classificação binária da base de câmera de *smartphone*.

	Acurácia	Precisão	Recall	F1-Score
KNN₁ + ACC	73,28 ± 5,11	63,13 ± 11,79	63,44 ± 11,96	63,09 ± 11,83
KNN₁ + GLCM	97,66 ± 1,75	88,31 ± 15,60	88,50 ± 15,76	88,38 ± 15,67
KNN₁ + HU	57,97 ± 2,47	58,86 ± 2,66	58,75 ± 2,83	57,55 ± 2,77
KNN₃ + ACC	74,06 ± 6,99	69,02 ± 11,69	69,14 ± 11,63	68,60 ± 11,46
KNN₃ + GLCM	98,91 ± 1,22	92,39 ± 13,64	92,74 ± 13,07	92,55 ± 13,36
KNN₃ + HU	63,75 ± 4,73	64,38 ± 4,39	64,34 ± 4,37	63,47 ± 4,60
KNN₅ + ACC	75,78 ± 7,10	70,26 ± 11,28	70,57 ± 11,26	70,21 ± 11,26
KNN₅ + GLCM	98,91 ± 1,22	92,38 ± 13,64	92,76 ± 13,08	92,55 ± 13,36
KNN₅ + HU	64,22 ± 4,39	65,01 ± 3,87	64,98 ± 4,07	63,95 ± 4,39
SVM + ACC	79,06 ± 4,26	69,04 ± 15,26	69,03 ± 14,92	68,88 ± 15,06
SVM + GLCM	98,91 ± 1,41	92,46 ± 13,93	92,76 ± 13,34	92,60 ± 13,64
SVM + HU	43,59 ± 3,46	21,80 ± 1,73	50,00	30,32 ± 1,68
RF + ACC	77,97 ± 7,83	73,05 ± 14,29	72,98 ± 13,88	72,78 ± 14,16
RF + GLCM	99,22 ± 1,05	92,84 ± 13,61	92,91 ± 13,37	92,87 ± 13,49
RF + HU	60,47 ± 3,77	61,03 ± 3,97	60,96 ± 3,75	60,17 ± 3,66
MLP + ACC	80,78 ± 3,89	67,54 ± 14,29	67,56 ± 14,09	67,42 ± 14,13
MLP + GLCM	99,06 ± 1,04	89,47 ± 15,39	89,48 ± 15,44	89,46 ± 15,42
MLP + HU	43,59 ± 3,46	21,80 ± 1,73	50,00	30,32 ± 1,68

Fonte: Autor.

De acordo com os resultados, a metodologia obtém resultados ótimos similares aos obtidos com a classificação das quatro classes. O resultado reafirma a vantagem do GLCM comparado aos extratores ACC e Momentos de Hu, nesta classificação o GLCM se saiu melhor quando combinado com o classificador RF, alcançando uma acurácia de 99,22%. Já o extrator ACC obteve melhor resultado ao ser combinado com o classificador MLP, no qual conseguiu acurácia de 80,78%.

Contrariando os resultados desfavoráveis ao se trabalhar com as quatro classes, o Momentos de HU obteve uma acurácia máxima de 64,22% ao trabalhar com classificador KNN5. Mesmo sendo um resultado ainda menor do que o conseguido com os outros extratores, é interessante notar a melhoria do Momentos de Hu ao tentar identificar apenas o sexo do mosquitos. Desta forma, considera-se que as características que distinguem apenas o sexo, como por exemplo as antenas, são melhor representados com este extrator do que as características que distinguem as espécies, como por exemplo o desenho no dorso.

4.3 Resultados Obtido pela Classificação Composta

A classificação composta tem o propósito de avaliar o cenário em que o modelo é treinado e testado com base de imagens diferentes. Para isto, o treino foi realizado com a base da câmera de *smartphone* e o teste utilizou a base da câmera digital. A tabela 10 exibe os resultados da classificação composta.

Tabela 10 – Resultados dos testes em que o treinamento utiliza a base de câmera de *smartphone* e o teste utiliza a base de câmera digital.

	Acurácia	Precisão	Recall	F1-Score
KNN1 + ACC	40,00	47,40	40,00	38,03
KNN1 + GLCM	87,50	88,83	87,50	87,31
KNN1 + HU	26,25	39,51	26,25	23,88
KNN3 + ACC	38,75	37,72	38,75	36,56
KNN3 + GLCM	85,00	86,32	85,00	84,98
KNN3 + HU	32,50	36,93	32,50	25,02
KNN5 + ACC	47,50	48,60	47,50	45,07
KNN5 + GLCM	86,25	87,39	86,25	86,19
KNN5 + HU	32,50	52,08	32,50	24,14
SVM + ACC	28,75	26,44	28,75	25,21
SVM + GLCM	87,50	88,27	87,50	87,43
SVM + HU	25,00	6,33	25,00	10,10
RF + ACC	36,88 ± 4,98	35,11 ± 9,12	36,88 ± 5,25	30,65 ± 6,06
RF + GLCM	92,13 ± 4,44	92,93 ± 3,63	92,13 ± 4,68	91,97 ± 4,98
RF + HU	24,25 ± 5,04	30,57 ± 9,52	24,25 ± 5,31	20,34 ± 3,00
MLP + ACC	32,50	35,20	32,50	30,07
MLP + GLCM	88,75	89,36	88,75	88,71
MLP + HU	32,50	24,29	32,50	23,39

Fonte: Autor.

Na tabela é exibido os valores da média de 10 ciclos de execução, porém, apenas o desvio padrão das classificações realizadas com o RF é apresentado. Isso se deve à característica do RF de escolher aleatoriamente subconjuntos de atributos para gerar as árvores de decisão, o que faz o resultado ter uma pequena diferença em cada ciclo. Já para

os outros classificadores, sempre dará o mesmo resultado, pois não há mudança na base de treino e teste em cada execução.

Os resultados demonstram mais uma vez que a combinação do extrator GLCM com o classificador RF obtém uma ótima acurácia para classificar as imagens de mosquitos, neste caso a acurácia foi de 92,13%. Ao comparar os resultados obtidos na classificação única, Seção 4.1, no qual o GLCM juntamente com o RF obtiveram uma acurácia de 98,91% ao se trabalhar na base de imagens de câmera *smartphone* e 94,38% ao utilizar a base de imagens de câmera digital, a classificação composta se mostra mais complexa, uma vez que as duas bases de imagens utilizadas possuem fotografias com aspectos distintos, como por exemplo, iluminação, sombra e resolução. Isso naturalmente adiciona uma dificuldade maior para que consiga uma alta taxa de assertividade ao classificar os espécimes.

Porém, ressalta-se que o extrator ACC se mostrou ineficiente na classificação composta. Uma vez que a maior acurácia obtida foi de apenas 47,50% ao se trabalhar com o classificador KNN5, valor este, insuficiente para resolver o problema proposto neste trabalho.

4.4 Resultados Obtido pela Classificação Visual dos Especialistas

Os especialistas participantes da pesquisa apontaram dificuldades em identificar os mosquitos através das imagens. Isso pode ser percebido através da acurácia média obtida por eles, que foi de 51,66%.

O tempo médio dos especialistas ao responderem o formulário foi de 13 minutos e 41 segundos. Isso equivale a identificação de uma imagem a cada 41 segundos.

Os profissionais necessitam de uma maior liberdade para visualizar o corpo do mosquito para chegar a uma definição. Apenas uma imagem do mosquito mostrou ser um fator limitante para que um especialista humano possa identificar a espécie e sexo dos mosquitos, já que nem todas as imagens mostram claramente características do espécime que possam ser úteis para a classificação. A Figura 25 ilustra bem esta situação.

Para as imagens 8 e 11 apresentadas na Figura 25 os três especialistas se equivocaram e assinalaram, incorretamente, a mesma resposta. A Imagem 8 representa o mosquito *Aedes albopictus* macho, porém, os especialistas disseram se tratar de um *Aedes aegypti* macho. Já a Imagem 11 pertence a um *Aedes aegypti* fêmea, para os especialistas esta imagem seria de um *Aedes albopictus* fêmea.

Os especialistas justificam o erro pelo fato de não ser possível ver o desenho do dorso dos espécimes, por outro lado, o sexo foi corretamente identificado nas duas situações, já que as antenas podem ser facilmente visualizadas.

De acordo com as respostas dos especialistas, os principais fatores que dificultaram

Figura 25 – Imagens 8 e 11 do formulário aplicado aos especialistas.




Imagem 08



Imagem 11

(a) Imagem 8 - *Aedes albopictus* macho.

(b) Imagem 11 - *Aedes aegypti* fêmea.

Fonte: Autor.

a identificação através da imagens são:

- Qualidade das imagens: As imagens não possuem alta definição, sendo que as imagens de câmera de *smartphone* foram consideradas as mais difíceis para visualizar aspectos importantes dos mosquitos,
- Impossibilidade de visualizar outros ângulos do mesmo espécime: Os especialistas costumam visualizar o corpo do mosquitos em vários ângulos diferentes, algo que não é possível fazer com as imagens.
- Impossibilidade de visualizar o tórax: Algumas imagens não mostram claramente o tórax do espécime, dificultando assim a distinção da espécie do mosquito.

Apesar dos três especialistas terem mencionado que as imagens geradas com a câmera macro são melhores para realizar a identificação dos mosquitos, os resultados apresentados mostram o contrário. Quando analisa-se as respostas dos especialistas somente com as imagens criadas com câmera macro, houve uma assertividade de apenas 44,44%. Quando observa-se apenas as imagens geradas com câmera de *smartphone*, o acerto foi de 62,5%.


Com relação à certeza dos especialistas ao identificarem os mosquitos, eles tiveram dúvida em 81,66% das respostas, tiveram muita certeza em 15% das respostas, e tiveram pouca certeza em 3,33% das respostas. Quando em dúvida, os especialistas acertaram 57,14% das vezes. Quando eles tinham muita certeza sobre a resposta, o acerto foi de 33,33%, e quando houve pouca certeza sobre a resposta, o acerto foi de 0%.

Desta forma, percebe-se que os especialistas não tem segurança em identificar os mosquitos através de imagens. O motivo se dá, provavelmente, ao fato de que eles não podem verificar outros aspectos do espécime observado, além dos que aparecem nas imagens.

4.4.1 Matriz de Confusão

A matriz de confusão da classificação dos especialistas permite conhecer melhor a dificuldade na identificação da espécie e sexo dos mosquitos. A matriz pode ser visualizada na Figura 26.

Figura 26 – Matriz de confusão da classificação dos especialistas.



Fonte: Autor.

De forma geral, os especialistas tiveram pouca dificuldade em identificar o sexo dos mosquitos. Isso pode ser verificado na matriz, quando uma classe é prevista incorretamente, o maior erro corresponde ao mosquito do mesmo sexo mas da outra espécie. Por exemplo, ao tentar prever a classe 0 - *Aedes aegypti* macho, somente teve erro com a classe 2 - *Aedes albopictus* macho.

A espécie *Aedes aegypti* foi a que os especialistas tiveram maior facilidade em identificar, tendo 73,33% de assertividade em se identificar o macho (classe 0) e 60% de assertividade em se identificar a fêmea (classe 1). A identificação dos mosquitos da espécie *Aedes albopictus* se mostrou mais complexa, ao tentar identificar o macho (classe 2), os especialistas tiveram apenas 40% de acerto, enquanto o macho da espécie *Aedes aegypti* teve erro de 46,67%. O mesmo acontece ao tentar identificar a fêmea da espécie *Aedes albopictus* (classe 3), que obteve 33,33% de acerto, contra 46,67% de erro da classe 1.

A confusão dos especialistas com relação às espécies dos mosquitos se dá pelo fato de nem todas as imagens exibirem o tórax dos mosquitos, já que o desenho que compõe o tórax é uma das principais características para diferenciar as espécies. Por outro lado, o sexo dos espécimes pode ser distinguido através das antenas, que aparecem de forma mais nítida em boa parte das imagens.

4.5 Análise Geral dos Resultados


Em sùmula, este capítulo apresentou os resultados dos experimentos de classificação de imagens de mosquitos em três bases de imagens, utilizando as técnicas de extração de atributos ACC, GLCM e Momentos de HU, além dos classificadores KNN, SVM, RF e MLP. Também foi exibido o resultado da classificação visual feito por especialistas.

Como regra geral dos resultados de qualidade apresentados neste estudo, pode-se afirmar que o extrator GLCM unido ao classificador RF é a melhor combinação para classificar imagens de mosquitos. Quando se observa a média das três bases de imagens, a acurácia dessas duas técnicas obtém 97,55%.


Quando lidamos com a classificação binária para identificar quais os mosquitos podem transmitir doenças, a acurácia do GLCM com o RF ficou em 99,22%. Ao tempo que a classificação composta, a qual apresenta uma maior complexidade por lidar com bases de imagens distintas, alcançou uma acurácia de 92,13%.

Boa parte do sucesso em identificar mosquitos através de imagens, da-se pela escolha do extrator GLCM. Os atributos obtidos por este extrator conseguem gerar um melhor agrupamento das classes, facilitando a classificação dos espécies. A Figura 27 exhibe os gráficos de dispersão para cada um dos extratores GLCM e Momentos de Hu. Os gráficos utilizam a base de imagens de câmera de *smartphone*, para a exibição em duas dimensões foram escolhidos os dois atributos que melhor representam os agrupamentos das classes.

Figura 27 – Gráficos de dispersão dos extratores GLCM e Momentos de Hu. As classes são definidas como: Classe 0 - *Aedes aegypti* Macho; Classe 1 - *Aedes aegypti* Fêmea; Classe 2 - *Aedes albopictus* Macho; e Classe 3 - *Aedes albopictus* Fêmea.



(a) Gráfico de dispersão - GLCM.



(b) Gráfico de dispersão - Momentos de Hu.

Fonte: Autor.

Na Figura 27a é possível visualizar que o GLCM consegue criar atributos os quais

permitem que as classes sejam quase linearmente separáveis, facilitando assim, o problema de classificação. Em contrapartida, no gráfico gerado a partir do extrator Momentos de Hu (Figura 27b), percebe-se que as classe ficam sobrepostas uma as outras, o que dificulta criar uma boa margem de separação entre as classes.

Com relação ao tempo, o GLCM junto com o RF se mostrou eficiente tanto para o treinamento do modelo, quanto para o teste das imagens. Neste sentido, o tempo de treino foi abaixo de 17 ms e o tempo de teste foi abaixo de 6 ms em todos os experimentos realizados. Com os tempos obtidos, é possível utilizar a metodologia para classificar os mosquitos em *frames* de video em tempo real sem a geração de gargalo.

Os resultados mostraram que a metodologia proposta é superior aos especialistas humanos no quesito de identificação de mosquitos através de imagens. Os especialistas obtiveram uma acurácia média de 51,66%, a baixa acurácia é justificada pela limitação da imagem, o que impossibilita visualizar várias partes do corpo do mesmo espécime.

Ao comparar os resultados das bases de imagens da câmera macro com a câmera de *smartphone* fica claro que um equipamento de captura mais simples e sem poder de *zoom*, como é o caso da câmera de *smartphone*, é capaz de gerar imagens de mosquitos boas o suficiente para permitirem sua identificação. Isto pôde ser comprovado na classificação única, no qual os resultados de acurácia da câmera de *smartphone* foram tão bons quantos os da base da câmera macro, e na classificação pelos especialistas, que tiveram uma maior assertividade com as fotos da câmera de *smartphone*.

A Tabela 11 apresenta uma confrontação de dados tais como, quantidade de imagens, quantidade de classes e o melhor resultado obtidos neste capítulo com os trabalhos citados na seção 2.1.

Tabela 11 – Apresentação dos dados de trabalhos relacionados à identificação de mosquitos.

Trabalho	Imagens	Classes	Melhor Resultado
Autor (2021)	320	4	99,38%
Okayasu et al. (2019)	14.400	3	95,50%
Huang et al. (2018)	83.624	2	98%
Minakshi, Bharti e Chellappan (2018)	303	9	90,03%
Fuchida et al. (2017)	400	3	98,90%
Minakshi, Bharti e Chellappan (2017)	60	7	84,50%

Fonte: Autor.

Na tabela, é possível visualizar que os trabalhos citados tem bons resultados para resolver o problema de classificação de mosquito, destacando que o presente estudo apresentou resultado bastante satisfatório dentre os expostos, com 99,38% de acurácia. Ressalta-se que cada trabalho possui uma metodologia aplicada em base de imagens

própria, as quais utilizam diferentes critérios de avaliação. Este contexto impede que uma comparação precisa, entre os resultados dos estudos, seja realizada.

5 Conclusões e Sugestões para Trabalhos Futuros

Neste capítulo são apresentadas as conclusões e sugestões para melhorias ou continuação deste trabalho.

5.1 Conclusões

Este estudo abordou a importância em se identificar mosquitos que podem ser vetores de doenças afim de auxiliar órgãos de controle de endemias a combater e prevenir surto de doenças transmitidas por mosquitos, como dengue, *chikungunya*, *zika* e febre amarela.

Após a aquisição dos espécimes dos mosquitos foi construída três bases de imagens utilizando três equipamentos de captura distintos, obtendo o total de 800 imagens. As bases contém imagens dos mosquitos das espécies *Aedes aegypti* e *Aedes albopictus* dos sexos masculino e feminino, que formam categorizadas em quatro classes.

A utilização dos extratores de característica juntamente com os classificadores permitiu comprovar que a combinação do GLCM com o RF é o melhor metodologia para resolver o problema de identificação de mosquitos em imagens digital. Esta metodologia atingiu uma acurácia de 97,55% na média das três bases de dados em um tempo médio de teste de 4,62 ms. Sendo que a melhor acurácia obtida foi de 99,38% ao classificar a base de imagens de câmera macro.

Através dos experimentos realizados também foi possível constatar que câmeras mais simples como as de *smartphone* geram imagens boas o suficiente para que seja possível realizar a identificação dos mosquitos, o que possibilita uma maior praticidade e um menor custo para obter as imagens dos mosquitos.

Por fim, este estudo contribui com o estado da arte propondo uma nova metodologia para a classificação de mosquitos, inovando ao acrescentar o sexo do mosquito como características para identificação.

5.2 Sugestões para Trabalhos Futuros

A seguir, são descritas as sugestões de melhorias ou continuação para este trabalho.

- Aumentar a base de dados com uma maior variedade de espécies e em ambientes diversos.

- Realizar a segmentação dos mosquitos nas imagens.
- Identificar outras espécies de mosquitos inclusive diferenciando os mosquitos de outros insetos.
- Otimizar a metodologia para aplicar em dispositivos móveis.

Referências

- AFFONSO, E. T. et al. Uso redes neurais multilayer perceptron (mlp) em sistema de bloqueio de websites baseado em conteúdo. *Mecânica Computacional*, v. 29, n. 93, p. 9075–9090, 2010. Citado na página 45.
- BARAKAT, R. D. M. Lagarta pintada, quem foi que te picou? A implementação da abordagem eco-bio-social em ambiente escolar para a vigilância ativa no controle do *Aedes aegypti*. Universidade Estadual do Ceará, 2019. Citado na página 48.
- BARALDI, A.; PANNIGIANI, F. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE transactions on geoscience and remote sensing*, IEEE, v. 33, n. 2, p. 293–304, 1995. Citado na página 39.
- BARRETO, C. E.; GUEDES, R. N.; SOUZA, R. C. P. de. Avaliação da eficácia do *Bacillus thuringiensis* var. *israelensis* no controle de formas imaturas do *Aedes (stegomyia) aegypti* (linnaeus, 1762) em ambiente de laboratório. *EntomoBrasilis*, Entomologistas do Brasil, v. 1, n. 1, p. 10–13, 2008. Citado na página 25.
- BISHOP, C. M. et al. *Neural networks for pattern recognition*. [S.l.]: Oxford university press, 1995. Citado na página 44.
- BRADY, O. J. et al. Refining the global spatial limits of dengue virus transmission by evidence-based consensus. *PLoS neglected tropical diseases*, Public Library of Science, v. 6, n. 8, 2012. Citado na página 25.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001. Citado na página 43.
- CASTRO, L. N. d.; FERRARI, D. G. Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações. São Paulo: Saraiva, 2016. Citado 2 vezes nas páginas 41 e 44.
- CONSOLI, R.; OLIVEIRA, R. D. Principais mosquitos de importância sanitária no Brasil. 1ª reimpressão: Editora fiocruz. Rio de Janeiro, 1998. Citado 2 vezes nas páginas 32 e 34.
- COSTA, A. A. M. et al. Uma abordagem centrada na filtragem colaborativa para redução do custo computacional do método k-nearest neighbors. Universidade Federal de Campina Grande, 2014. Citado na página 41.
- COVER, T.; HART, P. Nearest neighbor pattern classification. *IEEE transactions on information theory*, IEEE, v. 13, n. 1, p. 21–27, 1967. Citado na página 40.
- EBRAHIMPOUR, H.; KOUZANI, A. Face recognition using bagging knn. In: SN. *International Conference on Signal Processing and Communication Systems (ICSPCS'2007) Australia, Gold Coast*. [S.l.], 2007. p. 17–19. Citado na página 40.
- ERPEN, L. R. C. Reconhecimento de padrões em imagens por descritores de forma. 2004. Citado na página 38.

- FUCHIDA, M. et al. Vision-based perception and classification of mosquitoes using support vector machine. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 7, n. 1, p. 51, 2017. Citado 3 vezes nas páginas 25, 31 e 73.
- GEVERT, V. G. et al. Modelos de regressão logística, redes neurais e support vector machine (svm s) na análise de crédito a pessoas jurídicas. *RECEN-Revista Ciências Exatas e Naturais*, v. 12, n. 2, p. 269–293, 2010. Citado 2 vezes nas páginas 41 e 42.
- GÖLDI, E. A. *Os mosquitos no Pará: reunião de quatro trabalhos sobre os mosquitos indígenas, principalmente as espécies que molesta o homem*. [S.l.]: C. Wiegandt, 1905. v. 4. Citado na página 33.
- GÓMEZ, S. N. *Random forests estocástico*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul, 2012. Citado na página 43.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento digital de imagens*. [S.l.]: Pearson Educación, 2009. Citado 2 vezes nas páginas 36 e 37.
- HALSTEAD, S. B. Dengue. *The lancet*, Elsevier, v. 370, n. 9599, p. 1644–1652, 2007. Citado na página 25.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, n. 6, p. 610–621, 1973. Citado na página 38.
- HU, M.-K. Visual pattern recognition by moment invariants. *IRE transactions on information theory*, IEEE, v. 8, n. 2, p. 179–187, 1962. Citado na página 40.
- HUANG, J. et al. Image indexing using color correlograms. In: IEEE. *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. [S.l.], 1997. p. 762–768. Citado na página 38.
- HUANG, L.-P. et al. A vector mosquitoes classification system based on edge computing and deep learning. In: IEEE. *2018 Conference on Technologies and Applications of Artificial Intelligence (TAAI)*. [S.l.], 2018. p. 24–27. Citado 3 vezes nas páginas 25, 31 e 73.
- JONES, R. et al. Arbovirus vectors of epidemiological concern in the americas: A scoping review of entomological studies on zika, dengue and chikungunya virus vectors. *Plos one*, Public Library of Science San Francisco, CA USA, v. 15, n. 2, p. e0220753, 2020. Citado na página 32.
- KHIRADE, S. D.; PATIL, A. Plant disease detection using image processing. In: IEEE. *2015 International conference on computing communication control and automation*. [S.l.], 2015. p. 768–771. Citado na página 37.
- KRAEMER, M. U. et al. The global compendium of *Aedes aegypti* and *Ae. albopictus* occurrence. *Scientific data*, Nature Publishing Group, v. 2, n. 1, p. 1–8, 2015. Citado na página 25.
- LIPPMANN, R. P. Pattern classification using neural networks. *IEEE communications magazine*, IEEE, v. 27, n. 11, p. 47–50, 1989. Citado na página 37.

LOPES, N.; NOZAWA, C.; LINHARES, R. E. C. Características gerais e epidemiologia dos arbovírus emergentes no Brasil. *Revista Pan-Amazônica de Saúde*, v. 5, n. 3, p. 10–10, 2014. Citado na página 34.

MALVIYA, A. V.; LADHAKE, S. A. Pixel based image forensic technique for copy-move forgery detection using auto color correlogram. *Procedia Computer Science*, Elsevier, v. 79, p. 383–390, 2016. Citado na página 38.

MARCONDES, C. B. Entomologia médica e veterinária. In: *Entomologia médica e veterinária*. [S.l.: s.n.], 2011. p. 526–526. Citado 2 vezes nas páginas 33 e 34.

MARTINS, G. B. Processamento e análise de vídeos utilizando floresta de caminhos ótimos. Universidade Estadual Paulista (UNESP), 2016. Citado na página 38.

MINAKSHI, M.; BHARTI, P.; CHELLAPPAN, S. Identifying mosquito species using smart-phone cameras. In: *IEEE. 2017 European Conference on Networks and Communications (EuCNC)*. [S.l.], 2017. p. 1–6. Citado 2 vezes nas páginas 29 e 73.

MINAKSHI, M.; BHARTI, P.; CHELLAPPAN, S. Leveraging smart-phone cameras and image processing techniques to classify mosquito species. In: *Proceedings of the 15th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*. [S.l.: s.n.], 2018. p. 77–86. Citado 3 vezes nas páginas 25, 29 e 73.

Ministério da Saúde. Monitoramento dos casos de arboviroses urbanas transmitidas pelo *Aedes aegypti* (dengue, chikungunya e zika), semanas epidemiológicas 1 a 50, 2020. *Boletim Epidemiológico | Secretaria de Vigilância em Saúde | Ministério da Saúde*, v. 51, n. 51, 2020. Citado 2 vezes nas páginas 25 e 35.

Ministério da Saúde. Situação epidemiológica da febre amarela no monitoramento 2019/2020. *Boletim Epidemiológico | Secretaria de Vigilância em Saúde | Ministério da Saúde*, v. 51, n. 46, 2020. Citado na página 35.

MOLZ, R. F. Uma metodologia para o desenvolvimento de aplicações de visão computacional utilizando um projeto conjunto de hardware e software. 2001. Citado na página 40.

NETO, C. D. G. Identificação de fitofisionomias de cerrado no parque nacional de Brasília utilizando random forest aplicado a imagens de alta e média resoluções espaciais. *CEP*, v. 12, p. 010, 2018. Citado na página 43.

NETO, F. C. Descrição da colonização de *Aedes aegypti* na região de São José do Rio Preto, São Paulo. *Revista da Sociedade Brasileira de Medicina Tropical*, SciELO Brasil, v. 30, n. 4, p. 279–285, 1997. Citado na página 25.

OKAYASU, K. et al. Vision-based classification of mosquito species: Comparison of conventional and deep learning methods. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 9, n. 18, p. 3935, 2019. Citado 2 vezes nas páginas 30 e 73.

OLMEDO, M. T. C. et al. *Geomatic approaches for modeling land change scenarios*. [S.l.]: Springer, 2018. Citado na página 44.

OTSU, N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 9, n. 1, p. 62–66, 1979. Citado na página 52.

- PRINA, B. Z.; TRENTIN, R. Gmc: Geração de matriz de confusão a partir de uma classificação digital de imagem do arcgis R . *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, v. 17, p. 131–139, 2015. Citado na página 58.
- RODRIGUEZ, A. A. D. et al. A circle detection method proposal for image processing based on hu invariant moments, hough transform, and template matching= proposta de um método de detecção de círculos por processamento de imagens baseado em momentos de hu, transformada de hough e template matching. [sn], 2016. Citado na página 40.
- SANTOS, E. M. d. et al. Teoria e aplicação de support vector machines à aprendizagem e reconhecimento de objetos baseado na aparência. Universidade Federal de Campina Grande, 2002. Citado na página 41.
- SCHATZMAYR, H. G. et al. An outbreak of dengue virus at Rio de Janeiro-1986. Instituto Oswaldo Cruz, 1986. Citado na página 25.
- SHEHA, M. A.; SHARWY, A.; MABROUK, M. S. Automated imaging system for pigmented skin lesion diagnosis. *International Journal of Advanced Computer Science and Applications*, v. 7, n. 10, 2016. Citado na página 39.
- SILVA, S. F. d. et al. Realimentação de relevância via algoritmos genéticos aplicada à recuperação de imagens. Universidade Federal de Uberlândia, 2007. Citado na página 38.
- SOLOMON, C.; BRECKON, T. *Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em Matlab*. [S.l.]: Grupo Gen-LTC, 2000. Citado na página 37.
- SOUZA, F. A. A. d. *Análise de desempenho da rede neural artificial do tipo multilayer perceptron na era multicore*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2012. Citado na página 45.
- TELOKEN, A. et al. Estudo comparativo entre os algoritmos de mineração de dados random forest e j48 na tomada de decisão. *Simpósio de Pesquisa e Desenvolvimento em Computação*, v. 2, n. 1, 2016. Citado na página 43.
- VAPNIK, V. N. *The nature of statistical learning theory*. [S.l.]: Spring - Verlag New York, 1995. Citado na página 41.
- WHO, W. H. O. et al. *WHO.(2020) Dengue and severe dengue*. 2020. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/dengue-and-severe-dengue>>. Citado na página 25.

Anexos

ANEXO A – Formulário de Identificação de Mosquitos Através de Imagens

Formulário aplicado aos especialistas da Unidade de Vigilância de Zoonoses da cidade de Sobral-CE para identificação de imagens de mosquitos.

Formulário de identificação de mosquitos através de imagens

Nome do Especialista: _____

Cargo/Função: _____

Data: ____/____/____

Orientações: Identifique os mosquitos que serão exibidos nas imagens. As possíveis classes dos mosquitos são *Aedes aegypti* macho, *Aedes aegypti* fêmea, *Aedes albopictus* macho e *Aedes albopictus* fêmea.

Ao identificar cada imagem diga o seu grau de certeza com relação a resposta assinalada, sendo:

1. Pouca certeza sobre a resposta.
2. Em dúvida sobre a resposta.
3. Muita certeza sobre a resposta.

Imagem 01:

- | | |
|-------------------------------|-----------------------------------|
| a) <i>Aedes aegypti</i> macho | c) <i>Aedes albopictus</i> macho |
| b) <i>Aedes aegypti</i> fêmea | d) <i>Aedes albopictus</i> fêmea. |

Grau de certeza:

1	2	3
---	---	---

Imagem 02:

- | | |
|-------------------------------|-----------------------------------|
| a) <i>Aedes aegypti</i> macho | c) <i>Aedes albopictus</i> macho |
| b) <i>Aedes aegypti</i> fêmea | d) <i>Aedes albopictus</i> fêmea. |

Grau de certeza:

1	2	3
---	---	---

Imagem 03:

- | | |
|-------------------------------|-----------------------------------|
| a) <i>Aedes aegypti</i> macho | c) <i>Aedes albopictus</i> macho |
| b) <i>Aedes aegypti</i> fêmea | d) <i>Aedes albopictus</i> fêmea. |

Grau de certeza:

1	2	3
---	---	---

Imagem 04:

- | | |
|-------------------------------|-----------------------------------|
| a) <i>Aedes aegypti</i> macho | c) <i>Aedes albopictus</i> macho |
| b) <i>Aedes aegypti</i> fêmea | d) <i>Aedes albopictus</i> fêmea. |

Grau de certeza:

1	2	3
---	---	---

Imagem 05:

- | | |
|-------------------------------|-----------------------------------|
| a) <i>Aedes aegypti</i> macho | c) <i>Aedes albopictus</i> macho |
| b) <i>Aedes aegypti</i> fêmea | d) <i>Aedes albopictus</i> fêmea. |

Grau de certeza:

1	2	3
---	---	---

Imagem 06:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 07:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 08:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 09:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 10:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 11:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 12:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 13:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 14:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 15:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 16:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 17:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 18:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 19:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Imagem 20:

- a) *Aedes aegypti* macho
- b) *Aedes aegypti* fêmea

- c) *Aedes albopictus* macho
- d) *Aedes albopictus* fêmea.

Grau de certeza:

1	2	3
---	---	---

Quais foram as suas dificuldades em identificar os mosquitos através das imagens?
