



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

GERALDO PIRES CORDEIRO JÚNIOR

**Reconhecimento de espécies de mosquitos por meio de métodos computacionais
inteligentes baseados em aprendizagem profunda**

Recife
2022

GERALDO PIRES CORDEIRO JÚNIOR

**Reconhecimento de espécies de mosquitos por meio de métodos computacionais
inteligentes baseados em aprendizagem profunda**

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Ciência da
Computação da Universidade Federal de
Pernambuco, como requisito parcial para a
obtenção do título de Mestre em Ciência da
Computação. Área de Concentração:
Inteligência Computacional

Orientador: Prof. D.Sc. Leandro Maciel Almeida

Recife

2022

Catálogo na fonte:
Bibliotecária Luiza de Oliveira, CRB4-1316

C794r Cordeiro Júnior, Geraldo Pires
Reconhecimento de espécies de mosquitos por meio de métodos computacionais inteligentes baseados em aprendizagem profunda /Geraldo Pires Cordeiro Júnior. – 2022.
89 f.: il., tab.

Orientador: Leandro Maciel Almeida.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIN, Ciência da Computação, Recife, 2022.

Inclui referências.

1. Mosquitos. 2. Vetores. 3. Arboviroses. 4. Machine learning. 5. Deep learning I. Almeida, Leandro Maciel (orientador). II. Título.

006.31 CDD (23. ed.) UFPE - CCEN 2022-146

Geraldo Pires Cordeiro Júnior

“Reconhecimento de espécies de mosquitos por meio de métodos computacionais inteligentes baseados em aprendizagem profunda”

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação. Área de Concentração: Inteligência Computacional

Aprovado em: 18/05/2022.

BANCA EXAMINADORA

Prof. Dr. Fernando Maciano de Paula Neto
Centro de Informática/UFPE

Profa. Dra. Rosângela Maria Rodrigues Barbosa
Centro de Pesquisas Aggeu Magalhães / FIOCRUZ

Prof. Dr. Leandro Maciel Almeida
Centro de Informática / UFPE
(Orientador)

RESUMO

As doenças transmitidas por mosquitos vetores expressam um grande perigo à sociedade. Arboviroses como Dengue, Zika, Febre Amarela e Chikungunya vem causando alto número de mortes, além de diminuir a qualidade de vida das pessoas e causarem outras doenças, como é o caso de microcefalia em recém-nascidos, por conta do vírus da Zika, e impactarem a economia. Ações que visem o controle dos vetores se mostraram eficazes no combate a essas doenças. Entretanto, em áreas em que essas doenças são endêmicas, os vetores coexistem com outros mosquitos que não transmitem doenças, sendo essencial a identificação desses mosquitos, para que se possa analisar a densidade e entender mais sobre a população deles; todavia, é necessário a atuação de um especialista, além de muitas vezes ser um trabalho fatigante. Observando a importância da identificação desses vetores e os problemas das atuais técnicas de identificação, este estudo propõe um modelo computacional inteligente para a classificação automática de mosquitos vetores, baseado em imagens. Para isso, foi construída uma base com 5.432 imagens de mosquitos de 3 espécies: *Aedes aegypti*, *Aedes albopictus* e *Culex quinquefasciatus*. Foram utilizadas três redes convolucionais: VGG16, ResNet50 e EfficientNetB0. O modelo de *Deep Learning* que obteve maior resultado foi a VGG16, com acurácia de 95%, mostrando-se eficiente na identificação das espécies estudadas.

Palavras-chave: mosquitos; vetores; arboviroses; *machine learning*; *deep learning*.

ABSTRACT

Diseases transmitted by mosquito vectors pose a great danger to society. Arboviruses such as Dengue, Zika, Yellow Fever and Chikungunya have been causing a high number of deaths, in addition to reducing people's quality of life and causing other diseases, such as microcephaly in newborns, due to the Zika virus, and impact the economy. Actions aimed at vector control have proved to be effective in combating these diseases. However, in areas where these diseases are endemic, the vectors coexist with other mosquitoes that do not transmit diseases, and it is essential to identify these mosquitoes, in order to analyze their density and understand more about their population; however, the performance of a specialist is necessary, in addition to often being a tiring job. Noting the importance of identifying these vectors and the problems of current identification techniques, this study proposes an intelligent computational model for the automatic classification of mosquito vectors, based on images. For this, a database was built with 5.432 images of mosquitoes of 3 species: *Aedes aegypti*, *Aedes albopictus* and *Culex quinquefasciatus*. Three convolutional networks were used: VGG16, ResNet50 and EfficientNetB0. The Deep Learning model that obtained the best results was VGG16, with an accuracy of 95%, proving to be efficient in identifying the species studied.

Keywords: mosquitoes; vectors; arboviruses; machine learning; deep learning.

LISTA DE FIGURAS

Figura 1 –	Vista dorsal da fêmea do mosquito <i>A. aegypti</i>	21
Figura 2 –	Visão comparativa dorsal de <i>A. aegypti</i> e de <i>A. albopictus</i>	22
Figura 3 –	Comparativo entre o <i>Aedes</i> e o <i>C. quinquefasciatus</i>	22
Figura 4 –	Estrutura do modelo <i>Perceptron</i>	24
Figura 5 –	Exibição gráfica de um conjunto linearmente separável	25
Figura 6 –	Estrutura de uma rede multicamada: pode-se observar que a cada camada a rede consegue modelar melhor os limites de separação entre os conjuntos	26
Figura 7 –	Estrutura de uma rede neural profunda de 5 camadas, sendo a primeira a camada de entrada dos dados, no meio três camadas escondidas e por fim a camada de saída.....	27
Figura 8 –	Operação de convolução: o filtro é movido pela imagem para obter uma representação de características da imagem	29
Figura 9 –	Operação de <i>Max pooling</i> : de cada região é escolhido o maior valor, tendo por finalidade diminuir o tamanho espacial da representação da camada convolucional.....	30
Figura 10 –	Arquitetura da rede LeNet-5 mostrando os principais elementos de uma CNN: convolução, pooling e camada totalmente conectada.....	30
Figura 11 –	Configurações do modelo VGG.....	32
Figura 12 –	(a) Arquitetura da rede ResNet. (b) Bloco residual.....	33
Figura 13 –	Arquitetura da rede EfficientNet	34
Figura 14 –	Microscópio utilizado nas primeiras tentativas de captura de imagens (Microscópio Digital RoHS 2.0 MP)	47
Figura 15 –	Microscópio escolhido para as capturas, por possuir uma estrutura de suporte fixa (Microscópio HT-60S).....	48
Figura 16 –	Modelo utilizado para posicionamento dos espécimes em um local fixo na base do microscópio	49
Figura 17 –	Pinças de precisão utilizadas para manipulação dos mosquitos durante o processo de captura de imagens	49

Figura 18 –	Exemplos de cada tipo de mosquito (espécie/sexo) utilizados na pesquisa: <i>A. aegypti</i> fêmea (a), <i>A. aegypti</i> macho (b), <i>A. albopictus</i> fêmea (c), <i>A. albopictus</i> macho (d), <i>C. quinquefasciatus</i> fêmea (e), <i>C. quinquefasciatus</i> macho (d)	50
Figura 19 –	Posições de captura das imagens para cada mosquito, visando a obtenção de diferentes ângulos dos espécimes	51
Figura 20 –	Antes (esquerda) e depois (direita) da aplicação de nitidez e contraste	53
Figura 21 –	Aplicação de segmentação na imagem para remover o excesso de plano de fundo	53
Figura 22 –	Quantitativo da base de imagens	54
Figura 23 –	Pipeline do esquema de classificação	61
Figura 24 –	Divisão da base de imagens	63
Figura 25 –	Fluxograma para a construção do experimento	64
Figura 26 –	VGG16 - curvas de aprendizado e erro dos conjuntos de treinamento e validação	68
Figura 27 –	EfficientNetB0 - curvas de aprendizado e erro dos conjuntos de treinamento e validação	68
Figura 28 –	ResNet50 - curvas de aprendizado e erro dos conjuntos de treinamento e validação	69
Figura 29 –	Comparação dos tempos de treinamento	70
Figura 30 –	Comparação dos tempos de inferência de uma imagem de mosquito	70
Figura 31 –	VGG16 - Matriz de confusão utilizando o conjunto de teste	72
Figura 32 –	Comparação das semelhanças visuais entre <i>A. aegypti</i> macho (a) e <i>A. albopictus</i> macho (b)	73
Figura 33 –	Comparação das semelhanças visuais entre <i>A. albopictus</i> fêmea (a) e <i>A. albopictus</i> macho (b)	74
Figura 34 –	EfficientNetB0 - Matriz de confusão utilizando o conjunto de teste ..	75
Figura 35 –	VGG16 - Curva ROC utilizando o conjunto de teste	76
Figura 36 –	EfficientNetB0 - Curva ROC utilizando o conjunto de teste	76

LISTA DE TABELAS

Tabela 1 –	Classificação da pesquisa	37
Tabela 2 –	Quantidade de artigos após as etapas do mapeamento sistemático ..	40
Tabela 3 –	Estudos resultantes do mapeamento sistemático	40
Tabela 4 –	Transformações aplicadas no aumento de dados e seus valores	56
Tabela 5 –	Atribuição de pesos aos tipos de mosquitos baseados nas quantidades de cada tipo.....	56
Tabela 6 –	Configuração final dos hiperparâmetros da VGG16	65
Tabela 7 –	Configuração final dos hiperparâmetros da ResNet50	65
Tabela 8 –	Configuração final dos hiperparâmetros da EfficientNetB0	66
Tabela 9 –	Médias das acurácias de treinamento e validação	69
Tabela 10 –	VGG16- Métricas de avaliação do conjunto de teste.....	71
Tabela 11 –	EfficientNetB0 - Métricas de avaliação do conjunto de teste	71

LISTA DE ABREVIATURAS E SIGLAS

AI	<i>Artificial Intelligence</i> (Inteligência Artificial)
ANN	<i>Artificial Neural Networks</i> (Redes Neurais Artificiais)
CNN	<i>Convolutional Neural Network</i> (Redes Neurais Convolucionais)
GPL	<i>General Public License</i>
ML	<i>Machine Learning</i> (Aprendizagem de Máquina)
MLP	<i>Multilayer Perceptron</i>
VGG	<i>Visual Geometry Group</i>
ResNet	<i>Residual Network</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	MOTIVAÇÃO E JUSTIFICATIVA.....	14
1.2	OBJETIVO GERAL.....	15
1.3	OBJETIVOS ESPECÍFICOS	15
1.4	ORGANIZAÇÃO DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	ZOONOSES	17
2.2	ARBOVIROSES E SEUS VETORES	18
2.2.1	Taxonomia.....	21
2.3	APRENDIZAGEM DE MÁQUINA	23
2.3.1	Redes Neurais Artificiais	23
2.3.2	Aprendizagem profunda e classificação de imagens.....	26
2.3.3	Redes Neurais Convolucionais (CNNs)	28
2.3.3.1	Componentes	28
2.3.3.1.1	<i>Camada Convolucional</i>	28
2.3.3.1.2	<i>Camada de Pooling</i>	29
2.3.3.1.3	<i>Camada totalmente conectada</i>.....	30
2.3.3.2	VGG: Visual Geometry Group	30
2.3.3.3	Resnet: Residual Network	32
2.3.3.4	EfficientNet	33
2.4	INTELIGÊNCIA ARTIFICIAL E DOENÇAS ZOONÓTICAS.....	34
2.5	CONSIDERAÇÕES DO CAPÍTULO.....	35
3	METODOLOGIA DE PESQUISA.....	37
3.1	CLASSIFICAÇÃO METODOLÓGICA.....	37
3.2	REVISÃO DA LITERATURA	37
3.2.1	Estratégia de busca.....	38

3.2.2	Cr�terios de Inclus�o e Exclus�o.....	38
3.2.3	Mapeamento.....	39
3.3	TRABALHOS RELACIONADOS	44
3.4	CONSIDERA��ES DO CAP�TULO.....	46
4	MATERIAIS E M�TODOS	47
4.1	EQUIPAMENTO UTILIZADO	47
4.2	AMOSTRAS	50
4.3	M�TODOS DE CAPTURA.....	51
4.4	PR�-PROCESSAMENTO DAS IMAGENS	52
4.5	SOLU���ES PARA O DESBALANCEAMENTO DA BASE	55
4.6	MODELOS E AJUSTES	57
4.7	M�TRICAS.....	58
4.8	PIPELINE DA CLASSIFICA��O.....	61
4.9	CONSIDERA��ES DO CAP�TULO.....	62
5	EXPERIMENTOS E RESULTADOS	63
5.1	CONSTRU��O DOS EXPERIMENTOS.....	63
5.2	EXPERIMENTOS	64
5.2.1	VGG16.....	64
5.2.2	ResNet50	65
5.2.3	EfficientNetB0	66
5.3	RESULTADOS E AN�LISES	67
5.4	DIFICULDADES E LIMITA���ES	77
5.5	CONSIDERA��ES DO CAP�TULO.....	77
6	CONCLUS�O E TRABALHOS FUTUROS	79
	REFER�NCIAS.....	82

1 INTRODUÇÃO

Nas últimas décadas, a quantidade de doenças infecciosas emergentes aumentou, representando uma grande ameaça à saúde global, à segurança e ao crescimento econômico. Destas, 75% são zoonóticas, doenças transmitidas de animais para humanos, direta e indiretamente, quando vetores, seres vivos que funcionam como veículos para transmissão de uma doença, são necessários para completar seu ciclo de vida (PEREIRA-DOS-SANTOS *et al.*, 2020).

As principais doenças transmitidas por vetores representam, juntas, cerca de 17% da estimativa global de doenças transmissíveis, causando mais de 700.000 mortes por ano. Dentre essas doenças, estão: Malária, Dengue, Filariose Linfática, Chikungunya, Zika, Febre Amarela, todas transmitidas por mosquitos (WHO, 2017). Sendo esses mosquitos vetores hematófagos que podem adquirir vírus humanos em seu trato intestinal (WU *et al.*, 2019).

O risco de infecção por certos patógenos virais é especialmente alto em cidades onde os mosquitos *Aedes* e *Culex* se reproduzem, por causa do habitat favorável e do contato próximo com os humanos. Uma abordagem que vem se mostrando eficaz contra esses tipos de doenças são ações direcionadas ao combate desses vetores (WHO, 2017). Merece destaque a identificação da espécie, como evidencia Jourdain (JOURDAIN *et al.*, 2018) e colaboradores, ao falarem que a identificação precisa de uma espécie que esteja envolvida na transmissão de um patógeno, o que é essencial para que possam ser compreendidos os mecanismos que governam um sistema biológico.

Em áreas em que as doenças transmitidas por mosquitos são endêmicas, os vetores coexistem com outros tipos de mosquitos que não têm a capacidade de transmitir doenças. Em locais como a Flórida (EUA), América do Sul, Uganda e sul da Índia, mais de 50 espécies de mosquitos coexistem com os vetores. Por isso é fundamental saber quais tipos de mosquitos estão presentes e qual a densidade, para assim aprender acerca da população de vetores (MINAKSHI *et al.*, 2020).

Em todo o mundo esse processo de identificação é feito por profissionais de saúde pública que colocam armadilhas para mosquitos, coletam esses mosquitos e os levam para laboratórios ou locais semelhantes. Depois, taxonomistas examinam visualmente cada espécime com um microscópio para descobrir o tipo do mosquito,

sendo esse um processo que leva horas por dia, cognitivamente cansativo e estressante para os taxonomistas (MINAKSHI *et al.*, 2020).

Os mosquitos adultos podem ser identificados utilizando métodos baseados em características morfológicas ou não-morfológicas (MEDLOCK *et al.*, 2018). A identificação morfológica é o método padrão utilizado, necessitando da presença de um especialista para realizar essa identificação. Além disso, algumas espécies possuem similaridades morfológicas, o que pode dificultar esse processo, necessitando o acesso a mais de um estágio de desenvolvimento do espécime, o que nem sempre é possível (JOURDAIN *et al.*, 2018).

A visão computacional é uma área de aplicação da Inteligência Artificial (*Artificial Intelligence* - AI) com a proposta de extrair informações de uma imagem para compreender seu conteúdo e resolver uma tarefa específica (DANUSER, 2011). Nesse contexto, métodos de aprendizagem profunda, como as Redes Neurais Convolucionais (*Convolutional Neural Network* - CNN), são utilizados para resolver problemas difíceis, como a classificação, segmentação e detecção de imagens (O'MAHONY *et al.*, 2019). Desde 2012, as CNNs tornaram-se a abordagem dominante para classificação de imagens (HE, T. *et al.*, 2019); e um dos principais pontos desse método computacional inteligente é a extração automática das características das imagens (ALOM *et al.*, 2018). As CNNs são utilizadas em uma série de tarefas, apresentando um ótimo desempenho em diferentes aplicações (SHARMA; JAIN; MISHRA, 2018).

Dados os desafios da classificação manual de mosquitos e o avanço das tecnologias de identificação baseadas em imagem, vem sendo estudada a aplicação dessas tecnologias no contexto desse problema. Na pesquisa de Kittichai (KITTI CHAI *et al.*, 2021), 11 espécies de mosquitos foram utilizadas em experimentos de detecção, sendo aplicada a rede YOLO e obtendo-se uma acurácia de 96%. Motta (MOTTA *et al.*, 2020) aplicou algoritmos de aprendizagem profunda na classificação de 3 espécies de mosquitos, realizando experimentos com 10 modelos computacionais; seu melhor resultado foi de 93,5% de acurácia. O trabalho de Park (PARK *et al.*, 2020) propôs-se analisar a classificação de 8 espécies de mosquitos, aplicando 3 modelos de aprendizagem profunda e obtendo, em seu melhor resultado, uma acurácia de 97,19%.

No contexto apresentado, essa pesquisa se propõe a contribuir na investigação do uso de modelos de aprendizagem profunda na classificação de mosquitos vetores. Nas próximas seções as motivações, justificativas e objetivos serão explanados.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

As doenças transmitidas por vetores caracterizam uma grande ameaça à saúde em todo o mundo. Além do alto número de mortes anuais, suas consequências afetam a qualidade de vida das pessoas (WHO, 2017). Desde 2015, no Brasil, as epidemias de Zika causaram um número significativo de casos de microcefalia em recém-nascidos expostos ao vírus da Zika no útero (CARVALHO, F. R. *et al.*, 2019).

O impacto dessas doenças para a economia é significativo. Para governos em países endêmicos, isso inclui custos com as atividades de controles de vetores, bem como a gestão dos casos; para as famílias, custos com medidas de proteção ou tratamento, a renda perdida por causa da redução da produtividade ou afastamento do trabalho por conta da doença ou dos cuidados com membros da família doentes. Olhando sob uma ótica macroeconômica, essas doenças vêm sendo associadas a um menor desenvolvimento econômico (WHO, 2017).

A identificação da espécie do vetor é uma das ações essenciais para se entender os mecanismos biológicos da transmissão de um patógeno (JOURDAIN *et al.*, 2018). Em áreas endêmicas, os vetores coexistem com outros tipos de mosquitos que não transmitem doenças, tornando-se essencial a identificação desses mosquitos, para analisar a densidade e entender mais sobre a população de vetores (MINAKSHI *et al.*, 2020). Além disso, dentre os vetores existem diferenças na capacidade de transmissão, então a identificação entre espécies de vetores também se mostra um ponto crítico para determinar o risco de transmissão ou potencial de surto (GOODWIN *et al.*, 2020). Entretanto, os principais métodos de identificação atuais demandam a necessidade de um especialista e, mesmo assim, pode ser difícil a identificação caso as espécies possuam similaridades (JOURDAIN *et al.*, 2018), além do trabalho de identificação ser cansativo e estressante para o taxonomista (MINAKSHI *et al.*, 2020).

Nesse contexto, o uso de métodos de visão computacional se mostram promissores (DANUSER, 2011), em especial a aplicação de métodos de aprendizagem profunda, como as CNNs, uma vez que, dentre os problemas em que são utilizadas, está a classificação de imagens (O'MAHONY *et al.*, 2019). O uso desses métodos dará

suporte à decisão dos especialistas, além de minimizar a fadiga causada pelo método manual de classificação.

1.2 OBJETIVO GERAL

O objetivo geral deste trabalho é desenvolver um modelo computacional inteligente, utilizando materiais de baixo custo, para viabilizar a implantação e o desenvolvimento do trabalho em locais com poucos recursos, permitindo, assim, o reconhecimento automático de espécies de mosquitos vetores de arboviroses, com o intuito da identificação auxiliar em ações de controle desses vetores.

1.3 OBJETIVOS ESPECÍFICOS

- Definir um método de captura de dados com base em equipamentos de baixo custo;
- Criar uma base de imagens de mosquitos vetores de arboviroses;
- Utilizar a base criada no processo de aprendizagem de modelos de classificação baseados em aprendizagem profunda;
- Avaliar os resultados obtidos a partir dos treinamentos dos modelos;
- Definir o modelo a ser proposto.

1.4 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado em 6 capítulos:

- Capítulo 1: contextualiza o tema, apresenta as motivações e justificativas da pesquisa e também os objetivos;
- Capítulo 2: exhibe a fundamentação teórica, dando uma visão explicativa de arboviroses e vetores, conceitos de aprendizagem de máquina e das métricas de desempenho utilizadas na pesquisa;
- Capítulo 3: o mapeamento sistemático da literatura é descrito, bem como os trabalhos resultantes dele;
- Capítulo 4: são detalhados os passos percorridos para a construção da base de imagens, mostrando o equipamento usado, a coleta das amostras de mosquitos, a técnica de captura, bem como os pré-processamentos aplicados às imagens;

- Capítulo 5: a construção dos modelos inteligentes é detalhada; os resultados são mostrados através de diversas visualizações e analisados;
- Capítulo 6: a conclusão do trabalho é apresentada, bem como suas limitações, dificuldades e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ZOONOSES

A partir do momento em que o ser humano deixa a vida nômade e se relaciona de modo diferente com a natureza, há mudança nas inter-relações entre sociedade, meio ambiente, agentes biológicos e vetores. Todavia, somente com a urbanização advinda da revolução industrial é que as condições de vida sofreram um rápido perecimento, e é nessa época que se iniciaram as investigações de complexos ciclos de zoonoses (RODRIGUES *et al.*, 2021).

As zoonoses são doenças transmitidas de animais para humanos e vice-versa, e são consideradas as primeiras doenças transmissíveis conhecidas (AWAIDY; AL HASHAMI, 2020). Muitos micro-organismos que causam doenças infecciosas para o ser humano têm como origem ciclos naturais envolvendo o vetor e animais selvagens. Entretanto, por conta de atividades humanas, como as atividades econômicas, muitos insetos, como os mosquitos, se adaptaram a viver junto ao homem, favorecendo a disseminação de patógenos para os humanos (REZENDE, R. B., 2021).

Mais de 30 novos patógenos humanos foram detectados nas últimas três décadas, sendo 75% deles de origem animal. Pode-se, assim, deslumbrar que esteja em maior proporção no futuro, devido a possíveis mutações, novas técnicas de diagnósticos e o surgimento de novas propriedades dos patógenos em causar doenças nos hospedeiros, seja homem ou animal; percebe-se, assim, a complexidade de previsão das zoonoses que poder-se-á se deparar (RODRIGUES *et al.*, 2021). Se faz oportuna, então, a criação de abordagens e atitudes inovadoras para auxiliarem nos procedimentos de prevenção às doenças relacionadas ao meio ambiente (RODRIGUES *et al.*, 2021). No próximo capítulo serão discutidas as arboviroses, doenças zoonóticas de grande impacto nas últimas décadas.

2.2 ARBOVIROSES E SEUS VETORES

As arboviroses, ou doenças arbovirais, são causadas por vírus e transmitidas para as pessoas por meio da picada de um artrópode infectado, sendo os mosquitos e carrapatos seus principais transmissores. As arboviroses de ressurgimento mais marcante nesse século foram: Zika, Dengue, Febre Amarela e Chikungunya (WILDER-SMITH et al., 2017).

O vírus da Zika foi descoberto em 1947, na Uganda, sendo isolado de um macaco Rhesus. Entretanto, somente em 1954 foram reportadas as primeiras infecções, durante um surto de icterícia na Nigéria, quando foi confirmada em três pacientes. Essa arbovirose ficou confinada nos primeiros 60 anos na zona equatorial entre a Ásia e a África (SONG et al., 2017).

No Brasil, a primeira transmissão do vírus da Zika foi no início de 2015, no Nordeste, e até o final desse ano tinha-se uma estimativa de 440.000 a 1.300.000 casos suspeitos. Foi notado também que casos de recém-nascidos com microcefalia estavam aumentando nas áreas afetadas pelo vírus, em setembro de 2015; em fevereiro de 2016 mais de 4.000 casos suspeitos de microcefalia foram reportados (SONG et al., 2017).

Em 2017, mais de 22.000 casos confirmados e 580.000 casos suspeitos foram reportados em 52 países ou territórios das Américas. Devido ao grande número de infecções e a relação com defeitos de neurodesenvolvimento congênitos, esta epidemia foi reconhecida como uma emergência internacional de saúde pública (PIERSON; DIAMOND, 2018).

O vírus da Dengue se apresenta em climas tropicais e subtropicais em todo o mundo (WORLD HEALTH ORGANIZATION, 2021). A primeira vez que foram relatados casos compatíveis com Dengue foi durante a Dinastia Jin (265 a 420 d.C.), entretanto, as primeiras epidemias confirmadas ocorreram no período de 1779-1780, na África, Ásia e América do Norte (SILVA; SANTOS; MARTINS, 2020). Nas Américas, o vírus da Dengue foi introduzido no período de 1600-1946 (SALLES et al., 2018); na segunda metade do século 20 houve um grande crescimento na transmissão de Dengue, com o ressurgimento global de Dengue e o surgimento de Dengue hemorrágica (SILVA; SANTOS; MARTINS, 2020). Estima-se que ocorram de 100 a 400 milhões de infecções a cada ano (WORLD HEALTH ORGANIZATION, 2021).

Existem quatro sorotipos de Dengue, significando que uma pessoa pode ser infectada quatro vezes, podendo a doença pode se manifestar de modo leve ou agudo; esta última podendo ser letal, chamada de Dengue grave (WORLD HEALTH ORGANIZATION, 2021).

Febre Amarela é uma doença hemorrágica viral. O termo “amarela” faz referência à icterícia que acomete alguns pacientes. Sendo endêmica em regiões tropicais da África e das Américas Central e do Sul (WORLD HEALTH ORGANIZATION, 2019), foi o maior problema de saúde pública do Brasil desde meados do século XIX até meados do século XX (FIOCRUZ, 2008). A primeira epidemia no Brasil é datada em 1685, ocorrida no Nordeste (DE OLIVEIRA FIGUEIREDO et al., 2020). A que ocorreu em meados do século XIX é relacionada com a chegada de um navio negreiro vindo de Nova Orleans, em 1849, atingindo 90.658 dos 266 mil habitantes do Rio de Janeiro, causando 4.160 mortes (FIOCRUZ, 2008). Nos anos 1928-1929 ocorreu outra epidemia de Febre Amarela no Rio de Janeiro (DE OLIVEIRA FIGUEIREDO et al., 2020).

Com a criação de uma vacina nos anos 30 e massiva campanha de combate ao vetor urbano da doença nos anos 40, os casos diminuíram sendo no Acre em 1942 o último caso urbano reportado dessa época. Entretanto, com a reinfestação de *Aedes aegypti* na década de 70, a doença se espalhou em várias regiões do Brasil, tendo um amplo ressurgimento no final de 2016. De acordo com o Ministério da Saúde, foram registrados 2.237 casos em humanos e 759 mortes no período entre dezembro de 2016 e junho de 2019 (DE OLIVEIRA FIGUEIREDO et al., 2020).

Chikungunya é uma arbovirose que, entre seus sintomas, estão: febre e fortes dores nas articulações, sendo, inclusive, esse último sintoma o motivo do seu nome. A palavra é derivada de outra na língua Kimakonde, e significa “contorcer-se”, que reflete a aparência curvada dos acometidos pelas dores nas articulações.

Identificado pela primeira vez em 1952 na Tanzânia, o vírus esteve isolado pelos 50 anos seguintes, causando ocasionais surtos na África e na Ásia; entretanto, a partir de 2004 se espalhou rapidamente na Ásia, África, Europa e nas Américas. Nos últimos anos nas Américas e no Caribe foram relatados 185 mil casos, sendo o Brasil representante de mais de 90% das ocorrências nas Américas (WORLD HEALTH ORGANIZATION, 2020).

A. aegypti é o principal vetor das arboviroses citadas. Em algumas áreas, *Aedes albopictus* também sustenta a transmissão, mesmo nos casos da ausência de *A. aegypti*.

Segundo a OMS (Organização Mundial da Saúde), ações que visem reduzir o contato do vetor com o ser humano e a sobrevivência do vetor podem diminuir ou até mesmo acabar com a transmissão dessas doenças. Entretanto, ressalta que o impacto dessas ações tem que ser analisado, para não interferir na biodiversidade e, assim, evitar que indivíduos não visados sejam impactados (WHO, 2017).

Tendo como significado do nome a expressão “odioso do Egito”, *A. aegypti* é um mosquito originário da África, sendo uma espécie sinantrópica, ou seja, muito adaptada a viver perto de pessoas. No Brasil, a sua primeira ocorrência se deu provavelmente no século XVI, devido à expansão do comércio marítimo junto com o tráfico de escravos; a segunda, na década de 1960 (VALLE et al., 2021).

Em 1947 foi lançado o Programa de Erradicação de *A. aegypti*, responsável pela eliminação da espécie por quase toda a América. Em 1958, no Brasil, a espécie foi considerada eliminada oficialmente, entretanto voltou a ser detectada a partir de 1967. Com a erradicação da Febre Amarela urbana, os programas de controle de *Aedes* ficaram em segundo plano, tendo como consequência uma reinfestação do continente. Isso mostra que um dos grandes desafios para o controle do vetor está na sustentabilidade do processo (VALLE et al., 2021).


A. aegypti é um mosquito essencialmente urbano, já o *A. albopictus* prefere locais mais rurais e vive geralmente na periferia das cidades; é chamado de “mosquito tigre asiático”, por conta das suas patas pretas e brancas, e por sua origem geográfica (VALLE et al., 2021).

O pernilongo, tendo, do ponto de vista epidemiológico, como principal espécie *Culex quinquefasciatus*, é um mosquito intradomiciliar, cosmopolita, ainda mais urbano que o *A. aegypti*. De coloração marrom, mais claro que *Aedes*, não apresenta características morfológicas marcantes, o que torna mais difícil a identificação das espécies desse grupo (VALLE et al., 2021). Entre as doenças que transmite está a Filariose Linfática, infecção parasitária causada pelos vermes *Wuchereria bancrofti*, *Brugia malayi* e *Brugia timori* (DESHPANDE et al., 2020); doença listada como uma das doenças tropicais negligenciadas mais importantes e a segunda principal causa de incapacidade permanente e de longo prazo no mundo (RAI et al., 2019).

2.2.1 Taxonomia

A estrutura de um *A. aegypti* adulto é formada por cabeça, tórax e abdômen, como vê-se na Figura 1. Os machos e as fêmeas se parecem, diferindo principalmente pelo formato das antenas; os machos possuem as antenas plumosas (OECD, 2018). O *A. aegypti* possui tonalidade escura, faixas pretas e brancas nas patas e o desenho que se assemelha a uma lira, instrumento musical de cordas, na parte dorsal do tórax, composta por escamas brancas (VALLE et al., 2021).


Figura 1 – Vista dorsal da fêmea do mosquito *A. aegypti*



Fonte: adaptado de (OECD, 2018)

A principal diferença entre *A. aegypti* e *A. albopictus* está no tórax (VALLE et al., 2021). Em *A. aegypti*, como já foi falado, o tórax possui um desenho semelhante a uma lira, em contrapartida, *A. albopictus* possui uma faixa branca mediano-longitudinal (Figura 2).

Figura 2 – Visão comparativa dorsal de *A. aegypti* e de *A. albopictus*



Fonte: adaptado de (OECD, 2018)

A distinção entre *Aedes* e *Culex* é mais evidente. Enquanto *Culex* tem uma cor marrom e não possui marcação clara nas pernas, *Aedes* é mais escuro, possuindo marcações brancas no corpo e nas pernas (Figura 3) (FIOCRUZ, 2019).

Figura 3 – Comparativo entre o *Aedes* e o *C. quinquefasciatus*



Fonte: (FIOCRUZ, 2019)

2.3 APRENDIZAGEM DE MÁQUINA

Muitos problemas podem ser resolvidos facilmente com algoritmos tradicionais, aqueles onde o programador especifica passo a passo o que o algoritmo irá fazer; são problemas de solução conhecida ou que se pode enxergar uma solução usando esse método. Entretanto, problemas complexos, ou de uma área muito específica, fazem com que o uso de algoritmos tradicionais sejam de difícil execução, seja pela complexidade em se chegar a uma solução ou pela necessidade de um especialista. Nesse contexto, percebeu-se a necessidade de técnicas que permitissem a criação de algoritmos computacionais mais autônomos, que pudessem criar uma hipótese ou função por conta própria, a partir da experiência passada. A esse conjunto de técnicas de indução de hipóteses a partir da experiência passada dá-se o nome de Aprendizagem de Máquina (*Machine Learning* - ML); em outras palavras, essas técnicas farão o computador aprender com base na experiência passada (CARVALHO et al., 2011).

Para que esse aprendizado ocorra é utilizado um princípio denominado indução, no qual se tiram conclusões genéricas a partir de um conjunto específico de exemplos. Desse modo, os algoritmos de ML irão induzir hipóteses baseadas em um conjunto de dados de determinado problema (CARVALHO et al., 2011).

Para a representação desse conhecimento, cada algoritmo utiliza um método. As redes neurais, que é o algoritmo abordado neste trabalho, utilizam um conjunto de valores reais (pesos), associados a cada conexão da rede (CARVALHO et al., 2011).

2.3.1 Redes Neurais Artificiais


As Redes Neurais Artificiais (*Artificial Neural Network* - ANN) são estruturas inspiradas no cérebro humano. Sua ideia base é tentar imitar como os neurônios biológicos interagem uns com os outros (IBM, 2020b).

Em 1943 foi publicado um estudo de Warren S. McCulloch e Walter Pitts (MCCULLOCH; PITTS, 1943), onde os autores tentavam entender como o cérebro humano conseguia representar padrões complexos utilizando suas células, os neurônios. Nesse estudo, eles compararam o neurônio biológico com uma estrutura binária da lógica booleana, sendo as declarações verdadeiras ou falsas (IBM, 2020b).

Baseado nas ideias desse estudo, em 1958 Frank Rosenblatt idealizou o *perceptron* (ROSENBLATT, 1958); essa nova estrutura de neurônio adicionava pesos

ao modelo anterior (IBM, 2020b). O funcionamento do *perceptron* (Figura 4) pode ser explicado da seguinte maneira: o modelo recebe as entradas do problema a ser resolvido e junto a cada entrada há um valor decimal (peso) que é multiplicado a ela. Após isso os valores são somados, se o resultado estiver acima de um limiar a saída é 1, caso contrário, -1 (MITCHELL, 1997).


Figura 4 – Estrutura do modelo *Perceptron*



Fonte: (MITCHELL, 1997)

Entretanto, redes de uma camada, como a *perceptron*, tem a limitação de conseguir resolver apenas problemas que são linearmente separáveis. Como exemplo, pode-se supor o problema quando se tem objetos de dois tipos, que também podem ser chamados de classes, com dois atributos cada. Após ser plotado em um espaço bidimensional, utilizando os valores dos dois atributos para localizar a posição dos objetos, eles serão linearmente separáveis, se for possível separá-los com uma reta (Figura 5) (CARVALHO et al., 2011).

Figura 5 – Exibição gráfica de um conjunto linearmente separável




Fonte: (CARVALHO et al., 2011)

Contudo, é comum se deparar com problemas mais complexos que não podem ser resolvidos com uma separação linear. Assim, para a resolução desses problemas foi proposta a adição de uma ou mais camadas intermediárias; com isso é possível implementar qualquer função contínua. No caso do *perceptron*, essa rede é do tipo *perceptron* multicamadas (*multilayer perceptron* - MLP), sendo composta de uma ou mais camadas intermediárias e uma camada de saída (CARVALHO et al., 2011).

Ao utilizar-se dessa estrutura, a função implementada por determinado neurônio de uma camada é composta pela combinação das funções dos neurônios da camada anterior conectados a ele. E, com o avanço do processamento de uma camada a outra, a função vai se tornando mais complexa. A cada camada os neurônios vão conseguindo construir regiões de separação mais complexas, podendo, desse modo, classificar problemas diversos (CARVALHO et al., 2011). Um exemplo desse processo pode ser visto na Figura 6.

Figura 6 – Estrutura de uma rede multicamada: pode-se observar que a cada camada a rede consegue modelar melhor os limites de separação entre os conjuntos



Fonte: (CARVALHO et al., 2011)

O resultado da rede é obtido pelos valores dos neurônios da camada de saída. Cada neurônio dessa camada está associado a um tipo de objeto. O neurônio de maior valor representará o tipo ao qual o objeto foi identificado (CARVALHO et al., 2011).

A definição da arquitetura da rede neural (quantidade de camadas intermediárias, número de neurônios dessas camadas) é influenciada por diversos fatores, como: quantidade de exemplos de treinamento, quantidade de ruído, complexidade da função que deverá ser aprendida (CARVALHO et al., 2011).

Outro problema a ser destacado é quando o número de dimensões dos dados for alto; conforme o número de variáveis aumenta, o número de configurações distintas possíveis aumenta exponencialmente (GOODFELLOW; BENGIO; COURVILLE, 2016). Como exemplo, pode-se citar problemas de reconhecimento de voz e identificação de objetos.

2.3.2 Aprendizagem profunda e classificação de imagens


A utilização de redes neurais totalmente conectadas para a classificação de imagens pode acabar se tornando uma tarefa bastante custosa. Uma base de imagens pode conter centenas de pixels e em uma rede neural totalmente conectada,

cada neurônio é conectado a cada pixel, elevando o custo computacional e de memória (AFFONSO *et al.*, 2017).

Uma solução que vem sendo empregada é o uso da Aprendizagem Profunda (*Deep Learning* - DP). Ela difere dos clássicos algoritmos de aprendizagem de máquina pelo método de aprendizagem e pela quantidade de dados que usa, pois remove uma grande parcela da atuação humana no pré-processamento dos dados (IBM, 2020a). Enquanto nos algoritmos tradicionais de aprendizagem de máquina as características dos dados são extraídas manualmente pela aplicação de algoritmos de extração, na aprendizagem profunda essas características são aprendidas automaticamente (ALOM *et al.*, 2018).

A DP também permite a utilização de uma grande base de dados. O termo “profunda” se refere à profundidade das camadas da rede neural. Caso a rede possua mais de três camadas, incluindo a de entrada e de saída, já pode ser considerada como um algoritmo de aprendizagem profunda, como vê-se na estrutura da Figura 7. Como destaque nessa área, pode-se citar as CNNs (IBM, 2020a).

Figura 7 – Estrutura de uma rede neural profunda de 5 camadas, sendo a primeira a camada de entrada dos dados, no meio três camadas escondidas e, por fim, a camada de saída



Fonte: adaptada de (IBM, 2020a)

2.3.3 Redes Neurais Convolucionais (CNNs)

As CNNs possuem sua arquitetura inspirada no mecanismo de percepção visual natural das criaturas vivas (GU *et al.*, 2018), tendo como base as análises de Hubel e Wiesel sobre o córtex visual de gatos (LINDSAY, 2021).

Eles descobriram dois tipos principais de células no córtex desses felinos: células simples e células complexas. As simples respondiam a barras claras ou escuras quando colocadas em locais específicos; cada célula simples respondia de acordo com determinada angulação preferida. As células complexas também respondiam a angulações preferenciais, entretanto eram menos rigorosas quanto a localização, respondendo a barras que estivessem em vários locais próximos. Hubel e Wiesel chegaram à conclusão que as células complexas estariam recebendo informações de várias células simples, todas com a mesma orientação, mas com locais ligeiramente diferentes (LINDSAY, 2021).

Baseado nesse estudo, Fukushima (FUKUSHIMA, 1980) criou em 1980 um modelo funcional do sistema visual, chamado *Neocognitron*, precursor das CNNs modernas (LINDSAY, 2021).

2.3.3.1 Componentes

Existem vários modelos de CNN, entretanto seus componentes básicos são similares. Usando como exemplo a rede LeNet-5 (Figura 10), vê-se que ela possui três tipos de camadas: camadas convolucionais, de *pooling* e totalmente conectadas (GU *et al.*, 2018).


2.3.3.1.1 Camada Convolucional

Essa camada tem por objetivo aprender as representações das características da imagem (GU *et al.*, 2018). Sendo o principal componente de uma CNN, ela contém um conjunto de filtros que realizam uma operação de convolução entre os filtros e a entrada da camada para criar o mapa de características (LOPEZ PINAYA *et al.*, 2020).

O filtro é uma tabela de números discretos onde seus parâmetros armazenam um padrão, sendo esse padrão o que será detectado na entrada da camada. Um filtro

com um padrão de um gato poderá detectar a presença de um gato na entrada, por exemplo. Esse filtro será aplicado pelo seu deslizamento pela imagem, da esquerda para a direita e de cima para baixo, calculando o produto escalar em cada ponto (Figura 8). A combinação do deslizamento com o cálculo do produto escalar define a operação de convolução (LOPEZ PINAYA *et al.*, 2020).

Figura 8 – Operação de convolução: o filtro é movido pela imagem para obter uma representação de características da imagem




Fonte: adaptado de (LOPEZ PINAYA *et al.*, 2020)

2.3.3.1.2 Camada de Pooling

O propósito dessa camada é reduzir o tamanho espacial da representação vinda da camada convolucional. Ela simplifica a informação coletada e cria uma versão condensada da mesma informação. A forma mais usada é o *max pooling* (Figura 9), que desliza uma tabela de tamanho definido e pega o maior valor daquela tabela (LOPEZ PINAYA *et al.*, 2020).

Figura 9 – Operação de *Max pooling*: de cada região é escolhido o maior valor, tendo por finalidade diminuir o tamanho espacial da representação da camada convolucional




Fonte: (LOPEZ PINAYA *et al.*, 2020)

2.3.3.1.3 Camada totalmente conectada

A principal função dessa camada é realizar a classificação nas características extraídas nas fases de convolução e *pooling*. Para isso, o mapa de características deve ser achatado para um vetor de uma dimensão.

Na Figura 10 pode-se ver a estrutura completa da LeNet-5.

Figura 10 – Arquitetura da rede LeNet-5 mostrando os principais elementos de uma CNN: convolução, pooling e camada totalmente conectada



Fonte: adaptado de (LECUN *et al.*, 1998)

2.3.3.2 VGG: Visual Geometry Group

A arquitetura VGG (*Visual Geometry Group*) foi proposta por Simonyan e Zisserman (SIMONYAN; ZISSERMAN, 2014). Os modelos VGG com 16 camadas (VGG16) e o com 19 camadas (VGG19) ganharam o primeiro e segundo lugares no ImageNet Challenge 2014, nas modalidades de localização e classificação, respectivamente (REZENDE *et al.*, 2018).

Simonyan e Zisserman (SIMONYAN; ZISSERMAN, 2014) tiveram como objetivo do trabalho analisar como a profundidade da rede influencia na precisão dos modelos convolucionais de reconhecimento de imagens; para isso, eles corrigiram outros parâmetros da arquitetura e foram aumentando a profundidade da rede, adicionando mais camadas convolucionais. Para essa viabilidade, foram usados pequenos filtros convolucionais 3x3 (o menor tamanho para capturar a noção de esquerda/direita, acima/abaixo, centro) em todas as camadas.

Foram propostos 6 modelos, o primeiro com 11 camadas e o último com 19 camadas. A entrada dos modelos é uma imagem RGB de 244x244, que é passada pelas camadas convolucionais com filtro 3x3. A arquitetura é composta por 5 agrupamentos de camadas convolucionais seguidos de uma camada de pooling cada, e por último há três camadas totalmente conectadas. Como pode ser visto na Figura 11, a configuração das camadas totalmente conectadas é a mesma em todos os modelos, o que os diferencia é a quantidade ou configuração das camadas convolucionais.

Simonyan e Zisserman concluíram que o aumento da profundidade da rede convolucional é benéfica para a precisão da classificação; e mostraram que os modelos VGG propostos generalizam bem para uma ampla gama de tarefas e conjuntos de dados.

Figura 11 – Configurações do modelo VGG

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Fonte: (SIMONYAN; ZISSERMAN, 2014)


2.3.3.3 Resnet: Residual Network

Um dos problemas ao se treinar redes neurais profundas é a dissipação do gradiente, que dificulta a convergência da rede desde o início. Quando essas redes começam a convergir pode ocorrer um problema: com o aumento da profundidade da rede, a precisão fica saturada e então se degrada rapidamente (HE, K. *et al.*, 2015).

Com a intenção de resolver esse problema, He *et al.* (HE, K. *et al.*, 2015) propuseram um modelo convolucional chamado *Residual Network* (ResNet), cuja arquitetura pode ser vista na Figura 12(a). A ideia foi baseada na adição de conexões de atalho a cada duas camadas em uma rede estilo VGG. Essas conexões de atalho simplesmente executam um mapeamento identidade, e suas saídas são adicionadas às saídas das camadas empilhadas (Figura 12[b]).

Usando essa nova estrutura, foi possível treinar uma rede de 1001 camadas, algo que antes era virtualmente impossível (LI *et al.*, 2016). Existe uma variação dessa rede com 50 camadas, chamada ResNet50 (SAJID *et al.*, 2020).

Figura 12 – (a) Arquitetura da rede ResNet. (b) Bloco residual



Fonte: adaptado de (SAJID *et al.*, 2020)

2.3.3.4 EfficientNet


Uma das técnicas para tentar melhorar a precisão de classificação de uma rede convolucional é o aumento da escala de uma ou mais de suas dimensões. Por exemplo, a ResNet pode ser escalada da ResNet-18 para a ResNet-200 pela adição de mais camadas. Ter-se-ia, então, um escalonamento na profundidade da rede. O mesmo poderia acontecer caso fosse aumentado o número de neurônios, seria, então, um escalonamento na largura da rede. Outro caso é quando se aumentasse a resolução da imagem; mesmo podendo-se fazer o escalonamento de uma ou mais dimensões de modo arbitrário, acabaria sendo uma tarefa de ajuste manual e ainda poderia resultar em precisão e eficiência abaixo do esperado (TAN; LE, 2019).

A ideia da EfficientNet (Figura 13) parte do questionamento sobre como realizar esse escalonamento, e propõe um método de escalonamento composto, escalando uniformemente profundidade, largura e resolução. Por exemplo, caso se queira usar 2^N vezes mais recursos, pode-se simplesmente aumentar a profundidade da rede em α^N , a largura em β^N e o tamanho da imagem em γ^N , sendo α , β e γ

coeficientes constantes definidos em uma pequena busca em grade no modelo original menor (TAN; LE, 2019).

Tan e Le (TAN; LE, 2019) propuseram 8 modelos convolucionais, da *EfficientNet-B0* até a *EfficientNet-B7*, que alcançaram melhor precisão e eficiência do que redes convolucionais anteriores. Como exemplo pode-se citar a *EfficientNet-B7*, que atingiu 84,3% no top-1 de acurácia na ImageNet, sendo 8,4x menor e 6,1x mais rápido na inferência do que a melhor rede convolucional existente.

Figura 13 – Arquitetura da rede EfficientNet



Fonte: adaptado de (DHILLON; VERMA, 2020)

2.4 INTELIGÊNCIA ARTIFICIAL E DOENÇAS ZOONÓTICAS

A Inteligência Artificial, área da computação com enfoque para a resolução de problemas complexos, pode ser aplicada em diversos contextos. Uma área que vem se beneficiando com o seu uso é a das doenças zoonóticas.

Diversas linhas de pesquisas com algoritmos inteligentes estão sendo desenvolvidas com foco no combate a essas doenças, como na prevenção à disseminação geográfica de surtos, identificação de possíveis hospedeiros, predição da presença de vetores em determinada região, classificação de vetores, entre outras.

Uma pesquisa com foco na predição da presença de vetores é a de Mollalo e colaboradores (MOLLALO *et al.*, 2018); o trabalho propõe modelar a distribuição espacial do mosquito *Phlebotomus papatasi*, o principal vetor da leishmaniose tegumentar zoonótica. Ele desenvolveu um banco de dados georreferenciado com dados dos flebotomíneos coletados, além de dados sobre fatores ambientais relacionados, incluindo topografia, variáveis meteorológicas, distância dos principais rios e dados de sensoriamento remoto, utilizando três classificadores: regressão logística, floresta aleatória e máquina de vetores de suporte, para prever a presença

ou ausência do vetor. A máquina de vetores de suporte foi a que obteve melhores resultados, alcançando a precisão de 90,6%.

Já no trabalho de HAN (HAN *et al.*, 2015), o foco é na identificação de futuros hospedeiros de doenças zoonóticas. Nessa pesquisa foram estudados os roedores, grupo de mamíferos que compreendem um número desproporcional de hospedeiros dessas doenças. Os modelos inteligentes desenvolvidos previram com 90% de acurácia o pertencimento dos roedores a esse grupo de hospedeiros, baseados em características como a história de vida dos roedores, a ecologia, o comportamento, a fisiologia, entre outros.

Na pesquisa de Akhtar, Kraemer e Gardner (AKHTAR; KRAEMER; GARDNER, 2019), é proposto um modelo dinâmico de rede neural para prever a disseminação geográfica de surtos Zika em tempo real, baseando-se em dados socioeconômicos, populacionais, epidemiológicos, de viagens e de adequação de mosquitos vetores. O modelo pôde prever a expansão geográfica do vírus da Zika nas Américas com uma acurácia média acima de 85%.

Segundo Carlson *et al.* (CARLSON *et al.*, 2021), modelos de aprendizagem de máquina também têm sido usados para prever a gravidade de doenças zoonóticas e podem ser estendidos para prever a mortalidade no futuro.

Como observado, a aplicação da Inteligência Artificial nessa área já é uma realidade, entretanto ainda existe um longo caminho de desafios a percorrer, e o presente trabalho vislumbra contribuir para esse cenário de soluções.

2.5 CONSIDERAÇÕES DO CAPÍTULO

No capítulo discutiu-se sobre zoonoses e foi falado sobre a história das principais arboviroses de grande impacto (Zika, Dengue, Febre Amarela e Chikungunya) e seus principais vetores. Pôde-se perceber a gravidade dessas doenças e os impactos em diversas regiões ao longo dos anos, afetando a qualidade de vida das pessoas, bem como causando uma mortandade elevada e a manifestação de outras doenças, como é o caso da microcefalia em recém-nascidos. As ações mais efetivas contra essas doenças foram as direcionadas sobre os vetores, como exemplo, na erradicação da Febre Amarela urbana decorrente da eliminação do seu vetor, *A. aegypti*, por um período.

Nas últimas décadas viu-se um grande avanço nas tecnologias computacionais, ressaltando a evolução dos algoritmos inteligentes, cujo principal propósito é o de resolver problemas complexos, onde algoritmos tradicionais não conseguem fácil resolução. Vem se destacando nesse contexto os algoritmos baseados em aprendizagem profunda, se mostrando eficientes nas resoluções de problemas como detecção e classificação de imagens, predição de problemas baseados na periodicidade de determinados eventos, entre outros.

Dentre os problemas em que os algoritmos inteligentes estão sendo utilizados, as doenças zoonóticas estão inclusas, nas quais as arboviroses fazem parte. Problemas de difíceis resoluções que estão se munindo do potencial dos algoritmos inteligentes para auxiliar nas ações de combate a essas doenças.

A classificação automática dos vetores é um dos desafios que a Inteligência Artificial vem sendo empregada para resolver. No próximo capítulo essas soluções serão exploradas a partir de uma revisão sistemática da literatura.

3 METODOLOGIA DE PESQUISA

Neste capítulo serão abordadas as etapas para a realização da metodologia de pesquisa utilizada.

Na seção 3.1 explica-se a classificação metodológica da pesquisa; na seção 3.2 o método de mapeamento sistemático, sendo abordado na seção 3.2.1 a estratégia de busca; na seção 3.2.2 os critérios utilizados; na seção 3.2.3 é mostrado o resultado do mapeamento sistemático da literatura; e na 3.3 os trabalhos relacionados identificados são explicados.

3.1 CLASSIFICAÇÃO METODOLÓGICA

A pesquisa científica é o emprego de um conjunto de procedimentos que um pesquisador se utiliza, para a realização de um experimento, com o intuito de produzir conhecimento e integrá-lo aos conhecimentos já existentes (FONTELLES *et al.*, 2009).

Uma pesquisa pode ser classificada em três categorias: nos objetivos intencionados, na obtenção das informações e nos procedimentos utilizados (RAMALHO; MARQUES, 2009).

Na Tabela 1, pode-se ver a classificação desta pesquisa.

Tabela 1 – Classificação da pesquisa

Característica	Classificação
Objetivos	Exploratória e Descritiva
Obtenção das informações	Bibliográfica e de laboratório
Procedimentos	Revisão da Literatura e Experimentação

Fonte: O pesquisador

3.2 REVISÃO DA LITERATURA

Esta etapa foi conduzida através de um mapeamento sistemático da literatura, uma forma de identificar, avaliar e interpretar todas as pesquisas ou fenômenos disponíveis relevantes para uma questão de pesquisa específica, área temática, ou fenômeno de interesse (KEELE, 2007).

Neste contexto, as perguntas que cercaram esta pesquisa foram:

P1: Quais as principais soluções utilizadas para classificar as espécies de mosquitos vetores de doenças com base em inteligência artificial?

P2: Quais as principais soluções utilizadas para classificar as espécies de mosquitos vetores de doenças com base em imagens digitais?

P3: Quais as principais vantagens e desvantagens das soluções encontradas?

3.2.1 Estratégia de busca

Na construção da *string* de busca seguiu-se os seguintes passos: divisão da pesquisa em termos individuais, tradução dos termos para a língua inglesa e agrupamento dos termos através de operadores lógicos.

Foi feita inicialmente uma busca *ad hoc* utilizando-se a *string* ‘*mosquitoes and classification*’ no mecanismo de busca Google Acadêmico, para se conhecer mais sobre o cenário recente de pesquisas acerca desse tema. Com isso foi possível ter uma visão geral dos principais termos utilizados, métodos de pesquisa.

Dados os resultados da busca percebeu-se que os termos *mosquitoes*, *aedes*, *culex*, *classification*, *identification*, *recognition*, são comuns. Também percebeu-se que retornam artigos a partir das bases Elsevier, IEEE e Springer. Portanto, na segunda etapa do MSL, refinou-se a *string* e usou-se os mecanismos de busca Elsevier, IEEE, Springer e Google Acadêmico.

Com essa percepção, a segunda *string* de busca foi construída de modo a conseguir abranger os termos acima citados, ficando estruturada da seguinte forma: (*mosquitoes or aedes or culex*) and (*classification or identification or recognition*).

3.2.2 Critérios de Inclusão e Exclusão

Com os resultados obtidos, passou-se para a fase de seleção dos trabalhos. Segundo Keele (KEELE, 2007), a estratégia de seleção deve ser feita com base em critérios de inclusão (CI) e de exclusão (CE). Os critérios desta pesquisa são expostos a seguir.

Critérios de Inclusão:

- CI 1: Estudos que apresentem soluções para classificação de mosquitos;

- CI 2: Estudos publicados em periódico ou conferência delimitados no escopo desta pesquisa.

Critérios de Exclusão:

- CE 1: Trabalhos incompletos, rascunhos, documentos de compilação dos anais de conferência, tutoriais e apresentações em slides;
- CE 2: Trabalhos resultantes de uma mesma pesquisa ou com pequenas mudanças em relação a uma publicação anterior;
- CE 3: Trabalhos não publicados nos últimos 7 anos (2015 a 2021);
- CE 4: Livros, dissertações ou teses.

3.2.3 Mapeamento

O andamento do mapeamento envolve a seleção e a avaliação das fontes de informação através dos CIs e CEs definidos, ou seja, durante a execução os trabalhos são expostos aos critérios, com o intuito de filtrar, deixando apenas aqueles que estão de acordo com as definições do trabalho. Esta fase da pesquisa foi realizada em duas etapas:

Etapa 1: Aplicação dos critérios de exclusão CE 1, 2, 3 e 4;

Etapa 2: Aplicação dos critérios de inclusão CI 1 e 2.

Tabela 2 – Quantidade de artigos após as etapas do mapeamento sistemático

Mecanismo de busca	Etapa 1	Etapa 2
Elsevier	8	6
IEEE	8	7
Springer	2	1
Google Acadêmico	16	9
Total	34	23
	100%	70,5882%

Fonte: O pesquisador

O mapeamento da literatura resultou em 23 trabalhos no contexto dessa dissertação.

Tabela 3 – Estudos resultantes do mapeamento sistemático

Estudo	Ano	Base	Tipo de inseto	Método de análise	Forma de captura	Recursos para extração de características	Quantidade de amostras	Algoritmos/métodos	Acurácia
(RUSTAM <i>et al.</i> , 2021)	2021	Elsevier	<i>Aedes</i> e <i>Culex</i>	Visão computacional	Base de dados obtida pelo IEEE (CHUMCHU, 2020)	Imagens	1.404	VGG16	98,6%
								Inception V3	97,9%
								ResNet50	98,1%
								EfficientNetB0	94,7%
(FERNANDES; CORDEIRO; RECAMONDE-MENDOZA, 2021)	2021	Elsevier	20 espécies de mosquitos	Ondas sonoras	Base de dados gerada pelo projeto Abuzz (MUKUNDARAJAN <i>et al.</i> , 2017)	Imagens	1.285	CNN binária	97,65%
								CNN multiclasse	78,12%
								Ensemble	94,56%
(ALAR; FERNANDES, 2021)	2021	Elsevier	<i>Aedes</i> , <i>Anopheles</i> e <i>Culex</i> , com uma adicional não mosquito	Ondas sonoras	Base de dados aberta de Zoouniverse.org	Gravações de áudios	405	Mediana e Amplitude interquartil	92,8%
								Modelo Convucional	86,6%
(LORENZ; FERRAUDO;	20015	Elsevier	17 espécies do gênero <i>Anopheles</i> ,	Visão computacional		Imagens	388	Perceptron Multicamadas	Entre 85,70% e 100%

SUESDEK , 2015)			<i>Aedes e Culex</i>						
(OUYANG <i>et al.</i> , 2015)	2015	Elsevier	A. albopictus, A. aegypti e C. <i>quinquefasciatus</i>	Raios infravermelhos	Ambiente controlado	Sequências dos batimentos das asas dos mosquitos	788 sequências	Modelo de mistura Gaussiana	87,9%
								Rene Neural Artificial	86%
								KNN	80,3%
(SUMRUAYPHOL <i>et al.</i> , 2016)	2016	Elsevier	Ae. albopictus, Ae. scutellaris e Ae. aegypti	Visão computacional e Análise genética	Ambiente controlado				
(VYAS-PATEL <i>et al.</i> , 2015)	2015	Google	Diversas espécies de abelha, abelhão e mosquito.	Visão Computacional	Ambiente controlado	Imagens	925 imagens de asas	Algoritmo CO1	Entre 80% e 100%
(MINAKSHI; BHARTI; CHELLAPAN, 2018)	2018	Google	9 espécies de mosquitos	Visão computacional	Ambiente natural	Espaço de cor Lab, Textura, Histograma	303	SVM	77,5%
(HAKIM, 2020)	2020	Google		Ondas sonoras	Base de dados gerada pelo projeto Abuzz (MUKUNDARAJAN <i>et al.</i> , 2017)	Frames de áudio			
(FUCHIDA <i>et al.</i> , 2017)	2017	Google	Mosquitos e outros insetos	Visão computacional		Histograma de cor e relação largura- comprimento do tronco e região da perna		SVM	85,2%
(OKAYASU <i>et al.</i> , 2019)	2019	Google	A. <i>albopictus</i> , <i>Anopheles stephensi</i> e <i>Culex pipiens pallens</i>	Visão computacional	Ambiente controlado	Forma, textura, cor e frequência Imagem	4.800	SVM	82,4%
								AlexNet	92,3%
								VGGNet	91%
								ResNet	95,5%
(MOTTA <i>et al.</i> , 2020)	2020	Google	Ae. aegypti, Ae. <i>albopictus</i> ,	Visão compu	Ambiente controlado	Imagem	8.748	Xception	93,5%
								VGG16	
								VGG19	

			and C. <i>quinquefasciatus</i>	tacion al				ResNet50	
								InceptionV3	
								InceptionResNetV2	
								MobileNet	
								DenseNet	
								NASNet	
								MobilenetV2	
(PARK <i>et al.</i> , 2020)	2020	Google	Ae. Albopictus, Ae. Vexans, Anopheles spp., Cx. pipiens, Cx. tritaeniorhynchus, Ae. dorsalis, Ae. koreikus, Cx. inatomii	Visão computacional	Ambiente controlado	Imagem de 420 × 314 pixels	3.600	VGG-16	97,19%
								ResNet-50	96,86%
								SqueezeNet	90,71%
(KITTI CHAI <i>et al.</i> , 2021)	2021	Google	15 classes de mosquitos	Visão computacional	Ambiente misto	Imagem	10.564	YOLO	98,9%
(HUANG <i>et al.</i> , 2018)	2018	IEEE	<i>A. aegypti</i> , <i>A. albopictus</i> , <i>Culex annulus</i> e <i>Culex tritaeniorhynchus</i>	Visão computacional	Ambiente natural	Imagem	319 vídeos de mosquitos	CNN	90,5%
(LUKMAN; HARJOKO; YANG, [s. d.])	2017	IEEE	<i>Culex</i> e <i>A. aegypti</i>	Ondas sonoras		Áudio		SVM	75.55 %
(AMIRUDIN; KADIR, 2020)	2020	IEEE	<i>Aedes</i> , <i>Anopheles</i> , <i>Culex</i> , e <i>Mansonia</i>	Visão computacional	Mecanismo de busca Bing	Imagem	200	VGG-16	78%
								MobileNet V2	80%
								EfficientNet-b1	75%
								NASNetMobile	73%
(DE LOS REYES <i>et al.</i> , 2016)	2016	IEEE	<i>A. aegypti</i>	Visão computacional		Média, desvio padrão, entropia, energia, contraste		SVM	80%
	2021	IEEE	<i>Aedes</i> e <i>Culex</i>	Visão computacional				Haar-like cascade	87,5%

(HATEKA R et al., 2021)				tacion al				LBP	37,5%
(VASCON CELOS et al., 2019)	2019	IEEE	<i>A. aegypti</i> , <i>Culex</i> e <i>Culiseta</i>	Ondas sonoras	Ambiente misto	Áudio da batida das asas do mosquito, temperatura e umidade			
(FANIOU DAKIS; GEISMAR ; POTAMITI S, 2018)	2018	IEEE	<i>A. aegypti</i> , <i>A.</i> <i>albopictus</i> , <i>Anopheles</i> <i>arabiensis</i> , <i>Anopheles</i> <i>gambiae</i> , <i>Culex</i> <i>pipiens</i> , <i>C.</i> <i>quinquefasci</i> <i>atus</i>	Análise e sensorial ótica	Ambiente controlado	Registros óticos do bater de asas de mosquitos	27.956 6 de registros	DenseNet 121	96%
								5 layer CNN-PSD	92,1%
								5 layer CNN- Amostras brutas	91,2%
								InceptionV 3	95,20%
								MobileNet	95,62%
								Xception	92,18%
								NASNetM obile	94,85%
								XGBoost	81,81%
(SOUZA, 2016)	2016	Spring er	<i>Musca</i> <i>domestica</i> , <i>C.</i> <i>quinquefasci</i> <i>atus</i> , <i>Culex</i> <i>tarsalis</i> , <i>Drosophila</i> <i>melanogaste</i> <i>r</i> , <i>A. aegypti</i>	Análise e sensorial ótica	Ambiente controlado	Mel- Frequency Cepstral Coefficients (MFCC)	5.325	gausdd	86,96%
								mogdd	91,98%
								parzendd	84,35%
								knndd	85,42%
								kmeansdd	85,05%
								svdd	94,62%
								lpdd	77,90%
								mstd	78,04%

Fonte: O pesquisador

3.3 TRABALHOS RELACIONADOS

Após o mapeamento sistemático, foram identificados 7 trabalhos relacionados com esta pesquisa. Os critérios foram que os trabalhos tivessem como método de análise Visão computacional e os algoritmos utilizassem aprendizagem profunda. A seguir, é feita uma descrição de cada trabalho.

No trabalho de Rustam (RUSTAM et al., 2021) foi feita a classificação de mosquitos do gênero *Aedes* e *Culex*. A base de dados utilizada foi obtida pelo IEEE (CHUMCHU, 2020) e a seleção de características usada foi a RIFS. Quatro CNNs fizeram parte dos experimentos: VGG16, Inception V3, ResNet50 e EfficientNetB0. A VGG16 foi a rede que obteve a maior acurácia, 98,6%.

Na pesquisa de Okayasu (OKAYASU et al., 2019) foram utilizadas as espécies *A. albopictus*, *Anopheles stephensi* e *Culex pipiens pallens* na classificação. A base de dados criada foi composta por 4.800 imagens, que foram rotacionadas em 90°, de modo a quadruplicar a base. Os experimentos foram feitos com os seguintes algoritmos: SVM, AlexNet, VGGNet e ResNet. A maior acurácia obtida foi 95,5%, da ResNet.

Motta (MOTTA et al., 2020) realizou sua pesquisa com as seguintes espécies: *A. aegypti*, *A. albopictus* e *C. quinquefasciatus*. Foi construída uma base de dados constituída por 8.748 imagens, e foram realizados experimentos com 10 modelos de redes convolucionais, sendo a melhor acurácia obtida de 93,5%.

No estudo de Park (PARK et al., 2020) foram utilizadas 8 espécies de mosquitos. A base de dados foi construída e obteve-se um total de 3.600 imagens. Os experimentos realizados contaram com os seguintes modelos convolucionais: VGG16 (97,19% de acurácia), ResNet-50 (96,86% de acurácia) e SqueezeNet (90,71% de acurácia).

Na pesquisa de Kittichai (KITICHAI et al., 2021) 11 espécies de mosquitos foram utilizadas. A base de imagens foi construída a partir de 1.585 amostras, que foram fotografadas ou filmadas, obtendo-se um total de 10.564 imagens. O modelo utilizado foi a YOLO, com uma acurácia de 96%.

Huang (HUANG et al., 2018) pesquisou a classificação de 4 espécies: *A. aegypti*, *A. albopictus*, *Culex annulus* e *Culex tritaeniorhynchus*. A base foi construída a partir de um aparelho desenvolvido pelos pesquisadores, que atrai o mosquito e realiza vídeos do mesmo; ao total, obteve-se 319 vídeos. Algumas imagens também

foram adquiridas de um laboratório, sendo 114 *Aedes* e 129 *Culex*. Eles, então, prepararam algumas bases e realizaram experimentos com um modelo de CNN. A melhor acurácia obtida foi de 90,5%.

Na pesquisa de Amiruddin (AMIRUDDIN; KADIR, 2020) os seguintes gêneros de mosquitos foram utilizados: *Aedes*, *Anopheles*, *Culex*, e *Mansonia*. A base foi construída com 200 imagens do mecanismo de busca Bing e, nela, rodou-se os seguintes modelos convolucionais: VGG16 (78% de acurácia), MobileNetV2 (80% de acurácia), EfficientNetB1 (75% de acurácia) e NASNetMobile (73% de acurácia).

Fazendo uma análise dos trabalhos descritos acima, pode-se visualizar avanços significativos na área de classificação automática de mosquitos vetores, com bons resultados; trabalhos visando soluções de baixo custo, viabilizando, assim, a construção de soluções acessíveis e construindo bases de imagens, o que pode contribuir com pesquisas futuras, objetivando uma diversidade de mosquitos, e o que acaba contribuindo no aumento da cobertura desse tema. Alguns dos trabalhos relacionados poderiam se beneficiar ao detalhar melhor o processo de coleta, expandir as bases de imagens, recortar a área de interesse de modo automatizado e explorar outros algoritmos inteligentes.

O presente trabalho contribui com o cenário atual ao construir uma base de imagens de mosquitos vetores, utilizando-se de material de baixo custo, descrevendo o método de coleta desenvolvido, ressaltando as dificuldades encontradas e os caminhos para a resolução das mesmas. Contribui também com a construção de um modelo computacional, utilizando aprendizagem Profunda para a classificação dos vetores, detalhando os métodos utilizados e disponibilizando os artefatos obtidos (base, códigos, modelos treinados) publicamente sob a licença GNU General Public License (GPL) e na identificação e propostas de trabalhos futuros que possam incentivar outros pesquisadores.

Os artefatos estão disponíveis no seguinte link:
<https://github.com/pesquisamosquitos/dissertacao>

3.4 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foi visto o processo de mapeamento sistemático da literatura. Realizado em duas etapas: a primeira, uma busca exploratória, a segunda direcionada, onde se conseguiu ter uma visão dos trabalhos desenvolvidos dentro do tema da pesquisa.

Explorando os trabalhos encontrados, pôde-se visualizar duas principais diferentes linhas de pesquisas utilizadas na identificação de mosquitos vetores. Podendo ser diferenciadas principalmente pelas fontes de informações usadas na classificação. Alguns usaram o bater das asas dos mosquitos para distingui-los, o que se mostrou eficiente, entretanto o custo da aparelhagem se mostrava superior àqueles trabalhos que utilizaram o segundo método de captura, captura de imagens, uma vez que as câmeras digitais são bem populares atualmente, com preços mais acessíveis.

Na primeira etapa foram retornados 34 trabalhos, esse número sendo reduzido para 23 na segunda etapa. Desses, apenas 7 passaram pelos critérios definidos para serem considerados trabalhos relacionados, e foram os trabalhos que tivessem como método de análise Visão computacional e os algoritmos utilizassem aprendizagem profunda.

Dito isto, no próximo capítulo serão detalhados os materiais e métodos utilizados para a construção da base de imagens deste trabalho, o que permitiu construir os modelos inteligentes desenvolvidos nesta pesquisa.

4 MATERIAIS E MÉTODOS

Para a realização desta pesquisa, foi criada uma base de imagens composta por três espécies de mosquitos: *A. aegypti*, *A. albopictus* e *C. quinquefasciatus* e separadas entre machos e fêmeas. Os espécimes foram obtidos em uma parceria com o Instituto Aggeu Magalhães.

Neste capítulo será explanado desde a fase inicial do processo até a finalização da base, descrevendo os materiais e métodos utilizados.

Na seção 4.1 será descrito o material utilizado para as capturas das imagens. Na seção 4.2 o processo de coleta será explicado. Após, na seção 4.3, serão discutidas as escolhas sobre o método de captura. Na seção 4.4 o pré-processamento aplicado às imagens irá ser detalhado. Na seção 4.5, são explicadas as soluções abordadas para contornar o desbalanceamento da base, ocorrido devido a pandemia de COVID-19. E, por fim, no capítulo 4.6 serão mostrados os modelos escolhidos e como se deram as escolhas para os ajustes dos hiperparâmetros.

4.1 EQUIPAMENTO UTILIZADO

Procurando viabilizar a reprodução futura da pesquisa sem altos custos, buscou-se utilizar um material acessível. Inicialmente, foi tentado o uso do Microscópio Digital RoHS 2.0 Mega Pixels Digital 30 fps, com iluminação própria, com preço em torno de R\$ 100,00 (cem reais), como pode ser visto na Figura 14.

Figura 14 – Microscópio utilizado nas primeiras tentativas de captura de imagens (Microscópio Digital RoHS 2.0 MP)



Fonte: (FRIO, [s. d.])

Entretanto, teve-se dificuldade em deixar esse microscópio em uma posição fixa, pois com o seu manuseio a base não era fixa o suficiente para mantê-lo na mesma

posição. Após essa constatação, buscou-se realizar um teste com outro modelo de microscópio, o HT-60S (Figura 15), modelo com 5 MP, com luz própria, com preço em torno de R\$ 400,00 (quatrocentos reais), que atendia ao pré-requisito de ser de baixo custo e possuía uma base aparentemente fixa.

Depois de alguns testes percebeu-se que se conseguia deixá-lo em uma posição fixa, mesmo que fosse movido para outro local. Dado que atendia aos requisitos esperados, foi escolhido como o equipamento de captura das imagens.

Figura 15 – Microscópio escolhido para as capturas, por possuir uma estrutura de suporte fixa (Microscópio HT-60S)




Fonte: (GEARBEST, [s. d.])

O próximo passo foi definir o plano de fundo onde seriam capturadas as imagens dos espécimes. Algumas visitas ao laboratório do Instituto Aggeu Magalhães foram feitas, levando o equipamento de captura citado para que, com o auxílio de profissionais da área, essa questão pudesse ser definida. Foi sugerido o uso de um papel de cor bege que eles utilizavam nas suas atividades, entretanto, um ponto importante é que o plano de fundo fosse o mais contrastante possível do espécime a ser capturada a imagem, para facilitar o destaque da área de interesse, e a cor daquele papel poderia não trazer isso. Por fim, depois de ser discutido com o orientador da pesquisa, ficou definido usar uma folha de papel ofício branca, por trazer duas características importantes para a pesquisa: um alto contraste com o mosquito e o baixo custo do material. Fez-se, então, um modelo constituído por um quadrado (5x5 cm) com um quadrado menor no centro (2x2 cm) (Figura 16), alinhado com a câmera do equipamento, local onde a espécime deveria ficar. Essa base de papel foi

fixada à base do microscópio com fita adesiva transparente. Em uma folha de papel A4, consegue-se imprimir 12 bases assim, o que é importante, pois periodicamente tem que se trocar essa base, pois o manuseio dos mosquitos invariavelmente suja o papel. Isso será explicado na próxima seção.

Figura 16 – Modelo utilizado para posicionamento dos espécimes em um local fixo na base do microscópio



Fonte: O pesquisador

No manuseio dos mosquitos, uma vez que são insetos pequenos e delicados, foram utilizadas duas pinças de precisão (Figura 17). Para realizar a captura foi utilizado um notebook, no qual o microscópio digital era conectado.

Figura 17 – Pinças de precisão utilizadas para manipulação dos mosquitos durante o processo de captura de imagens




Fonte: (ALIBABA, [s. d.])

4.2 AMOSTRAS

Como foi dito, houve uma parceria com o Instituto Aggeu Magalhães, pois o instituto possui um insetário com várias espécies de mosquitos. Com a periodicidade de uma a duas semanas, era pedida uma quantidade de mosquitos de determinada espécie e sexo; essa quantidade variava de acordo com a velocidade com que se conseguia capturar as imagens, mas em média era pedido de 100 a 200 espécimes por vez. Os profissionais congelavam os mosquitos, faziam a separação e os armazenavam em tubos de ensaio. Na Figura 18 pode-se ver um exemplar de cada espécie e sexo utilizado na pesquisa.

Figura 18 – Exemplos de cada tipo de mosquito (espécie/sexo) utilizados na pesquisa: *A. aegypti* fêmea (a), *A. aegypti* macho (b), *A. albopictus* fêmea (c), *A. albopictus* macho (d), *C. quinquefasciatus* fêmea (e), *C. quinquefasciatus* macho (d)



Fonte: O pesquisador


Pelo fato de precisarem ter um número mínimo de mosquitos no insetário, nem sempre era obtida determinada espécie na quantidade pedida, mas posteriormente faziam o fornecimento.

Em certo momento o insetário pegou um fungo, algo que acontece em insetários, sendo as principais causas a alta humidade e temperatura (VIRGINIO; LORENZ; BREVIGLIERI, 2018), e o Instituto Aggeu Magalhães, por cerca de duas semanas, não pôde disponibilizar espécimes.

4.3 MÉTODO DE CAPTURA

Assim como ocorreu na escolha do plano de fundo, discutiu-se, junto com a equipe do Instituto Aggeu Magalhães e com o orientador da pesquisa, quais seriam as posições dos mosquitos que se usaria para as capturas. Foram escolhidas quatro posições: a primeira com a probóscide, prolongamento do aparelho bucal, que funciona como sugador, voltada para cima no lado esquerdo da imagem, a segunda com a probóscide voltada para baixo do lado direito da imagem, a terceira com a probóscide voltada para cima no lado direito da imagem e a quarta com a probóscide voltada para baixo do lado direito da imagem. Pensou-se nessas posições de modo que fossem bem distintas e conseguisse pegar diferentes ângulos dos mosquitos (Figura 19).

Figura 19 – Posições de captura das imagens para cada mosquito, visando a obtenção de diferentes ângulos dos espécimes



Fonte: O pesquisador

No início, as capturas das imagens eram feitas em um laboratório do Instituto Aggeu Magalhães, com o auxílio de um profissional local que ficava responsável por

manipular os mosquitos e deixá-los nas posições pré-definidas. Todavia, esse método apresentou alguns problemas. Nem sempre o mesmo profissional estava disponível e, assim, o novo profissional teria que aprender a manipular os espécimes, o que resultava, nesse período de aprendizado, danificando alguns mosquitos, perdendo amostras. Em conversa com o profissional do Instituto Aggeu Magalhães, decidiu-se que o próprio pesquisador iria fazer a manipulação dos mosquitos para a realização das capturas das imagens. Quanto à iluminação, foi observado que a luz do ambiente não era significativa para as capturas, uma vez que o equipamento de captura possuía luz própria.

Nesse processo de capturas houve alguns empecilhos, um deles foi na manipulação dos espécimes. Caso fossem segurados com a pinça pelas patas, havia uma grande chance delas se quebrarem, assim, o melhor local encontrado para fazer essa manipulação foi as asas, uma vez que são mais resistentes. Foi percebido também que qualquer ventilação que houvesse próxima ao microscópio poderia deslocar o mosquito, devido à sua leveza. Entre uma captura e outra era importante observar a base de papel; com o manuseio dos mosquitos, a base acabava ficando suja, sendo necessária a troca da base.

Um ponto relevante a ser ressaltado é quanto à preservação das amostras. Durante as capturas, caso o pesquisador precisasse se ausentar, os mosquitos deveriam ser recolocados nos tubos de ensaio, caso contrário, outros insetos, como formigas, poderiam tentar pegá-los, fato que quase aconteceu.

Como geralmente não se conseguia retirar fotos de todas as amostras em um mesmo dia, os mosquitos não utilizados eram recolocados nos tubos de ensaio e mantidos em um congelador.

O processo de captura teve início em setembro de 2019 e término em março de 2020, sendo interrompido com a chegada da pandemia de COVID-19.

4.4 PRÉ-PROCESSAMENTO DAS IMAGENS

Para se obter uma melhor qualidade visual, testou-se a aplicação de algumas técnicas de processamento de imagem. Foi aplicado aumento de contraste através de correção logarítmica (SCIKIT-IMAGE, [s. d.]) e aumento de nitidez obtido pela diferença entre a imagem original e sua versão desfocada (SCIKIT-IMAGE, [s. d.]). Na Figura 20 é mostrado o antes e o depois da aplicação das técnicas.

Figura 20 – Antes (esquerda) e depois (direita) da aplicação de nitidez e contraste



Fonte: O pesquisador

Para que os algoritmos que fossem utilizados tivessem foco apenas no mosquito, fez-se a segmentação da imagem através da biblioteca OpenCV, onde foi removido o excesso de plano de fundo (Figura 21).

Figura 21 – Aplicação de segmentação na imagem para remover o excesso de plano de fundo




Fonte: O pesquisador

Tinha-se por objetivo capturar 6.000 imagens, contudo, devido às medidas de restrições da pandemia de COVID-19, o processo precisou ser interrompido e ao total foram capturadas 5.438 imagens, sendo 1.001 de *C. quinquefasciatus* macho, 1.005 de *C. quinquefasciatus* fêmea, 1.000 de *A. aegypti* macho, 1.000 de *A. aegypti* fêmea, 740 de *A. albopictus* macho e 692 de *A. albopictus* fêmea.

Para ser o mais fiel possível à proposta inicial de 1.000 imagens por espécie e sexo, foram pegas 1.000 imagens das capturas que passaram de 1.000 (*C. quinquefasciatus* macho e *C. quinquefasciatus* fêmea), ficando a base com a configuração vista na Figura 22. Para contornar o desbalanceamento da base, algumas técnicas foram usadas e serão explicadas na próxima seção.

Figura 22 – Quantitativo da base de imagens



Fonte: O pesquisador

No contexto de inteligência artificial esses agrupamentos são chamados de tipos ou classes (CARVALHO et al., 2011), sendo a segunda opção a mais utilizada. Entretanto, no contexto de biologia, classe é uma categoria taxonômica. Desse modo, para evitar confusão, será utilizado o termo “tipo” para designar imagens pertencentes a determinado grupo espécie-sexo.

Para facilitar a escrita e a otimização de espaço, os nomes dos tipos serão abreviados para a exibição em gráficos, tabelas etc.:

- *A. aegypti* macho: aae-macho;
- *A. aegypti* fêmea: aae-femea;
- *A. albopictus* macho: aal-macho;
- *A. albopictus* fêmea: aal-femea;
- *C. quinquefasciatus* macho: cq-macho;
- *C. quinquefasciatus* fêmea: cq-femea.

4.5 SOLUÇÕES PARA O DESBALANCEAMENTO DA BASE

Como foi mostrado, a base se encontra desbalanceada e, conseqüentemente, com dados aquém do esperado. Isso pode causar alguns problemas, um deles é o enviesamento do modelo para determinado tipo. Uma vez que a maioria dos modelos de aprendizagem de máquina foi construída com a suposição da existência de um número de exemplos iguais para cada tipo, um desequilíbrio nessas quantidades pode resultar em modelos com baixo desempenho preditivo, principalmente para a classe minoritária (BROWNLEE, 2019a). Outro problema é a pouca representatividade dos dados para o treinamento, uma vez que haverá menos dados para treinar. Para resolver esses problemas foram utilizados dois métodos: o aumento de dados e a atribuição de pesos para os tipos.

O aumento de dados (*Data Augmentation*) parte da suposição de que mais informações podem ser extraídas do conjunto de dados através do aumento da sua quantidade. Esse aumento é feito através de transformações nos dados, como transformações geométricas e de cor (SHORTEN; KHOSHGOFTAAR, 2019); logo, os dados de treinamento terão um aumento sem a necessidade da coleta de novas amostras. Nesta pesquisa, as transformações para aumento de dados, aplicadas aos dados de treinamento, foram escolhidas de modo a evitar que as novas amostras fugissem às características reais dos mosquitos estudados, o que poderia ocorrer se fossem feitas transformações de cor, por exemplo.

Foram aplicadas as seguintes transformações:

- **rotation_range**: intervalo de graus para rotação aleatória;
- **zoom_range**: intervalo para zoom aleatório;
- **width_shift_range**: intervalo de mudança de largura;
- **height_shift_range**: intervalo de mudança de altura;
- **shear_range**: intensidade de cisalhamento (deformação) (ângulo de cisalhamento no sentido anti-horário em graus);
- **horizontal_flip**: inverte aleatoriamente as entradas horizontalmente.

Na Tabela 4 vê-se os valores de cada transformação, que foram aplicadas na base de treinamento. A cada época da fase de treinamento essas transformações foram aplicadas.

Tabela 4 – Transformações aplicadas no aumento de dados e seus valores

Transformação	Valor
rotation_range	20
zoom_range	0.15
width_shift_range	0.2
height_shift_range	0.2
shear_range	0.15
horizontal_flip	True

Fonte: O pesquisador

A atribuição de pesos aos tipos consiste em estimar os pesos baseando-se nas quantidades de cada tipo e atribuir ao modelo. Desse modo, tipos minoritários terão pesos maiores e, assim, maior relevância no treinamento. Na Tabela 5 vê-se os valores dos pesos atribuídos a cada tipo, de acordo com a base construída nessa pesquisa, obtidos pela função *compute_class_weight* da biblioteca Scikitlearn (SCIKITLEARN, [s. d.]).

Tabela 5 – Atribuição de pesos aos tipos de mosquitos baseados nas quantidades de cada tipo

Tipo	Valor
aae-femea	0.905
aae-macho	0.905
aal-femea	1.309
aal-macho	1.223
cq-femea	0.905
cq-macho	0.905

Fonte: O pesquisador

4.6 MODELOS E AJUSTES

Neste trabalho, três modelos convolucionais foram utilizados: VGG16, ResNet50 e EfficientNetB0. A escolha se deu pelos bons desempenhos apresentados por essas redes para diferentes problemas de aprendizagem de máquina, como pode ser visto em (SIMONYAN; ZISSERMAN, 2014), (HE, K. *et al.*, 2015) e (TAN; LE, 2019), respectivamente.

Para a realização dos experimentos é necessário ajustar os modelos através do conjunto de hiperparâmetros. Um hiperparâmetro de um modelo é uma configuração externa ao modelo, o qual o valor não pode ser estimado a partir dos dados. Não se pode saber o melhor valor para um hiperparâmetro em um determinado problema. Pode-se, no entanto, utilizar regras práticas, copiar valores usados em outros problemas ou pesquisar o melhor valor por tentativa e erro (BROWNLEE, 2017).

As escolhas dos hiperparâmetros desta pesquisa foram feitas com base em recomendações de publicações das documentações das bibliotecas utilizadas, a partir da observação de valores comumente usados em problemas semelhantes e por tentativa e erro.

Os hiperparâmetros comuns utilizados nos experimentos foram:

- **include_top**: se deve incluir as 3 camadas totalmente conectadas no topo da rede;
- **weights**: define como os pesos serão inicializados. Caso seja None, a inicialização é aleatória, 'imagenet' serão carregados os pesos pré-treinados na base ImageNet ou um caminho para um arquivo de pesos a ser carregado;
- **input_shape**: tupla que define o formato das imagens de entrada;
- **loss**: função objetivo que visa minimizar o erro do modelo;
- **optimizer**: atualiza os parâmetros de peso para minimizar a função de perda;
- **learning_rate**: define o tamanho da etapa em cada iteração;

- **epochs**: número de épocas para treinar o modelo. Uma época consiste em uma iteração sobre todos os dados x e y ;
- **batch_size**: número de amostras de treinamento usadas em uma iteração.

Os hiperparâmetros mais sensíveis foram a taxa de aprendizado e o número de épocas, uma vez que, na variação deles observou-se relevantes alterações (positivas e negativas) nos resultados.

Segundo GoodFellow (GOODFELLOW; BENGIO; COURVILLE, 2016), talvez o hiperparâmetro mais importante seja a taxa de aprendizado, pois controla a taxa ou a velocidade com que o modelo aprende. Uma taxa de aprendizado grande permite que o modelo aprenda mais rápido, entretanto pode correr o risco de chegar a um conjunto de pesos abaixo do ideal. Uma taxa de aprendizado menor pode permitir que o modelo aprenda um conjunto de pesos mais otimizado, porém o treinamento pode levar muito tempo (BROWNLEE, 2019b).

Brownlee (BROWNLEE, 2019b) fala que 0.1 ou 0.01, valores tradicionais padrões para a taxa de aprendizado, podem representar um bom ponto de partida.

Nesta pesquisa escolheu-se por tentativa e erro a taxa de aprendizagem dentro dos seguintes valores: 0.1, 0.01, 0.001 e 0.0001.

No início da pesquisa escolheu-se o número de épocas 50, porém foi sendo expandido até chegar ao valor 300, que apresentou ser uma boa quantidade, levando em consideração o tempo de treinamento e a observação do momento de convergência dos modelos.

4.7 MÉTRICAS

Para a avaliação de desempenho dos modelos foram utilizadas as seguintes métricas: acurácia, precisão, *recall*, *F1-Score*, matriz de confusão e curva ROC.

A matriz de confusão é uma estrutura que pode representar a decisão de um classificador. Em problemas binários ela é dividida em quatro categorias (DAVIS; GOADRIC, 2006):

- Verdadeiros positivos (TP – *True Positive*) são exemplos corretamente rotulados como positivos;

- Falsos positivos (FP – *False Positive*) referem-se a exemplos negativos rotulados incorretamente como positivo;
- Verdadeiros negativos (TN – *True Negative*) correspondem a negativos rotulados corretamente como negativos;
- Falsos negativos (FN – *False Negative*) referem-se a exemplos positivos rotulados incorretamente como negativo.

A acurácia (Eq. 1) consiste na quantidade de instâncias classificadas corretamente do total de instâncias. Sendo definida como a razão entre o número de previsões corretas e o número total de predições (SHOBHA; RANGASWAMY, 2018).

$$acurácia = \frac{TP + TN}{TP + FP + TN + FN}$$

(Eq. 1)

A precisão (Eq. 2) é considerada uma medida da exatidão do classificador, uma vez que quantifica as verdadeiras instâncias positivas entre todas as instâncias positivas (PICEK *et al.*, 2019).

$$precisão = \frac{TP}{TP + FP}$$

(Eq. 2)

Recall (Eq. 3) é uma métrica que quantifica o número de previsões positivas corretas feitas a partir de todas as previsões positivas que poderiam ter sido feitas (BROWNLEE, 2020a).

$$recall = \frac{TP}{TP + FN}$$

(Eq. 3)

O *F1-Score* (Eq. 4) é a média harmônica entre a precisão e o recall (PICEK *et al.*, 2019).

$$F1_Score = 2 * \frac{precisão * recall}{precisão + recall}$$

(Eq. 4)

A curva ROC é um gráfico que investiga a relação entre a sensibilidade e especificidade de um classificador (FLACH, 2016). Pode-se pensar no gráfico como a fração de inferências corretas (taxa de TP) (Eq. 5) contra a fração de erros (taxa de FP) (Eq. 6), onde se deseja que a fração de inferências corretas seja 1 (parte superior do gráfico) e a fração de inferências incorretas seja 0 (parte esquerda do gráfico). Sendo então, a classificação ideal aquela que atinge o canto superior esquerdo do gráfico (0,1) (BROWNLEE, 2020b).

$$\text{Taxa de TP} = \text{sensibilidade} = \frac{TP}{TP + FN}$$

(Eq. 5)

$$\text{Taxa de FP} = 1 - \text{especificidade} = \frac{FP}{FP + TN}$$

(Eq. 6)


Comparar classificações baseadas nas curvas pode ser um desafio. Em vez disso, a área sob a curva pode ser calculada para fornecer uma pontuação única para a classificação (BROWNLEE, 2020b). A Área Abaixo da Curva ou AUC é a estatística mais importante associada à curva ROC. Seu valor pode variar entre 0 e 1, sendo o valor 1 a pontuação ideal (FLACH, 2016).

4.8 PIPELINE DA CLASSIFICAÇÃO

Na Figura 23 tem-se o pipeline do esquema de classificação desta pesquisa:

- Inicialmente a imagem é pré-processada, onde procura-se melhorar a sua qualidade e destacar a área de interesse;
- Após isso ela é passada para o modelo convolucional, que é responsável pela extração das características e interpretação da imagem;
- Por fim, tem-se a classificação da imagem, onde é informada a espécie e o sexo do mosquito.

Figura 23 – Pipeline do esquema de classificação



Fonte: O pesquisador

4.9 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foram mostrados os passos e escolhas feitas para a construção da base de imagens. Enfatizou-se a escolha de um material de baixo custo para as capturas das imagens, para facilitar a reprodutibilidade do método. E mostrou-se o pipeline de classificação da pesquisa.

Ao longo do processo algumas dificuldades foram encontradas, como a definição do ambiente de captura, as posições dos espécimes, o manuseio deles. E por meio de tentativas cada ponto foi sendo definido. Uma das maiores dificuldades foi a manutenção do mosquito em determinada posição, uma vez que eles eram congelados em posições diversas. O cansaço visual também foi um ponto significativo, uma vez que se estava manipulando um inseto pequeno; recomenda-se que a cada hora uma pausa de 10 a 15 minutos seja realizada. Para o problema do desbalanceamento da base (devido à pandemia de COVID-19), foi aplicado o aumento de dados no treinamento dos modelos e o uso de atribuição de pesos para os tipos das imagens.

Em um panorama geral, a construção da base de imagens foi um trabalho que exigiu paciência, pela quantidade de espécimes envolvidas, atenção, por se estar lidando com insetos pequenos, delicados e muitas vezes semelhantes, e dedicação, muitas vezes devido ao cansaço do trabalho repetitivo de captura.

No próximo capítulo será explicado como, a partir dessa base de imagens construída, os algoritmos de classificação foram treinados, e serão detalhadas as análises sobre os resultados obtidos.

5 EXPERIMENTOS E RESULTADOS


Neste capítulo serão abordados os passos que permitiram a execução dos experimentos, bem como a exibição dos resultados e as análises feitas a partir deles.

Na seção 5.1 a construção dos experimentos será mostrada, informando as configurações do ambiente para execução. Na seção 5.2 as configurações dos experimentos serão detalhadas. E por fim, na seção 5.3, os resultados de cada modelo serão vistos sob diversas métricas, e as análises a partir desses resultados serão discutidas para auxiliar na escolha do modelo mais adequado para utilização.

5.1 CONSTRUÇÃO DOS EXPERIMENTOS

Para a realização dos experimentos de classificação, a base necessitou ser dividida: 70% das imagens de cada tipo foram aleatoriamente separadas em um diretório para serem utilizadas na fase de treinamento, 15% foram separadas para a fase de validação e mais 15% para a fase de teste (Figura 24).

Figura 24 – Divisão da base de imagens




Fonte: O pesquisador

Após essa divisão, foram aplicados modelos de aprendizagem profunda, que foram treinados com os dados de treinamento aumentados e avaliados com o conjunto de validação, isso em 300 épocas. Então, os modelos foram testados com o conjunto de teste.

Na Figura 25 pode-se ver um fluxograma de como foi construído o experimento.

Figura 25 – Fluxograma para a construção do experimento



Fonte: O pesquisador

O *Google Colaboratory* foi a plataforma em que os experimentos foram executados, um ambiente *Jupyter* com execução na nuvem do Google, podendo ser executados códigos em Python ou R (PCDAS, [s. d.]). Neste trabalho foram utilizados códigos em Python.

Para a construção do código foram utilizadas as bibliotecas Scikit-learn (SCIKIT-LEARN, [s. d.]), TensorFlow (TENSORFLOW, [s. d.]), Numpy (NUMPY, [s. d.]) e Matplotlib (MATPLOTLIB, [s. d.]).

5.2 EXPERIMENTOS

A seguir, serão expostos os valores escolhidos para cada hiperparâmetro em cada modelo.

5.2.1 VGG16

A VGG16 foi executada em cima de uma GPU Tesla P100-PCIE com 16,8 GB de memória, com os seguintes hiperparâmetros:

Tabela 6 – Configuração final dos hiperparâmetros da VGG16

Hiperparâmetro	Valor
include_top	True
weights	None
Input_shape	(224,224,3)
loss	CategoricalCrossentropy
optimizer	SGD
learning_rate	0.01
epochs	300
batch_size	32

Fonte: O pesquisador

5.2.2 ResNet50

A ResNet50 foi executada em cima de uma GPU Tesla P100-PCIE com 16,8 GB de memória com os seguintes hiper parâmetros:

Tabela 7 – Configuração final dos hiperparâmetros da ResNet50

Hiperparâmetro	Valor
include_top	True
weights	None
Input_shape	(128,128,3)
loss	CategoricalCrossentropy
optimizer	SGD
learning_rate	0.001
epochs	300
batch_size	32
momentum	0.9
decay	learning_rate/epochs

Fonte: O pesquisador

Além dos hiperparâmetros mencionados anteriormente, são utilizados mais dois nesse modelo, com o objetivo de tentar melhorar a performance:

momentum: hiperparâmetro que acelera a descida do gradiente em uma direção relevante;

decay: reduz a taxa de aprendizado por um fator a cada poucas épocas. A intenção é que mudanças mais atenuadas sejam aplicadas à medida que o modelo vá aprendendo.

Nesse experimento observou-se a necessidade do uso da técnica *early stopping*, uma vez que o modelo começou a apresentar overffiting.

O early stopping é uma técnica em que o treinamento do modelo é parado no ponto onde a performance na validação começa a diminuir (BROWNLEE, 2018). Para isso fez-se uso do hiperparâmetro patience com valor 20. Ou seja, se em 20 épocas o modelo não tiver melhoras na performance o treinamento é parado. Assim, o modelo parou de treinar na época 58.

5.2.3 EfficientNetB0

A EfficientNetB0 foi executada em cima de uma GPU Tesla P100-PCIE com 16,8 GB de memória com os seguintes hiperparâmetros:

Tabela 8 – Configuração final dos hiperparâmetros da EfficientNetB0

Hiper parâmetro	Valor
include_top	True
weigths	None
Input_shape	(224,224,3)
loss	CategoricalCrossentropy
optimizer	SGD
learning_rate	0.0001
epochs	300
batch_size	32

Fonte: O pesquisador

Assim como no experimento anterior, percebeu-se a tendência a *overfitting*, sendo aplicada a técnica de early stopping com o mesmo valor do patience do modelo anterior, parando na época 140.

5.3 RESULTADOS E ANÁLISES

Para poder-se indicar qual dos modelos se posiciona como o mais adequado para utilização, deve-se observar alguns indicadores. Nesta seção será olhado para os resultados sob diversos ângulos, analisando o tempo de execução do treinamento e da inferência, as curvas de aprendizado e erro, bem como algumas métricas de desempenho, como a acurácia, a precisão, o recall e o F1-score.

Olhando para os gráficos das curvas de aprendizado, pode-se perceber que o modelo VGG16 (Figura 26) conseguiu generalizar o aprendizado na base de imagens. Chega-se a essa conclusão observando que, tanto a curva de erro de treinamento quanto a de validação descem juntas, até chegarem à convergência do modelo.


No modelo EfficientNetB0 (Figura 27) o erro na validação oscila bastante, no entanto, ao passar das épocas a curva desse erro acompanha a curva do erro de treinamento.

No modelo ResNet50 (Figura 28) a curva do erro de validação oscila muito e vai se distanciando da curva do erro de treinamento.

Observando as médias das acurácias dos modelos (obtidas das últimas 30 acurácias do processo de treinamento/validação), tanto do treinamento como da validação (Tabela 9), pode-se perceber que no modelo ResNet50 também há essa discrepância de valores, onde a acurácia do treinamento foi 91%, enquanto a acurácia da validação foi 82.7%. A partir dessa análise das curvas de aprendizagem e das acurácias nota-se indícios de *overffiting* nesse modelo, o que ocorre quando o modelo se ajusta demais aos dados de treinamento, não generalizando o aprendizado. Ressaltando que o modelo passou pelo mesmo processo de construção que os demais e ainda foram aplicadas algumas técnicas, momentum e *decay*, explicadas na seção 5.3.2, na tentativa de evitar o problema, mas sem sucesso.


Visto isso, o modelo ResNet50 não será utilizado na comparação dos modelos, ficando apenas os modelos VGG16 e EfficientNetB0.

Figura 26 – VGG16 - curvas de aprendizado e erro dos conjuntos de treinamento e validação



Fonte: O pesquisador

Figura 27 – EfficientNetB0 - curvas de aprendizado e erro dos conjuntos de treinamento e validação



Fonte: O pesquisador

Figura 28 – ResNet50 - curvas de aprendizado e erro dos conjuntos de treinamento e validação



Fonte: O pesquisador


Tabela 9 – Médias das acurácias de treinamento e validação

Modelo	Média da acurácia de treinamento	Desvio padrão de treinamento	Média da acurácia de validação	Desvio padrão da validação
VGG16	96%	0.005	94.7%	0.033
EfficientNetB0	95%	0.008	93.1%	0.026
ResNet50	91%	0.019	82.7%	0.076

Fonte: O pesquisador


Outro ponto a ser analisado são os tempos de treinamento e de inferência. Na Figura 29 nota-se que a VGG16 possui um tempo maior de treinamento, cerca de 10h e 20 min, em comparação com a EfficientNetB0, cerca de 4h e 30 min. No entanto, ao observar o tempo de inferência de uma imagem (Figura 30) os resultados se invertem, a VGG16 possui um menor tempo, 11 milissegundos, enquanto a EfficientNetB0 apresentou 14 milissegundos.

Figura 29 – Comparação dos tempos de treinamento



Fonte: O pesquisador

Figura 30 – Comparação dos tempos de inferência de uma imagem de mosquito



Fonte: O pesquisador

Observando as acurácias dos dois modelos, vê-se que a VGG16 obteve uma acurácia maior (95%) (Tabela 10) do que o modelo EfficientNetB0 (94%) (Tabela 11).

Como a base de dados é desbalanceada, olha-se para a métrica F1-Score, que é a média harmônica entre a Precisão e o Recall. Assim consegue-se obter um olhar mais equilibrado sobre quão assertivo o modelo é em suas predições (precisão) e quão bom é em identificar os tipos de imagens na base (recall).

Tabela 10 – VGG16- Métricas de avaliação do conjunto de teste

Tipo	Precisão	Recall	F1-Score	Número de amostras (suporte)
aae-femea	96%	95%	95%	150
aae-macho	92%	90%	91%	150
aal-femea	89%	95%	92%	104
aal-macho	90%	89%	90%	111
cq-femea	99%	98%	99%	150
cq-macho	98%	99%	99%	150
Acurácia do modelo	95%			Total de Amostras
				815
Média macro	94%	94%	94%	815
Média ponderada	95%	95%	95%	815

Fonte: O pesquisador

No modelo VGG16 o tipo que apresentou o menor *F1-Score* foi o aal-macho, com 90% e os tipos com maiores *F1-Score* foram o cq-macho e cq-femea com 99% cada (Tabela 10).

No modelo EfficientNet (Tabela 11), o que apresentou pior *F1-Score* foi novamente o tipo aal-macho, porém com um valor menor do que o do modelo anterior, 85% e os tipos com maiores *F1-Score* continuaram sendo o cq-macho e cq-femea, com 98%.

Tabela 11 – EfficientNetB0 - Métricas de avaliação do conjunto de teste

Tipo	Precisão	Recall	F1-Score	Número de amostras (suporte)
aae-femea	95%	98%	97%	150
aae-macho	88%	92%	90%	150
aal-femea	94%	98%	96%	104
aal-macho	93%	79%	85%	111
cq-femea	97%	99%	98%	150
cq-macho	99%	97%	98%	150
Acurácia do modelo	94%			Total de Amostras
				815
Média macro	94%	94%	94%	815
Média ponderada	94%	94%	94%	815


Fonte: O pesquisador

Ao se fazer a comparação dos resultados das duas tabelas anteriores, percebe-se que o modelo VGG16 apresenta valores mais próximos entre si no *F1-Score*, indicando um maior equilíbrio entre as precisões e os recalls.

Para visualizar em mais detalhes as inferências do modelo, pode-se recorrer à matriz de confusão. No eixo horizontal tem-se as inferências e no eixo vertical os rótulos verdadeiros. A matriz de confusão ideal seria aquela em que os resultados estivessem todos na diagonal principal, pois significaria que o modelo acertou todas as inferências. Logo, ao fazer uma análise com essa matriz, deve-se olhar primeiramente para a diagonal principal, para verificar os acertos, e posteriormente ir observando em quais classes o modelo ficou confuso e errou, tentando entender o motivo das principais confusões. Na

Figura 31 vê-se a matriz de confusão do modelo VGG16. Pode-se notar uma boa ocorrência de acertos, havendo pequenos erros entre alguns tipos:

Figura 31 – VGG16 - Matriz de confusão utilizando o conjunto de teste



Fonte: O pesquisador

A VGG16 inferiu que 5 imagens eram do tipo aae-macho, mas eram do tipo aal-macho, bem como inferiu que 8 imagens eram do tipo aal-macho, mas eram do tipo aae-macho. Supõe-se que essas confusões se deram por conta dos mosquitos pertencerem ao mesmo gênero, *Aedes*, compartilhando assim características em comum, como a presença de listras brancas no corpo e nas patas, por exemplo. Na Figura 32 vê-se um espécime de *A. aegypti* macho (a) e ao lado um espécime de *A. albopictus* macho (b), podendo assim serem visualmente comparados. Pode-se notar as listras brancas citadas.


Figura 32 – Comparação das semelhanças visuais entre *A. aegypti* macho (a) e *A. albopictus* macho (b)



Fonte: O pesquisador

A VGG16 inferiu também que 6 imagens eram do tipo aal-femea, mas na verdade eram do tipo aal-macho. Aqui nota-se uma confusão com mosquitos de uma mesma espécie, supõe-se mais uma vez que isso ocorreu pelos espécimes apresentarem características em comum. Na Figura 33 vê-se, como exemplo, um espécime de *A. albopictus* fêmea (a) e ao lado um espécime de *A. albopictus* macho (b). A diferença visual mais relevante entre os dois são as antenas. As do macho são mais plumadas.


Figura 33 – Comparação das semelhanças visuais entre *A. albopictus* fêmea (a) e *A. albopictus* macho (b)



Fonte: O pesquisador

Analisando as inferências a partir dos mosquitos da espécie *C. quinquefasciatus* nota-se algumas confusões entre os tipos cq-macho e cq-fêmea, novamente pela suposição de características semelhantes entre mosquitos da mesma espécie e quase nenhuma confusão entre os *Aedes* e o *Culex*. Supõe-se que isso ocorra devido às espécies possuírem características mais distintas entre si.


Figura 34 – EfficientNetB0 - Matriz de confusão utilizando o conjunto de teste



Fonte: O pesquisador

Observando a matriz de confusão da EfficientNetB0 (Figura 34), nota-se um comportamento semelhante à matriz anterior, porém em diferente quantidade. Nota-se que a EfficientNetB0 inferiu que 18 imagens eram do tipo aae-macho quando, na verdade, eram do tipo aal-macho. Mostrando assim, a presença de uma maior confusão do que o modelo VGG16.


Figura 35 – VGG16 - Curva ROC utilizando o conjunto de teste



Fonte: O pesquisador

Na Figura 35 é mostrada a curva ROC. Pode-se observar que todas as classes tiveram valor de AUC próximos de 1, as que tiveram menor desempenho de distinção foram a aae-macho com AUC de 0.9942 e a aal-macho com AUC de 0.9949.

Figura 36 – EfficientNetB0 - Curva ROC utilizando o conjunto de teste



Fonte: O pesquisador

Na Figura 36 é mostrada a curva ROC da EfficientNetB0. Assim como na VGG16, as classes tiveram valores de AUC próximos de 1. As classes aae-macho e aal-macho também tiveram os menores desempenhos de distinção e estes foram menores que os do modelo VGG16, com AUC de 0.9898 e 0.9844, respectivamente.

Com isso observou-se que o modelo VGG16 possui performance maior nas métricas analisadas, mostrando-se o mais adequado para a proposta de classificação deste trabalho. E com esses ótimos resultados pode-se pensar no uso do modelo para implantação em uma aplicação móvel, para que tanto profissionais quanto pessoas leigas possam beneficiar-se com a possibilidade de classificação automática desses vetores.

5.4 DIFICULDADES E LIMITAÇÕES

Durante o desenvolvimento deste trabalho algumas dificuldades foram enfrentadas. Houve um momento em que a larvicultura dos mosquitos passou por um problema de contaminação fúngica, ocasionando o comprometimento na obtenção de mosquitos adultos. Em outro momento, próximo da finalização da base, o surgimento da pandemia de COVID-19 impediu que mais coletas fossem feitas, ficando os mosquitos da espécie *A. albopictus* em quantidade aquém da planejada.

Como limitações da pesquisa pode-se citar esse desbalanceamento da base, uma vez que os modelos são projetados para aprender com um mesmo número de tipos. A coleta em ambiente controlado também figura como uma limitação, já que mosquitos criados em laboratório podem diferir morfológicamente de mosquitos selvagens.

Outra limitação foi a não realização de testes estatísticos entre os modelos, por conta da limitação de tempo de uso do ambiente de execução *Google Colab*. Não sendo assim possível afirmar, se possuem diferenças estatísticas nas suas performances de classificação.

5.5 CONSIDERAÇÕES DO CAPÍTULO

Este capítulo detalhou a construção dos experimentos com os três modelos convolucionais escolhidos: VGG16, ResNet50 e EfficientNetB0, mostrando as configurações usadas no ambiente de execução e em cada modelo.

Foi identificada a presença de *overfitting* no modelo ResNet50 que, por esse motivo, não foi utilizado para comparação com os outros modelos.

Com os resultados observados sob diversos aspectos, curvas de aprendizado e erro, tempo de treinamento e inferência, matriz de confusão, acurácia, precisão, *recall*, *F1-Score*, curva ROC e AUC, fez-se análises em cima de cada modelo.

Um ponto a ser ressaltado foi a confusão, mesmo que pequena, dos modelos com os mosquitos do gênero *Aedes*. Mesmo sendo de diferentes espécies, eles compartilham semelhanças do gênero e essa pode ser uma questão a ser observada, caso se construa um modelo com diversos mosquitos de espécies distintas, mas do mesmo gênero.

No próximo capítulo será feita a conclusão do trabalho, a apresentação das dificuldades e limitações e a sugestão de trabalhos futuros.

6 CONCLUSÃO E TRABALHOS FUTUROS

Como foi definido na seção 1.2, o objetivo geral deste trabalho foi o desenvolvimento de um modelo computacional inteligente de baixo custo, para reconhecimento de espécies de mosquitos vetores. Para que esse objetivo pudesse ser alcançado, cinco objetivos específicos foram definidos.

No capítulo 3, um mapeamento sistemático da literatura foi feito para fornecer uma visão da conjuntura atual de trabalhos que propusessem soluções de classificação de mosquitos através de métodos inteligentes. Pôde-se perceber a variedade de técnicas utilizadas: ondas sonoras, raio infravermelho, material genético e visão computacional.

Nesse trabalho escolheu-se o uso de visão computacional, por apresentar método de captura mais comum e de equipamento de baixo custo, além de resultar boa performance.

Para a construção da base de imagens foi definido um método de captura onde foi utilizado um microscópio digital de 5 MP de resolução, com preço aproximado de R\$ 400,00 (quatrocentos reais). Os mosquitos foram colocados em um molde quadriculado de papel ofício que foi fixado à base do microscópio, para definir o posicionamento em relação à câmera; e os mosquitos posicionados com o auxílio de pinças de precisão. Atendendo, esse método de captura, ao primeiro objetivo específico: definir um método de captura de dados com base em equipamentos de baixo custo.

Uma vez definido o método, foi feita a captura de 5.438 imagens de mosquitos dos gêneros *Aedes* e *Culex*, sendo as amostras fornecidas pelo Instituto Aggeu Magalhães. Após isso foi realizado pré-processamento nas imagens, concluindo a construção da base, o que atende ao segundo objetivo específico: criar uma base de imagens de mosquitos vetores de arboviroses.

Em seguida, a base criada foi utilizada no processo de aprendizagem e análise de três modelos convolucionais: VGG16, ResNet50 e EfficientNetB0. O que atende ao terceiro objetivo específico: utilizar a base criada no processo de aprendizagem de modelos de classificação baseados em aprendizagem profunda.

Com base nas curvas de aprendizado, notou-se que o modelo ResNet50 não conseguiu aprender a classificar os mosquitos de modo generalista, o que fez com que o modelo fosse descartado.

Os outros dois modelos apresentaram ótimos resultados. A VGG16 apresentando uma maior acurácia de teste do que a EfficientNetB0: a VGG16 obteve 95%, enquanto a EfficientNetB0 94%.

Olha-se para a métrica F1-Score, que mostra o equilíbrio entre a precisão e o recall, o modelo VGG16 apresentou valores mais próximos entre si do que o modelo EfficientNetB0. As matrizes de confusão mostraram que o modelo EfficientNetB0 se confunde mais do que o modelo VGG16. E com a análise da curva ROC, pôde-se ver que o modelo VGG16 é o que melhor faz distinção entre os tipos. Quanto aos tempos de treinamento e inferência, a VGG16 tem um tempo maior de treinamento, entretanto um tempo menor de inferência.

Dadas essas análises, o modelo VGG16 foi proposto como o mais adequado para a classificação de mosquitos vetores desse trabalho. Atendendo assim aos dois últimos objetivos específicos: avaliar os resultados a partir dos treinamentos dos modelos e definir o modelo a ser proposto. E, com isso, consegue-se atingir o objetivo geral definido.

Analisando as contribuições e limitações deste trabalho, consegue-se enxergar esforços futuros que possam, a partir dele, gerar novas contribuições. Dito isto, os seguintes trabalhos futuros são propostos:

- Realizar a captura de mais imagens de *A. albopictus* para balancear a base e realizar novos treinamentos, para avaliar se há ou não melhoria na performance;
- Construir uma base com mosquitos capturados em ambiente natural e testá-la com o modelo proposto, para avaliar a capacidade de classificação de mosquitos selvagens;
- Criar uma base mista (mosquitos criados em ambiente controlado e selvagens) e testar se modelos treinados com elas mantêm ou conseguem superar a performance conseguida nesse trabalho;
- Realizar testes estatísticos com os modelos para identificar se existem diferenças estatísticas entre eles;
- Implantar o modelo proposto em uma aplicação para dispositivos móveis para testar inferências em campo;

- Expandir a base com novas espécies de mosquitos vetores para a construção de modelos com maior abrangência.

REFERÊNCIAS

AFFONSO, Carlos *et al.* Deep learning for biological image classification. **Expert Systems with Applications**, [s. l.], v. 85, p. 114–122, 2017.

AKHTAR, Mahmood; KRAEMER, Moritz U G; GARDNER, Lauren M. A dynamic neural network model for predicting risk of Zika in real time. **BMC medicine**, [s. l.], v. 17, n. 1, p. 1–16, 2019.

ALAR, Hernan S; FERNANDEZ, Proceso L. Classifying mosquito presence and genera using median and interquartile values from 26-filter wingbeat acoustic properties. **Procedia Computer Science**, [s. l.], v. 193, p. 453–463, 2021.

ALIBABA. **No Title**. [S. l.], [s. d.]. Disponível em: <https://portuguese.alibaba.com/product-detail/green-stainless-steel-precision-tweezers-set-anti-static-tweezers-repair-tool-soldering-station-welding-assist-esd-62486553601.html>. Acesso em: 13 jan. 2022.

ALOM, Md Zahangir *et al.* The history began from alexnet: A comprehensive survey on deep learning approaches. **arXiv preprint arXiv:1803.01164**, [s. l.], 2018.

AMIRUDDIN, Brilian Putra; KADIR, Rusdhianto Effendi Abdul. CNN architectures performance evaluation for image classification of mosquito in indonesia. *In: , 2020. 2020 International Seminar on Intelligent Technology and Its Applications (ISITIA)*. [S. l.]: IEEE, 2020. p. 223–227.

AWAIDY, Salah Al; AL HASHAMI, Hilal. Zoonotic diseases in Oman: successes, challenges, and future directions. **Vector-Borne and Zoonotic Diseases**, [s. l.], v. 20, n. 1, p. 1–9, 2020.

BROWNLEE, Jason. **A Gentle Introduction to Early Stopping to Avoid Overtraining Neural Networks**. [S. l.], 2018. Disponível em: <https://machinelearningmastery.com/early-stopping-to-avoid-overtraining-neural-network-models/>. Acesso em: 5 jan. 2022.

BROWNLEE, Jason. **A Gentle Introduction to Imbalanced Classification**. [S. l.], 2019a. Disponível em: <https://machinelearningmastery.com/what-is-imbalanced-classification/>. Acesso em: 4 jan. 2022.

BROWNLEE, Jason. **How to Calculate Precision, Recall, and F-Measure for Imbalanced Classification**. [S. l.], 2020a. Disponível em: <https://machinelearningmastery.com/precision-recall-and-f-measure-for-imbalanced-classification/>. Acesso em: 5 jan. 2022.

BROWNLEE, Jason. **How to Configure the Learning Rate When Training Deep Learning Neural Networks**. [S. l.], 2019b. Disponível em: <https://machinelearningmastery.com/learning-rate-for-deep-learning-neural-networks/>. Acesso em: 4 jan. 2022.

BROWNLEE, Jason. **ROC Curves and Precision-Recall Curves for Imbalanced Classification**. [S. l.], 2020b. Disponível em: <https://machinelearningmastery.com/roc-curves-and-precision-recall-curves-for-imbalanced-classification/>. Acesso em: 7 jan. 2022.

BROWNLEE, Jason. **What is the Difference Between a Parameter and a Hyperparameter?**. [S. l.], 2017. Disponível em: <https://machinelearningmastery.com/difference-between-a-parameter-and-a-hyperparameter/>. Acesso em: 4 jan. 2022.

CARLSON, Colin J *et al.* Zoonotic risk technology enters the viral emergence toolkit. [s. l.], 2021.

CARVALHO, André *et al.* Inteligência Artificial—uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**, [s. l.], p. 45, 2011.

CARVALHO, Fabiana Rabe *et al.* Simultaneous circulation of arboviruses and other congenital infections in pregnant women in Rio de Janeiro, Brazil. **Acta tropica**, [s. l.], v. 192, p. 49–54, 2019.

CHUMCHU, Reshma Pise; Mayawadee Aungmaneepon; Kailas Patil; Prawit. **Image Dataset of Aedes and Culex Mosquito Species**. [S. l.]: IEEE Dataport, 2020. Disponível em: <http://10.0.82.235/m05g-mq78>

DANUSER, Gaudenz. Computer Vision in Cell Biology. **Cell**, [s. l.], v. 147, n. 5, p. 973–978, 2011. Disponível em: <https://doi.org/https://doi.org/10.1016/j.cell.2011.11.001>

DAVIS, Jesse; GOADRIC, Mark. The relationship between Precision-Recall and ROC curves. In: , 2006. **Proceedings of the 23rd international conference on Machine learning**. [S. l.: s. n.], 2006. p. 233–240.

DE LOS REYES, Anna Monica M *et al.* Detection of Aedes Aegypti mosquito by digital image processing techniques and support vector machine. In: , 2016. **2016 IEEE Region 10 Conference (TENCON)**. [S. l.]: IEEE, 2016. p. 2342–2345.

DE OLIVEIRA FIGUEIREDO, Poliana *et al.* Re-Emergence of Yellow Fever in Brazil during 2016–2019: Challenges, Lessons Learned, and Perspectives. **Viruses**, [s. l.], v. 12, n. 11, p. 1233, 2020.

DESHPANDE, Aniruddha *et al.* The global distribution of lymphatic filariasis, 2000–18: a geospatial analysis. **The Lancet Global Health**, [s. l.], v. 8, n. 9, p. e1186–e1194, 2020.

DHILLON, Anamika; VERMA, Gyanendra K. Convolutional neural network: a review of models, methodologies and applications to object detection. **Progress in Artificial Intelligence**, [s. l.], v. 9, n. 2, p. 85–112, 2020. Disponível em: <https://doi.org/10.1007/s13748-019-00203-0>

FANIOUDAKIS, Eleftherios; GEISMAR, Matthias; POTAMITIS, Ilyas. Mosquito wingbeat analysis and classification using deep learning. In: , 2018. **2018 26th European Signal Processing Conference (EUSIPCO)**. [S. l.]: IEEE, 2018. p. 2410–2414.

FERNANDES, Marcelo Schreiber; CORDEIRO, Weverton; RECAMONDE-MENDOZA, Mariana. Detecting Aedes aegypti mosquitoes through audio classification with convolutional neural networks. **Computers in Biology and Medicine**, [s. l.], v. 129, p. 104152, 2021.

FIOCRUZ. **A. aegypti X Pernilongo Doméstico**. [S. l.], 2019. Disponível em: <http://www.ioc.fiocruz.br/dengue/textos/aedexculex.html>. Acesso em: 17 set. 2021.

FIOCRUZ. **Uma breve história da febre amarela**. [S. l.], 2008. Disponível em: <https://agencia.fiocruz.br/uma-breve-história-da-febre-amarela>. Acesso em: 9 set. 2021.

FLACH, Peter A. ROC analysis. In: **ENCYCLOPEDIA OF MACHINE LEARNING AND DATA MINING**. [S. l.]: Springer, 2016. p. 1–8.

FONTELLES, Mauro José *et al.* Metodologia da pesquisa científica: diretrizes para a elaboração de um protocolo de pesquisa. **Revista paraense de medicina**, [s. l.], v. 23, n. 3, p. 1–8, 2009.

FRIO, Ponto. **No Title**. [S. l.], [s. d.]. Disponível em: <https://www.pontofrio.com.br/microscopio-digital-rohs-20-mega-pixels-digital-30-fps/p/1519604518>. Acesso em: 13 jan. 2022.

FUCHIDA, Masataka *et al.* Vision-based perception and classification of mosquitoes using support vector machine. **Applied Sciences**, [s. l.], v. 7, n. 1, p. 51, 2017.

FUKUSHIMA, Kunihiko. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, [s. l.], v. 36, n. 4, p. 193–202, 1980. Disponível em: <https://doi.org/10.1007/BF00344251>

GEARBEST. **No Title**. [S. l.], [s. d.]. Disponível em: https://www.gearbest.com/microscopes-endoscope/pp_364457.html. Acesso em: 13 jan. 2022.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. [S. l.]: MIT press, 2016.

GOODWIN, Adam *et al.* Development of a low-cost imaging system for remote mosquito surveillance. **Biomedical Optics Express**, [s. l.], v. 11, n. 5, p. 2560–2569, 2020.

GU, Jiuxiang *et al.* Recent advances in convolutional neural networks. **Pattern Recognition**, [s. l.], v. 77, p. 354–377, 2018. Disponível em: <https://doi.org/https://doi.org/10.1016/j.patcog.2017.10.013>

HAKIM, Ayesha. Automatic Mosquito Surveillance and Visualisation using Acoustic Signals. **Pakistan Journal of Engineering and Applied Sciences**, [s. l.], v. 26, n. 1, 2020.

HAN, Barbara A *et al.* Rodent reservoirs of future zoonotic diseases. **Proceedings of the National Academy of Sciences**, [s. l.], v. 112, n. 22, p. 7039 LP – 7044, 2015. Disponível em: <https://doi.org/10.1073/pnas.1501598112>

HATEKAR, Rohan *et al.* Detection of Mosquito using Digital Image Processing. In: , 2021. **2021 Fourth International Conference on Computational Intelligence and Communication Technologies (CCICT)**. [S. l.]: IEEE, 2021. p. 224–229.

HE, Kaiming *et al.* Deep Residual Learning for Image Recognition. **Proceedings of the IEEE**

Computer Society Conference on Computer Vision and Pattern Recognition, [s. l.], v. 2016-December, p. 770–778, 2015. Disponível em: <https://doi.org/10.1109/CVPR.2016.90>. Acesso em: 29 nov. 2021.

HE, Tong *et al.* Bag of tricks for image classification with convolutional neural networks. In: , 2019. **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. [S. l.: s. n.], 2019. p. 558–567.

HUANG, Li-Pang *et al.* A vector mosquitoes classification system based on edge computing and deep learning. In: , 2018. **2018 Conference on Technologies and Applications of Artificial Intelligence (TAAI)**. [S. l.]: IEEE, 2018. p. 24–27.

IBM. **AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference?** [S. l.], 2020a. Disponível em: <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>. Acesso em: 16 nov. 2021.

IBM. **Neural Networks**. [S. l.], 2020b. Disponível em: <https://www.ibm.com/cloud/learn/neural-networks>. Acesso em: 21 set. 2021.

JOURDAIN, Frédéric *et al.* Identification of mosquitoes (Diptera: Culicidae): an external quality assessment of medical entomology laboratories in the MediLabSecure Network. **Parasites & vectors**, [s. l.], v. 11, n. 1, p. 1–7, 2018.

KEELE, Staffs. **Guidelines for performing systematic literature reviews in software engineering**. [S. l.]: Citeseer, 2007.

KITTICHA, Veerayuth *et al.* Deep learning approaches for challenging species and gender identification of mosquito vectors. **Scientific reports**, [s. l.], v. 11, n. 1, p. 1–14, 2021.

LECUN, Yann *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, [s. l.], v. 86, n. 11, p. 2278–2324, 1998.

LI, Sihan *et al.* Demystifying ResNet. [s. l.], 2016. Disponível em: <https://arxiv.org/abs/1611.01186v2>. Acesso em: 29 nov. 2021.

LINDSAY, Grace W. Convolutional neural networks as a model of the visual system: Past, present, and future. **Journal of cognitive neuroscience**, [s. l.], v. 33, n. 10, p. 2017–2031, 2021.

LOPEZ PINAYA, Walter Hugo *et al.* Chapter 10 - Convolutional neural networks. In: MECHELLI, Andrea; VIEIRA, Sandra B T - Machine Learning (org.). [S. l.]: Academic Press, 2020. p. 173–191. Disponível em: <https://doi.org/https://doi.org/10.1016/B978-0-12-815739-8.00010-9>

LORENZ, Camila; FERRAUDO, Antonio Sergio; SUESDEK, Lincoln. Artificial Neural Network applied as a methodology of mosquito species identification. **Acta Tropica**, [s. l.], v. 152, p. 165–169, 2015.

LUKMAN, Achmad; HARJOKO, Agus; YANG, Chuan-Kay. MFCC Feature Classification from Culex and Aedes Aegypti Mosquitoes Noise Using Support Vector Machine. [s. l.], MATPLOTLIB. [S. l.], [s. d.]. Disponível em: <https://matplotlib.org/>. Acesso em: 3 jan. 2022.

MCCULLOCH, Warren S; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, [s. l.], v. 5, n. 4, p. 115–133, 1943. Disponível em: <https://doi.org/10.1007/BF02478259>

MEDLOCK, Jolyon *et al.* Field sampling methods for mosquitoes, sandflies, biting midges and ticks: VectorNet project 2014-2018. **EFSA Supporting Publications**, [s. l.], v. 15, n. 6, p. 1435E, 2018.

MINAKSHI, Mona *et al.* Automating the surveillance of mosquito vectors from trapped specimens using computer vision techniques. In: , 2020. **Proceedings of the 3rd ACM SIGCAS Conference on Computing and Sustainable Societies**. [S. l.: s. n.], 2020. p. 105–115.

MINAKSHI, Mona; BHARTI, Pratoool; CHELLAPPAN, Sriram. Leveraging smart-phone cameras and image processing techniques to classify mosquito species. In: , 2018. **Proceedings of the 15th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services**. [S. l.: s. n.], 2018. p. 77–86.

MITCHELL, Tom. Machine learning. [s. l.], 1997.

MOLLALO, Abolfazl *et al.* Machine learning approaches in GIS-based ecological modeling of the sand fly *Phlebotomus papatasi*, a vector of zoonotic cutaneous leishmaniasis in Golestan province, Iran. **Acta tropica**, [s. l.], v. 188, p. 187–194, 2018.

MOTTA, Daniel *et al.* Optimization of convolutional neural network hyperparameters for automatic classification of adult mosquitoes. **Plos one**, [s. l.], v. 15, n. 7, p. e0234959, 2020.

MUKUNDARAJAN, Haripriya *et al.* Using mobile phones as acoustic sensors for high-throughput mosquito surveillance. **Elife**, [s. l.], v. 6, p. e27854, 2017.

NUMPY. [S. l.], [s. d.]. Disponível em: <https://numpy.org/>. Acesso em: 3 jan. 2022.

O'MAHONY, Niall *et al.* Deep learning vs. traditional computer vision. In: , 2019. **Science and Information Conference**. [S. l.]: Springer, 2019. p. 128–144.

OKAYASU, Kazushige *et al.* Vision-based classification of mosquito species: Comparison of conventional and deep learning methods. **Applied Sciences**, [s. l.], v. 9, n. 18, p. 3935, 2019.

ORGANIZATION, World Health; UNICEF. Global vector control response 2017-2030. [s. l.], 2017.

OUYANG, Tai-Hsien *et al.* Mosquito vector monitoring system based on optical wingbeat classification. **Computers and Electronics in Agriculture**, [s. l.], v. 118, p. 47–55, 2015.

PARK, Junyoung *et al.* Classification and morphological analysis of vector mosquitoes using deep convolutional neural networks. **Scientific reports**, [s. l.], v. 10, n. 1, p. 1–12, 2020.

PCDAS. **APRENDIZAGEM COLABORATIVA Google Colab**. [S. l.], [s. d.]. Disponível em: <https://pcdas.icict.fiocruz.br/rede-de-parcerias/google-colab/>. Acesso em: 30 dez. 2021.

PEREIRA-DOS-SANTOS, Taissa *et al.* **A Systematic Review: Is Aedes albopictus an Efficient Bridge Vector for Zoonotic Arboviruses?**. [S. l.: s. n.], 2020. Disponível em: <https://doi.org/10.3390/pathogens9040266>

PICEK, Stjepan *et al.* The curse of class imbalance and conflicting metrics with machine learning for side-channel evaluations. **IACR Transactions on Cryptographic Hardware and Embedded Systems**, [s. l.], v. 2019, n. 1, p. 1–29, 2019.

PIERSON, Theodore C; DIAMOND, Michael S. The emergence of Zika virus and its new clinical syndromes. **Nature**, [s. l.], v. 560, n. 7720, p. 573–581, 2018.

RAI, Priyanka *et al.* Insecticide resistance mapping in the vector of lymphatic filariasis, *Culex quinquefasciatus* Say from northern region of West Bengal, India. **Plos one**, [s. l.], v. 14, n. 5, p. e0217706, 2019.

RAMALHO, Ângela Maria Cavalcanti; MARQUES, Francisca Luseni Machado. Classificação da pesquisa científica. **Paraíba: UFRN/UEPB. Apostila**, [s. l.], 2009.

REZENDE, Edmar *et al.* Malicious software classification using VGG16 deep neural network's bottleneck features. *In: INFORMATION TECHNOLOGY-NEW GENERATIONS*. [S. l.]: Springer, 2018. p. 51–59.

REZENDE, Rubens Barbosa. Epidemiological analysis of emerging and re-emerging arbovirus infections in Brazil between the years 2019 and 2020. **Research, Society and Development**, [s. l.], v. 10, n. 2 SE-, p. e33010212611, 2021. Disponível em: <https://doi.org/10.33448/rsd-v10i2.12611>

RODRIGUES, Claudio Manuel *et al.* A saúde não é assim tão única: ressignificando discursos sobre (re) emergências de zoonoses. [s. l.], 2021.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, [s. l.], v. 65, n. 6, p. 386, 1958.

RUSTAM, Furqan *et al.* Vector mosquito image classification using novel RIFS feature selection and machine learning models for disease epidemiology. **Saudi Journal of Biological Sciences**, [s. l.], 2021.

SAFETY ASSESSMENT OF TRANSGENIC ORGANISMS IN THE ENVIRONMENT, VOLUME 8. [S. l.]: OECD, 2018. (Harmonisation of Regulatory Oversight in Biotechnology). Disponível em: <https://doi.org/10.1787/9789264302235-en>. Acesso em: 27 nov. 2021.

SAJID, Muhammad *et al.* Deep Learning in Age-invariant Face Recognition: A Comparative Study. **The Computer Journal**, [s. l.], 2020. Disponível em: <https://doi.org/10.1093/comjnl/bxaa134>

SALLES, Tiago Souza *et al.* History, epidemiology and diagnostics of dengue in the American and Brazilian contexts: a review. **Parasites & vectors**, [s. l.], v. 11, n. 1, p. 1–12, 2018.

SCIKIT-IMAGE. **Gamma and log contrast adjustment**. [S. l.], [s. d.]. Disponível em:

https://scikit-image.org/docs/dev/auto_examples/color_exposure/plot_log_gamma.html#sphx-gl-r-auto-examples-color-exposure-plot-log-gamma-py. Acesso em: 9 dez. 2021 a.

SCIKIT-IMAGE. **Unsharp masking**. [S. l.], [s. d.]. Disponível em: https://scikit-image.org/docs/dev/auto_examples/filters/plot_unsharp_mask.html#sphx-gl-r-auto-examples-filters-plot-unsharp-mask-py. Acesso em: 9 dez. 2021 b.

SCIKIT-LEARN. [S. l.], [s. d.]. Disponível em: <https://scikit-learn.org/stable/>. Acesso em: 3 jan. 2022.

SCIKITLEARN. **Sklearn.utils.class_weight.compute_class_weight**. [S. l.], [s. d.]. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html. Acesso em: 4 dez. 2022.

SHARMA, Neha; JAIN, Vibhor; MISHRA, Anju. An analysis of convolutional neural networks for image classification. **Procedia computer science**, [s. l.], v. 132, p. 377–384, 2018.

SHOBHA, Gangadhar; RANGASWAMY, Shanta. Machine learning. In: **HANDBOOK OF STATISTICS**. [S. l.]: Elsevier, 2018. v. 38, p. 197–228.

SHORTEN, Connor; KHOSHGOFTAAR, Taghi M. A survey on image data augmentation for deep learning. **Journal of Big Data**, [s. l.], v. 6, n. 1, p. 1–48, 2019.

SILVA, Nelly M; SANTOS, Nuno C; MARTINS, Ivo C. Dengue and Zika viruses: Epidemiological history, potential therapies, and promising vaccines. **Tropical Medicine and Infectious Disease**, [s. l.], v. 5, n. 4, p. 150, 2020.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, [s. l.], 2014.

SONG, Byung-Hak *et al.* Zika virus: History, epidemiology, transmission, and clinical presentation. **Journal of neuroimmunology**, [s. l.], v. 308, p. 50–64, 2017.

SOUZA, Vinicius M A. Identifying Aedes aegypti mosquitoes by sensors and one-class classifiers. In: , 2016. **Iberoamerican Congress on Pattern Recognition**. [S. l.]: Springer, 2016. p. 10–18.

SUMRUAYPHOL, Suchada *et al.* DNA barcoding and wing morphometrics to distinguish three Aedes vectors in Thailand. **Acta tropica**, [s. l.], v. 159, p. 1–10, 2016.

TAN, Mingxing; LE, Quoc. Efficientnet: Rethinking model scaling for convolutional neural networks. In: , 2019. **International Conference on Machine Learning**. [S. l.]: PMLR, 2019. p. 6105–6114.

TENSORFLOW. [S. l.], [s. d.]. Disponível em: <https://www.tensorflow.org/?hl=pt-br>. Acesso em: 3 jan. 2022.

VALLE, Denise *et al.* **Aedes de A a Z**. [S. l.]: SciELO-Editora FIOCRUZ, 2021.

VASCONCELOS, Dinarte *et al.* LOCOMOBIS: a low-cost acoustic-based sensing system to monitor and classify mosquitoes. *In: , 2019. 2019 16th IEEE Annual Consumer Communications & Networking Conference (CCNC).* [S. l.]: IEEE, 2019. p. 1–6.

VIRGINIO, Flávia; LORENZ, Camila; BREVIGLIERI, Enrico. **LIVRO: O FANTÁSTICO MUNDO DOS MOSQUITOS.** [S. l.: s. n.], 2018. Disponível em: <https://doi.org/10.13140/RG.2.2.29630.61766>

VYAS-PATEL, Nayna *et al.* Insect Wing Classification of Mosquitoes and Bees Using CO1 Image Recognition. **bioRxiv**, [s. l.], p. 34819, 2015.

WILDER-SMITH, Annelies *et al.* Epidemic arboviral diseases: priorities for research and public health. **The Lancet infectious diseases**, [s. l.], v. 17, n. 3, p. e101–e106, 2017.

WORLD HEALTH ORGANIZATION. **Chikungunya.** [S. l.], 2020. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/chikungunya>. Acesso em: 8 set. 2021.

WORLD HEALTH ORGANIZATION. **Dengue and severe dengue.** [S. l.], 2021. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/dengue-and-severe-dengue>. Acesso em: 8 set. 2021.

WORLD HEALTH ORGANIZATION. **Yellow fever.** [S. l.], 2019. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/yellow-fever>. Acesso em: 8 set. 2021.

WU, Pa *et al.* A Gut Commensal Bacterium Promotes Mosquito Permissiveness to Arboviruses. **Cell Host & Microbe**, [s. l.], v. 25, n. 1, p. 101-112.e5, 2019. Disponível em: <https://doi.org/https://doi.org/10.1016/j.chom.2018.11.004>