

Universidade Federal do Pará  
Instituto de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

# **Identificação de Larvas de Mosquitos do Gênero Aedes Utilizando Redes Neurais Convolucionais**

Romário da Costa Silva

DM 31/2023

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém - Pará - Brasil  
2023

Universidade Federal do Pará  
Instituto de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

Romário da Costa Silva

## **Identificação de Larvas de Mosquitos do Gênero Aedes Utilizando Redes Neurais Convolucionais**

Dissertação de Mestrado submetida à avaliação da Banca Examinadora aprovada pelo colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Pará e julgada adequada para a obtenção do Grau de Mestre em Engenharia Elétrica na área de computação aplicada.

DM 31/2023

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém - Pará - Brasil  
2023

---

S586i Silva, Romário da Costa, 1994-

Identificação de larvas de mosquito do gênero aedes utilizando redes neurais convolucionais / Romário da Costa Silva.-2023.

Orientador: Carlos Renato Lisboa Francês

Coorientador: José Jailton Henrique Ferreira Júnior

Dissertação (Mestrado) – Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-graduação em Engenharia Elétrica, Belém, 2023.

1. Redes neurais (computação). 2. Arboviroses - prevenção. 3. Arboviroses - processamento de dados. I. Título.

CDD 23. ed. 005.74

---

Elaborado por Lucicléa Silva de Oliveira CRB/2-648

UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

## **Identificação de Larvas de Mosquitos do Gênero Aedes Utilizando Redes Neurais Convolucionais**

Autor: Romário da Costa Silva

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 19/09/2023

**Banca Examinadora:**

---

**Carlos Renato Lisboa Francês**  
Orientador

---

**José Jailton Henrique Ferreira Junior**  
Co-Orientador

---

**Prof.<sup>a</sup> Dra. Jasmine Priscyla Leite de Araújo**  
Membro Interno - PPGEE UFPA

---

**Prof. Dr. Hugo Pereira Kuribayashi**  
Membro Externo - UNIFESSPA

**Visto:**

---

**Prof. Dr. Diego Lisboa Cardoso**  
Coordenador do PPGEE/ITEC/UFPA

*Dedico este trabalho aos meus avós, Maria Costa, Clarisse Silva, Albertino Costa e Raimundo Silva (in memoriam).*

# Agradecimentos

Ao meu orientador, Professor Renato Francês sou imensamente grato pelas orientações, confiança e ideias discutidas durante o desenvolvimento deste trabalho. Sua dedicação e orientação não apenas me ajudaram a conquistar meu sonho, mas também enriqueceram minha jornada acadêmica e pessoal.

Ao meu coorientador, Professor José Jailton Junior, pelas contribuições e inestimável apoio durante a minha carreira acadêmica desde a graduação.

À professora Jasmine Araújo, pelas valiosas orientações, e ao Prof Hugo Kuribayashi por aceitarem participar da avaliação deste trabalho.

Aos colegas do Laboratório de Planejamento de Redes de Alto Desempenho – LPRAD, que de alguma maneira contribuíram para este trabalho, em especial ao Carlos Teixeira pelas significativas contribuições.

Aos meus grandes amigos Maria Vitória, José Ítalo, Luciano Teran, Jailson Cavalcante e Juan Vidal, gostaria de expressar minha profunda gratidão pelo apoio constante, cumplicidade e companheirismo em todos os momentos.

Aos meus amigos Jhonatan Oliveira, Alessandra Caroline, Rafaela Benjamin, Adrielle Veras e Beatriz Castro, por acreditarem constantemente em mim, especialmente nos momentos em que tive dúvidas.

Aos meus pais, José Ribamar e Maria Auxiliadora, cujas orientações e incentivos moldaram meu caminho. Suas palavras e sacrifícios são as raízes do meu sucesso.

Às minhas queridas irmãs, Rosiane Monteiro e Rosivânia Silva, por sempre torcerem e acompanharem todas as etapas de minha formação.

Aos meus cunhados, Reinaldo Ramos e Wallace Darlan, pelas palavras de incentivo e encorajamento.

Aos meus adoráveis sobrinhos, Raissa, Mateus, Samuel e Lucas. Vocês trouxeram alegria e inspiração. Espero que este trabalho os incentive a perseguir seus próprios sonhos.

À CAPES pelo valioso apoio concedido à minha pesquisa. Seu comprometimento em fomentar a pesquisa e a educação foi fundamental para o meu desenvolvimento acadêmico e profissional.

A todos que contribuíram, direta ou indiretamente, para o desenvolvimento deste trabalho.

*“Quando não podemos mais mudar a situação,  
nós nos desafiamos a mudar nós mesmos.”*

**Viktor Frankl**

# Resumo

As arboviroses transmitidas pelos mosquitos do gênero *Aedes* constituem uma séria ameaça à saúde pública. A detecção e o controle desses vetores são fundamentais para prevenir surtos de doenças, incluindo Dengue, Chikungunya, Zika e Febre Amarela. As técnicas de visão computacional e aprendizagem profunda tem sido cada vez mais utilizadas no controle epidemiológico, principalmente, no que tange à classificação e detecção destes mosquitos. Nesse sentido, propõe-se três modelos voltados para classificação, detecção e segmentação de larvas dos mosquitos baseado na utilização de redes neurais convolucionais (CNN) e algoritmos de detecção de objetos (YOLO). Para tanto, foi criado um conjunto de dados (dataset) próprio para treinamento. O dataset é composto por imagens de larvas, sendo categorizadas entre as classes *Aedes* e Não *Aedes*. Os resultados obtidos indicam que os modelos propostos se apresentam como estratégias promissoras e alcançaram valores de acurácia de 86,71%, mAP (*Mean Average Precision*) de 88,3% e 95,7% para as tarefas de classificação, detecção e segmentação, respectivamente.

**Palavras-chaves:** Visão computacional. Aprendizagem Profunda. Arboviroses. Controle Vetorial.

# Abstract

Arboviruses transmitted by mosquitoes of the *Aedes* genus constitute a threat to public health. Detection and control of these vectors are critical to preventing disease outbreaks including Dengue, Chikungunya, Zika and Yellow Fever. Computer vision and deep learning techniques have been increasingly used in epidemiological control, mainly with regard to the classification and detection of these mosquitoes. In this sense, three models are proposed for classification, detection and segmentation of mosquito larvae based on the use of convolutional neural networks (CNN) and object detection algorithms (YOLO). For this purpose, a dataset was created for training purposes. The dataset is composed of images of larvae, being categorized between *Aedes* and Non-*Aedes* classes. The results show that the proposed models are promising strategies and achieved accuracy values of 86.71%, mAP (Mean Average Precision) of 88.3% and 95.7% for the tasks of classification, detection and segmentation, respectively.

**Keywords:** Computer vision. Deep Learning. Arboviruses. Vector Control.

# Lista de Figuras

Figura 1 – Ciclo de vida do mosquito Aedes . . . . .	7
Figura 2 – Relação entre os conceitos de Inteligência Artificial, Aprendizado de Máquina e Aprendizagem Profunda . . . . .	9
Figura 3 – Estrutura minimalista de sistemas de classificação baseados em aprendizado de máquina e aprendizagem profunda . . . . .	10
Figura 4 – Diferenças entre classificação de imagens e detecção de objetos . . . . .	12
Figura 5 – Exemplo de aplicação para as tarefas de detecção e segmentação de objetos . . . . .	13
Figura 6 – Estrutura de uma Rede Neural Simples e Rede Neural de Aprendizado Profundo . . . . .	14
Figura 7 – Representação da arquitetura e processos de uma CNN . . . . .	14
Figura 8 – Exemplo de aplicação de uma camada de convolução . . . . .	15
Figura 9 – Exemplo de aplicação de uma camada <i>Max Pooling</i> . . . . .	16
Figura 10 – Ilustração da arquitetura de uma CNN com camadas convolucionais, de pooling, totalmente conectada e de saída . . . . .	17
Figura 11 – Arquitetura da CNN Inception . . . . .	18
Figura 12 – Arquitetura da rede VGG 19 . . . . .	19
Figura 13 – Arquitetura da CNN ResNet-50 . . . . .	20
Figura 14 – Mapa de saída de um sistema detector com caixas delimitadoras . . . . .	21
Figura 15 – Detecção com o algoritmo YOLO . . . . .	22
Figura 16 – Comparação entre os modelos YOLO mais recentes . . . . .	24
Figura 17 – Desempenho da redes com transferência de aprendizado . . . . .	25
Figura 18 – Rede bibliométrica do levantamento de literatura . . . . .	30
Figura 19 – Metodologia final a ser implementada no processo de monitoramento e detecção de larvas de mosquitos do gênero Aedes. . . . .	34
Figura 20 – Imagens presentes no dataset. . . . .	35
Figura 21 – Imagens rotuladas após o pré-processamento . . . . .	36
Figura 22 – Resultados obtidos para as CNNs . . . . .	40
Figura 23 – Comparação da Acurácia e Loss obtidos para os classificadores propostos . . . . .	41
Figura 24 – mAP e MSE obtidos para o detector YOLO . . . . .	42
Figura 25 – Classificações realizadas pelo detector YOLO . . . . .	43
Figura 26 – mAP e MSE obtidos para o detector YOLO com segmentação . . . . .	44
Figura 27 – Classificações realizadas pelo modelo com segmentação . . . . .	45
Figura 28 – Classificações de múltiplas larvas pelo modelo com segmentação . . . . .	45

# Lista de Tabelas

Tabela 1 – Matriz de Confusão para duas classes . . . . .	26
Tabela 2 – Resumo dos Trabalhos Correlatos . . . . .	32
Tabela 3 – Parâmetros de treinamento das CNNs . . . . .	37
Tabela 4 – Principais parâmetros de treinamento do YOLO voltado para detecção e segmentação . . . . .	37
Tabela 5 – Métricas das arquiteturas de CNN propostas . . . . .	41
Tabela 6 – Resultados obtidos para o detector YOLO . . . . .	42
Tabela 7 – Resultados obtidos para o detector YOLO com segmentação . . . . .	44
Tabela 8 – Métricas de avaliação obtidas em cada modelo . . . . .	46

# Lista de abreviaturas e siglas

<b>CAPES</b>	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
<b>CNN</b>	Convolutional Neural Network
<b>COCO</b>	Common Objects in Context
<b>GPU</b>	Unidade de Processamento Gráfico
<b>ILSVRC</b>	Large Scale Visual Recognition Challenge
<b>MAP</b>	Mean Average Precision
<b>MSE</b>	Mean Squared Error
<b>NDVI</b>	Índice de Vegetação de Diferença Normalizada
<b>ReLU</b>	Rectified Linear Activation
<b>ResNet</b>	Redes Residuais
<b>ROI</b>	Região de Interesse
<b>SGD</b>	Stochastic Gradient Descent
<b>VANT</b>	Veículo Aéreo Não Tripulado
<b>VGG</b>	Visual Geometry Group
<b>YOLO</b>	You Only Look Once

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>1.1</b>	<b>Contextualização</b>	<b>1</b>
<b>1.2</b>	<b>Motivação e Desafios</b>	<b>2</b>
<b>1.3</b>	<b>Objetivos</b>	<b>2</b>
<b>1.4</b>	<b>Organização da Trabalho</b>	<b>3</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>4</b>
<b>2.1</b>	<b>Considerações Iniciais</b>	<b>4</b>
<b>2.2</b>	<b>Arboviroses</b>	<b>4</b>
2.2.1	Dengue	4
2.2.2	Zika Vírus	5
2.2.3	Chikungunya	6
2.2.4	Mosquito Aedes	6
2.2.4.1	Características	6
2.2.4.2	Ciclo de Vida	7
2.2.5	Controle Vetorial	8
<b>2.3</b>	<b>Aprendizagem Profunda</b>	<b>9</b>
2.3.1	Visão Computacional	10
2.3.1.1	Classificação	11
2.3.1.2	Detecção	11
2.3.1.3	Segmentação	12
2.3.2	Redes Neurais Convolucionais	13
2.3.3	Arquitetura de uma Rede Neural Convolucional	14
2.3.3.1	Camada Convolucional	15
2.3.3.2	Camada de Pooling	15
2.3.3.3	Camada Totalmente Conectada	16
2.3.4	Exemplos de CNNs	17
2.3.4.1	Inception	17
2.3.4.2	VGG	18
2.3.4.3	ResNet	19
<b>2.4</b>	<b>Algoritmos de Detecção de Objetos</b>	<b>20</b>
2.4.1	YOLO	22
<b>2.5</b>	<b>Transferência de Aprendizado</b>	<b>24</b>
<b>2.6</b>	<b>Métricas de Avaliação</b>	<b>25</b>
<b>2.7</b>	<b>Considerações Finais</b>	<b>28</b>

<b>3</b>	<b>TRABALHOS CORRELATOS . . . . .</b>	<b>29</b>
<b>3.1</b>	<b>Considerações Iniciais . . . . .</b>	<b>29</b>
<b>3.2</b>	<b>Levantamento do Estado da Arte . . . . .</b>	<b>29</b>
<b>3.3</b>	<b>Considerações Finais . . . . .</b>	<b>33</b>
<b>4</b>	<b>MATERIAIS E MÉTODOS . . . . .</b>	<b>34</b>
<b>4.1</b>	<b>Considerações Iniciais . . . . .</b>	<b>34</b>
<b>4.2</b>	<b>Conjunto de dados . . . . .</b>	<b>34</b>
<b>4.3</b>	<b>Anotação e Pré-processamento das imagens . . . . .</b>	<b>35</b>
<b>4.4</b>	<b>Desenvolvimento dos modelos . . . . .</b>	<b>36</b>
<b>4.4.1</b>	<b>Classificadores com CNNs . . . . .</b>	<b>36</b>
<b>4.4.2</b>	<b>Detectores com YOLO . . . . .</b>	<b>37</b>
<b>4.5</b>	<b>Treinamento dos modelos . . . . .</b>	<b>37</b>
<b>4.6</b>	<b>Avaliação de Performance . . . . .</b>	<b>38</b>
<b>4.7</b>	<b>Considerações Finais . . . . .</b>	<b>38</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÃO . . . . .</b>	<b>39</b>
<b>5.1</b>	<b>Considerações Iniciais . . . . .</b>	<b>39</b>
<b>5.2</b>	<b>Classificação . . . . .</b>	<b>39</b>
<b>5.3</b>	<b>Detecção . . . . .</b>	<b>41</b>
<b>5.4</b>	<b>Segmentação . . . . .</b>	<b>43</b>
<b>5.5</b>	<b>Comparativo . . . . .</b>	<b>46</b>
<b>5.6</b>	<b>Considerações Finais . . . . .</b>	<b>46</b>
<b>6</b>	<b>CONCLUSÕES . . . . .</b>	<b>48</b>
<b>6.1</b>	<b>Trabalhos Futuros . . . . .</b>	<b>48</b>
<b>6.2</b>	<b>Trabalhos Publicados . . . . .</b>	<b>49</b>
<b>6.3</b>	<b>Dificuldades Encontradas . . . . .</b>	<b>49</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>51</b>

# 1 Introdução

Este capítulo apresenta as considerações iniciais sobre o desenvolvimento do trabalho, incluindo a contextualização do tema, descrição do problema, objetivos geral, específicos e, por fim, aborda a organização da dissertação.

## 1.1 Contextualização

Os mosquitos do gênero *Aedes* são reconhecidos por sua elevada capacidade de transmitir doenças graves, como dengue, zika, chikungunya e febre amarela, as quais ocasionam enormes impactos na saúde pública em todo o mundo (MOREIRA; FEITOSA; ABREU, 2022). A habilidade de atuar como vetores eficientes é devida à sua preferência por habitats urbanos e sua habilidade de se reproduzir em pequenos criadouros de água parada (CASTRO et al., 2022). Além disso, esses mosquitos têm demonstrado uma notável capacidade de adaptação a diferentes ambientes e condições climáticas, permitindo uma proliferação rápida e um desafio persistente para os esforços de controle (VALLE et al., 2021).

Enfrentar e controlar os mosquitos *Aedes* representa um desafio complexo. As estratégias tradicionais de controle frequentemente envolvem monitoramento manual e *in loco*, o que pode ser trabalhoso, demorado e nem sempre eficaz em áreas extensas e densamente povoadas (WERMELINGER, 2019). As ações de controle, como a eliminação de criadouros e a aplicação de pesticidas, muitas vezes requerem recursos significativos e enfrentam dificuldades em manter uma cobertura abrangente e consistente. Outrossim, medidas de controle aplicadas de forma não planejada podem levar ao desenvolvimento de resistência dos mosquitos aos pesticidas, tornando ainda mais desafiador conter a propagação das doenças transmitidas por estes (ZULFA et al., 2022).

No entanto, avanços na visão computacional estão oferecendo novas alternativas na luta contra os mosquitos *Aedes*. O emprego de técnicas de processamento de imagens e algoritmos de detecção de objetos, como os baseados em redes neurais convolucionais, permite a automação do monitoramento de mosquitos e criadouros (FERNANDES; CORDEIRO; RECAMONDE-MENDOZA, 2021). O uso dessas novas técnicas de visão computacional pode trazer avanços significativos na prevenção e controle das doenças transmitidas pelos mosquitos *Aedes*, oferecendo uma abordagem mais ágil e tecnologicamente avançada para enfrentar esse desafio global de saúde pública .

## 1.2 Motivação e Desafios

Entre as diversas dificuldades para o efetivo controle vetorial, destaca-se a necessidade de um monitoramento constante e em grande escala para conter a reprodução do mosquito. O ciclo de vida do *Aedes* é curto, o que exige uma vigilância rigorosa para detectar os locais onde os ovos são depositados e as larvas se desenvolvem. Além disso, muitas áreas urbanas têm acesso limitado, o que torna difícil o rastreamento minucioso dos criadouros em propriedades privadas (SCHABAT; BUSATO et al., 2023).

Diante desses obstáculos, uma abordagem que vem ganhando destaque é o foco no combate às larvas por meio de técnicas de visão computacional. Utilizando câmeras e algoritmos de análise de imagens, é possível identificar potenciais criadouros e quais tipos de larvas estão presentes nestes (BRUNO et al., 2023). Essa abordagem não apenas facilita a identificação rápida de áreas de risco, mas também permite uma alocação mais eficiente de recursos de controle. Ao atacar as larvas antes que se tornem mosquitos adultos, é possível interromper o ciclo de reprodução com mais eficácia, contribuindo para a redução da população de mosquitos transmissores e, conseqüentemente, das doenças por eles propagadas.

Em resumo, o monitoramento e controle desses mosquitos apresenta desafios multifacetados devido à adaptabilidade desses insetos, seus hábitos de reprodução e a resistência aos métodos convencionais. No entanto, a aplicação de técnicas avançadas de visão computacional para a detecção precoce de criadouros e larvas oferece uma perspectiva promissora para a contenção das doenças transmitidas.

## 1.3 Objetivos

### GERAL

O presente trabalho busca apresentar uma solução para classificar, detectar e segmentar larvas de mosquitos do gênero *Aedes* através da utilização de técnicas de aprendizagem profunda, baseadas em redes neurais convolucionais (CNN). Para tanto, foram empregadas CNNs e algoritmos de detecção e segmentação de imagens, aliados a técnica de transferência de aprendizado.

### ESPECÍFICOS:

- Realizar um levantamento sobre soluções voltadas para o controle vetorial de mosquitos transmissores de arbovirose;
- Identificar as principais lacunas presentes nas soluções levantadas;

- Criar um conjunto público de dados (dataset) com imagens de larvas de mosquitos do gênero *Aedes* e similares, incluindo imagens capturadas em condições variáveis, como fundo e tamanho das larvas;
- Desenvolver modelos para as tarefas de classificação, detecção e segmentação automática de larvas de mosquitos *Aedes*, utilizando tecnologias recentes na área de visão computacional;
- Realizar a execução de testes dos modelos para análise e validação dos resultados obtidos;
- Avaliar os modelos de classificação, detecção e segmentação de larvas do mosquito *Aedes* através das métricas de Acurácia, Precisão, Sensitividade, F-Score, *Mean Average Precision* - mAP e *Mean Squared Error* - MSE.

## 1.4 Organização da Trabalho

Este trabalho está estruturado da seguinte forma:

Capítulo 1: Apresenta uma breve introdução sobre o cenário de arboviroses transmitidas por mosquitos *Aedes*, justifica a proposta desta pesquisa e aponta os objetivos do trabalho;

Capítulo 2: Fundamenta uma breve revisão bibliográfica sobre os principais conceitos e técnicas utilizados para o desenvolvimento da pesquisa;

Capítulo 3: Aponta pesquisas correlatas que nortearam o desenvolvimento deste trabalho, destacando suas contribuições e limitações;

Capítulo 4: Detalha a metodologia aplicada e as etapas necessárias para atingir os objetivos almejados nesta dissertação;

Capítulo 5: Descreve os resultados obtidos para os modelos propostos;

Capítulo 6: Apresenta as considerações finais do trabalho, sugestões para pesquisas futuras, trabalhos publicados referente ao tema e desafios da pesquisa.

## 2 Fundamentação Teórica

### 2.1 Considerações Iniciais

Neste capítulo é apresentado um resumo sobre os conceitos que fundamentaram o desenvolvimento do trabalho. Estes conceitos são agrupados em dois grupos distintos: os relacionados a transmissão das arboviroses e os relacionados as técnicas de visão computacional. Adicionalmente, são apresentados conceitos referentes as métricas de avaliação utilizadas para validação das soluções propostas.

### 2.2 Arboviroses

No contexto global das doenças epidêmicas que têm moldado a história da saúde pública, é fundamental compreender a ameaça persistente representada por essas enfermidades. (MORAIS et al., 2020) apontam que doenças emergentes ou reemergentes apresentam amplo potencial de desencadear consequências devastadoras, destacando a importância de vigilância ativa e resposta eficazes para proteger as populações vulneráveis. A exemplo, as epidemias como a gripe espanhola de 1918 e, mais recentemente, a pandemia de COVID-19, foram responsáveis por enormes danos à sociedade (KUBO et al., 2020).

Dentre as várias categorias de doenças epidêmicas, as arboviroses emergem como um desafio particular devido à sua transmissão complexa por vetores artrópodes. Conforme delineado por (DIAS et al., 2020), os vírus transmitidos por mosquitos e carrapatos têm se espalhado amplamente, acarretando uma crescente carga de morbidade e mortalidade. A compreensão das interações entre vetores, hospedeiros e agentes patogênicos é essencial para conter a disseminação dessas doenças.

Entre as arboviroses mais conhecidas, destacam-se a dengue, cujos casos aumentaram significativamente nas últimas décadas, a febre Chikungunya, que causa sintomas incapacitantes nas vítimas, e o vírus Zika, que levou a preocupações globais devido a suas associações com malformações congênitas (VIEGAS; VENTURA; NUNES, 2022). Conforme observado por (SOUSA et al., 2023), essas arboviroses compartilham características epidemiológicas complexas e representam um desafio crescente para a saúde pública.

#### 2.2.1 Dengue

A dengue, uma das arboviroses mais significativas globalmente, representa uma ameaça constante à saúde pública e afeta entre 100 e 400 milhões de pessoas anualmente (CHEN; DIAMOND, 2020). Transmitida pelo mosquito *Aedes aegypti*, essa doença causa

um amplo espectro de sintomas, desde febre alta, dores musculares e articulares até formas mais graves que podem levar a complicações potencialmente fatais, como a dengue hemorrágica e a síndrome do choque da dengue. Sua disseminação é impulsionada por fatores como urbanização rápida, mobilidade humana e variações climáticas, aumentando a vulnerabilidade das populações em áreas endêmicas e não endêmicas.

Santos et al. (2020) ressalta que a dengue é causada por quatro sorotipos distintos do vírus, denominados DEN-1, DEN-2, DEN-3 e DEN-4. Além disso, a infecção por um sorotipo confere imunidade vitalícia, mas apenas imunidade temporária aos outros sorotipos. A exposição subsequente a um sorotipo diferente aumenta o risco de desenvolver formas mais graves da doença. De acordo com Silva et al. (2022), a complexidade dos sorotipos desafia a criação de uma vacina eficaz, já que é necessário alcançar proteção contra todos os tipos de vírus para garantir uma imunização abrangente e duradoura.

Além do sofrimento humano causado pela doença, a dengue sobrecarrega os sistemas de saúde pública, comprometendo os recursos médicos e financeiros (DOURADO; ARAÚJO; GODÓI, 2020). Estratégias de prevenção e controle, como a eliminação de criadouros de mosquitos, educação pública sobre medidas de proteção pessoal e o desenvolvimento de tecnologias inovadoras de controle de vetores, desempenham um papel fundamental na mitigação da propagação da doença. O engajamento de governos, comunidades e organizações de saúde é essencial para enfrentar eficazmente a dengue e reduzir seu impacto nas populações vulneráveis.

## 2.2.2 Zika Vírus

O Zika vírus emergiu como uma preocupação significativa de saúde pública devido à sua associação com complicações neurológicas graves, como a microcefalia em bebês nascidos de mães infectadas durante a gestação. Transmitido principalmente pelo mosquito *Aedes aegypti*, o vírus inicialmente causava sintomas leves semelhantes aos da gripe, mas sua rápida disseminação e as descobertas sobre suas consequências devastadoras tornaram-no objeto de intensa pesquisa e atenção (LÖWY, 2019).

O surto de Zika que ocorreu em várias partes do mundo reforçou a necessidade de uma vigilância rigorosa, medidas eficazes para controle de vetores e pesquisas contínuas para entender melhor o vírus e desenvolver estratégias para lidar com seus impactos. Além das complicações em bebês nascidos de mães infectadas, como a microcefalia, o vírus também foi associado a outras condições neurológicas, como a síndrome de Guillain-Barré (QUEIROZ, 2020).

### 2.2.3 Chikungunya

Chikungunya é uma arbovirose transmitida principalmente pelo mosquito *Aedes aegypti* e *Aedes albopictus*, que tem atraído crescente atenção devido à sua rápida disseminação e à intensidade dos sintomas associados à infecção. Originária da África, a doença se espalhou para diferentes partes do mundo, causando epidemias em áreas tropicais e subtropicais. Caracteriza-se por febre alta, dores articulares graves, inflamação das articulações e erupções cutâneas. Embora raramente seja fatal, a Chikungunya pode causar sintomas debilitantes que podem persistir por meses, impactando a qualidade de vida dos pacientes (KHONGWICHIT et al., 2021).

Constant et al. (2021) ressaltam que a importância de combater a Chikungunya reside na sua capacidade de causar surtos agudos e causar sofrimento a longo prazo para os indivíduos afetados. Além disso, a Chikungunya pode ter efeitos socioeconômicos adversos, afetando a produtividade e a capacidade de trabalho das pessoas afetadas, bem como a capacidade de cuidar de suas famílias. A colaboração entre governos, comunidades e organizações de saúde é essencial para enfrentar eficazmente essa doença emergente.

### 2.2.4 Mosquito Aedes

Pereira e Silva (2023) apontam que os mosquitos do gênero *Aedes*, principalmente o *Aedes aegypti* e o *Aedes albopictus*, desempenham um papel preponderante como os principais vetores de arboviroses, transmitindo patógenos virais de importância global. Esses vetores são responsáveis por disseminar as doenças citadas anteriormente: Dengue, Zika e Chikungunya. A capacidade desses mosquitos de se reproduzirem em ambientes urbanos, seu comportamento alimentar preferencial por humanos e sua ampla distribuição geográfica contribuem para sua eficácia na transmissão dessas doenças.

#### 2.2.4.1 Características

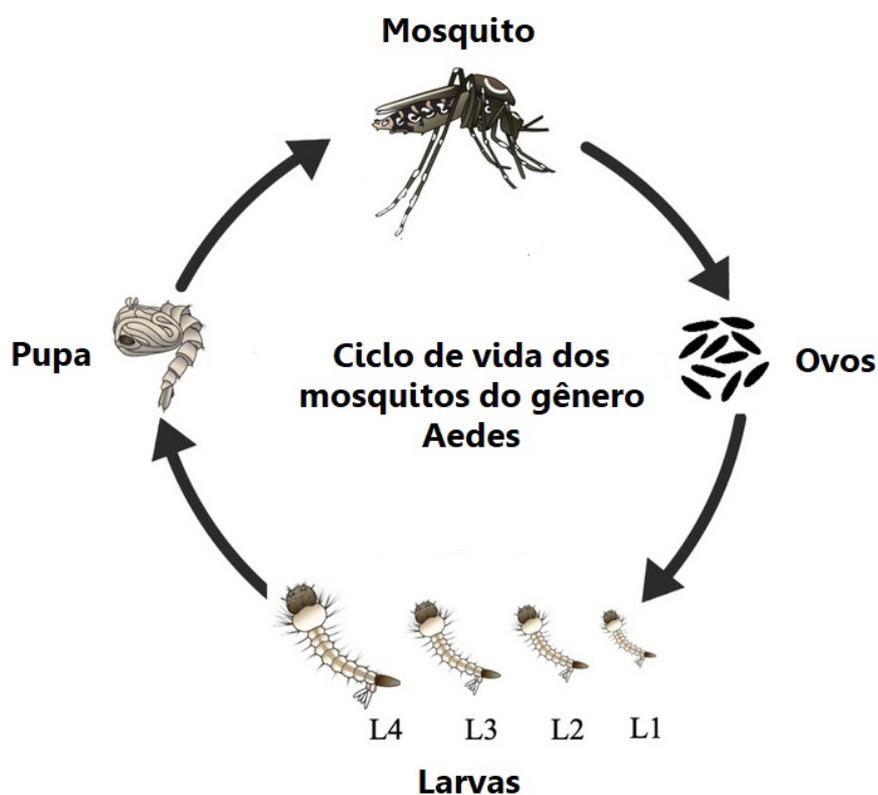
Esses mosquitos são principalmente diurnos, preferindo atividades durante o dia em comparação com outros mosquitos que são mais ativos ao entardecer ou à noite. Além disso, os *Aedes* são conhecidos por sua preferência por ambientes urbanos e periurbanos, onde encontram uma abundância de criadouros em pequenos recipientes de água parada, como vasos, pneus e recipientes plásticos (CEVIDANES et al., 2023).

Essa preferência por água parada é crucial para seu ciclo de vida, uma vez que as fêmeas depositam seus ovos nesses locais, impulsionando a reprodução. No entanto, essa propensão a usar criadouros urbanos também aumenta seu potencial como vetores de doenças, uma vez que muitas doenças, como arboviroses, podem se espalhar rapidamente em áreas densamente povoadas.

### 2.2.4.2 Ciclo de Vida

O ciclo de vida dos mosquitos do gênero *Aedes*, como o *Aedes aegypti* e o *Aedes albopictus*, é um processo composto por quatro estágios distintos, cada um com uma duração específica (AMINUDDIN et al., 2023). A Figura 1 apresenta o ciclo de vida dos mosquito, o qual inicia com os ovos, que são depositados pela fêmea em recipientes com água parada, como vasos, pneus e tambores. Esses ovos podem permanecer secos e viáveis por semanas a meses até que sejam submersos em água. A fase de ovo dura aproximadamente de 2 a 3 dias.

Figura 1 – Ciclo de vida do mosquito *Aedes*



Fonte: Adaptado de Hossain et al. (2022)

Quando os ovos são submersos em água, eclodem em larvas. As larvas são organismos aquáticos que se alimentam de detritos e microorganismos presentes na água. Elas passam por quatro ínstares, ou seja, quatro estágios de crescimento, ao longo de cerca de 5 a 7 dias. Após esses ínstares, as larvas entram na fase de pupa.

A fase de pupa é um estágio intermediário entre a larva e o mosquito adulto. As pupas são aquáticas e não se alimentam, mas realizam mudanças internas cruciais para a transformação em adultos. Esse estágio dura em média de 1 a 2 dias. Durante esse período, os órgãos internos do mosquito adulto se desenvolvem completamente.

Finalmente, após a fase de pupa, emerge o mosquito adulto. O mosquito adulto rompe o exoesqueleto da pupa, emerge da água e aguarda até que suas asas sequem e endureçam, o que leva cerca de algumas horas. Uma vez que as asas estejam prontas, o mosquito adulto é capaz de voar em busca de sangue para se alimentar, sendo que as fêmeas também buscam locais adequados para a postura dos ovos. O ciclo completo, desde o ovo até o mosquito adulto, pode variar de 8 a 10 dias em condições ideais. Esse ciclo rápido e eficiente contribui para a rápida proliferação desses vetores e a disseminação das arboviroses por eles transmitidas (MEENA, 2020).

### 2.2.5 Controle Vetorial

A prevenção de arboviroses é um desafio constante na saúde pública global. O foco primordial recai sobre o combate aos mosquitos vetores, especialmente do gênero *Aedes*, que são os principais responsáveis pela transmissão dessas doenças. A disseminação das arboviroses está intrinsecamente ligada à proliferação desses mosquitos, demandando esforços coordenados para limitar suas populações e controlar a transmissão (NEPOMUCENO; BACHUR, 2022).

As estratégias de controle usuais envolvem medidas direcionadas à redução dos mosquitos vetores, principalmente do *Aedes aegypti*. Essas táticas incluem a eliminação de criadouros em locais com água parada, como recipientes e pneus, onde os mosquitos depositam seus ovos (CAVALLI et al., 2019). No entanto, essas estratégias muitas vezes dependem da participação ativa e consciente da comunidade, uma vez que a eliminação de criadouros requer ações práticas de higiene e limpeza por parte dos indivíduos. Portanto, a eficácia dessas abordagens está intimamente ligada à adesão das pessoas às práticas de prevenção (DIAS et al., 2022).

De acordo com Valle et al. (2021), o combate às larvas de mosquitos é um aspecto crítico da prevenção de arboviroses. As larvas se desenvolvem em água parada e representam o estágio vulnerável do ciclo de vida dos mosquitos. Ao focar na eliminação de criadouros e na aplicação de larvicidas, é possível interromper o ciclo de reprodução e reduzir significativamente a população de mosquitos adultos. Essa abordagem direcionada ajuda a prevenir a disseminação de doenças transmitidas por mosquitos, impedindo a maturação das larvas em vetores adultos.

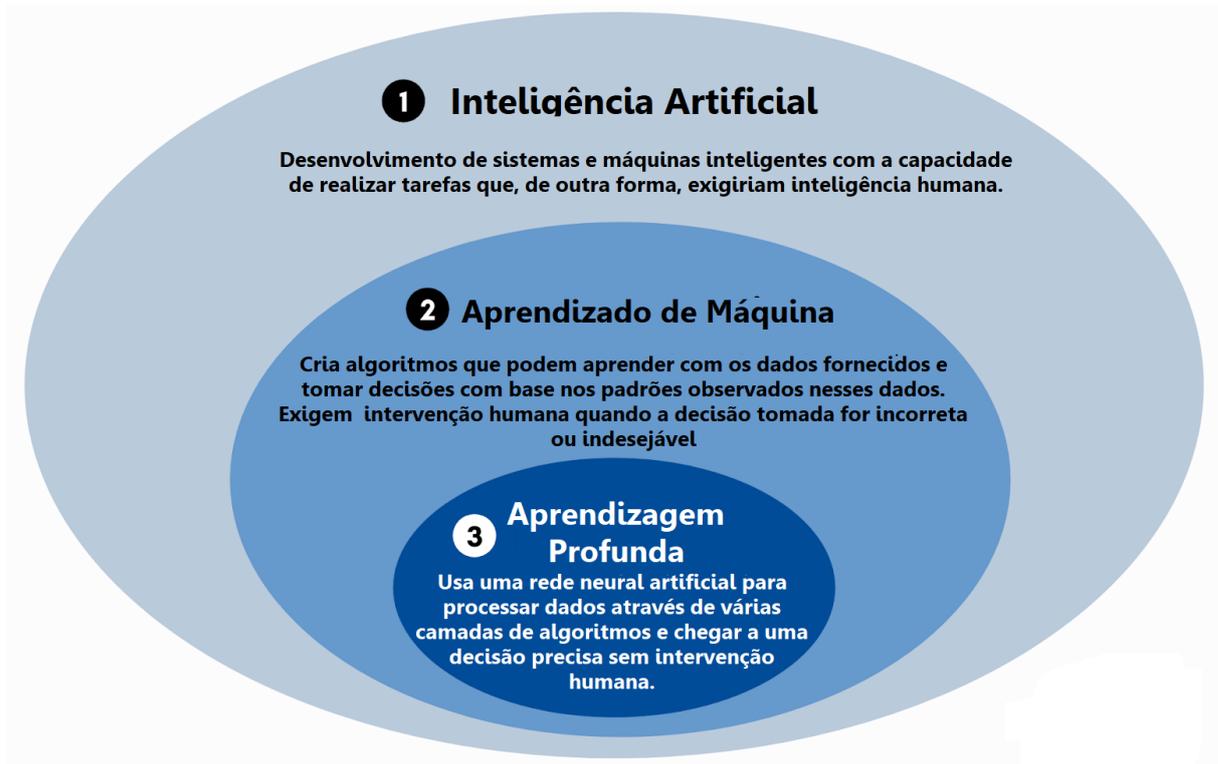
Nesse sentido, soluções inovadoras baseadas em técnicas de visão computacional têm mostrado potencial para fortalecer as estratégias de prevenção de arboviroses. Sistemas de monitoramento de vetores por meio de câmeras e algoritmos de processamento de imagem podem auxiliar na identificação de larvas e, conseqüentemente, mapear áreas de maior infestação, permitindo a implementação direcionada de medidas de controle (CARRASCO-ESCOBAR et al., 2019). Além disso, análise de imagens de satélite e dados geoespaciais pode oferecer *insights* valiosos sobre a distribuição e movimentação dos vetores. Essas

abordagens tecnológicas podem melhorar a eficácia das medidas de prevenção, fornecendo informações precisas para tomadas de decisão informadas e estratégias de controle mais eficientes.

## 2.3 Aprendizagem Profunda

A aprendizagem profunda é uma abordagem avançada de inteligência artificial que visa simular o processo de aprendizado humano em máquinas. Baseada em redes neurais artificiais de múltiplas camadas, essa técnica permite que as máquinas sejam treinadas para aprender representações complexas e abstratas dos dados, resultando na capacidade de reconhecer padrões, tomar decisões e realizar tarefas complexas. (SOCIETY, 2020) retrata de forma sucinta a correlação entre os conceitos de IA, aprendizado de máquina e aprendizagem profunda.

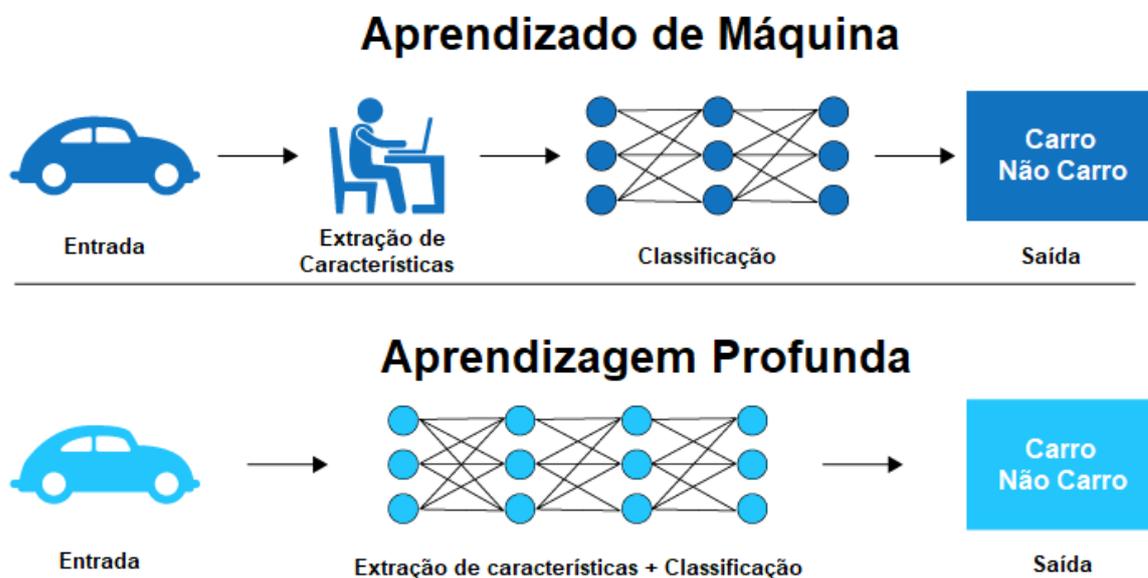
Figura 2 – Relação entre os conceitos de Inteligência Artificial, Aprendizado de Máquina e Aprendizagem Profunda



Fonte: Adaptado de Society (2020)

A aprendizagem profunda se destaca pela sua capacidade de extrair automaticamente características relevantes dos dados, eliminando a necessidade de programação manual intensiva e abrindo caminho para aplicações inovadoras em áreas como visão computacional, processamento de linguagem natural, jogos e medicina, por exemplo.

Figura 3 – Estrutura minimalista de sistemas de classificação baseados em aprendizado de máquina e aprendizagem profunda



Fonte: Adaptado de Society (2020)

Um dos pilares da aprendizagem profunda é o treinamento em grandes conjuntos de dados, permitindo que os algoritmos ajustem seus parâmetros para se adaptar às nuances e variações presentes nos dados. Através da técnica de retropropagação, as redes neurais são ajustadas iterativamente para minimizar a diferença entre as previsões do modelo e os valores reais dos dados (ZAVADZKI et al., 2020). À medida que a complexidade dos modelos de aprendizado profundo aumenta, também aumenta sua capacidade de capturar relações intrincadas e realizar tarefas sofisticadas, promovendo avanços significativos na tecnologia e impulsionando a pesquisa em inteligência artificial a novos patamares.

### 2.3.1 Visão Computacional

A visão computacional é um campo interdisciplinar da inteligência artificial que capacita os computadores a interpretar e analisarem informações visuais, como imagens e vídeos. Por meio do uso de algoritmos e técnicas avançadas, a visão computacional permite o desenvolvimento de soluções capazes de identificar objetos, reconhecer padrões, rastrear movimentos e até mesmo compreender o conteúdo visual em um nível semelhante ao humano (KUMAR et al., 2021).

Essa tecnologia tem uma ampla gama de aplicações em setores diversos, desde medicina e indústria automotiva até segurança e entretenimento, promovendo avanços significativos em áreas como reconhecimento facial (ROCHA et al., 2023), direção autônoma

(DYGALO; LYASHENKO; POTAPOV, 2019) e diagnóstico médico por imagem (SILVA; JUNIOR; FRANCES, 2023).

À medida que a visão computacional avança, seu impacto na sociedade e na indústria se torna cada vez mais evidente. As tarefas de classificação, detecção e segmentação de objetos desempenham um papel crucial em muitas aplicações que melhoram a eficiência e a precisão em diversas áreas (NUNES, 2023).

### **2.3.1.1 Classificação**

A classificação de imagens é uma tarefa na qual um algoritmo ou modelo de aprendizado de máquina é treinado para atribuir rótulos ou categorias específicas a imagens com base em seu conteúdo visual. Dessa forma, a partir de uma imagem de entrada, o sistema pode identificar automaticamente o que está representado nela (MARTÍNEZ, 2022).

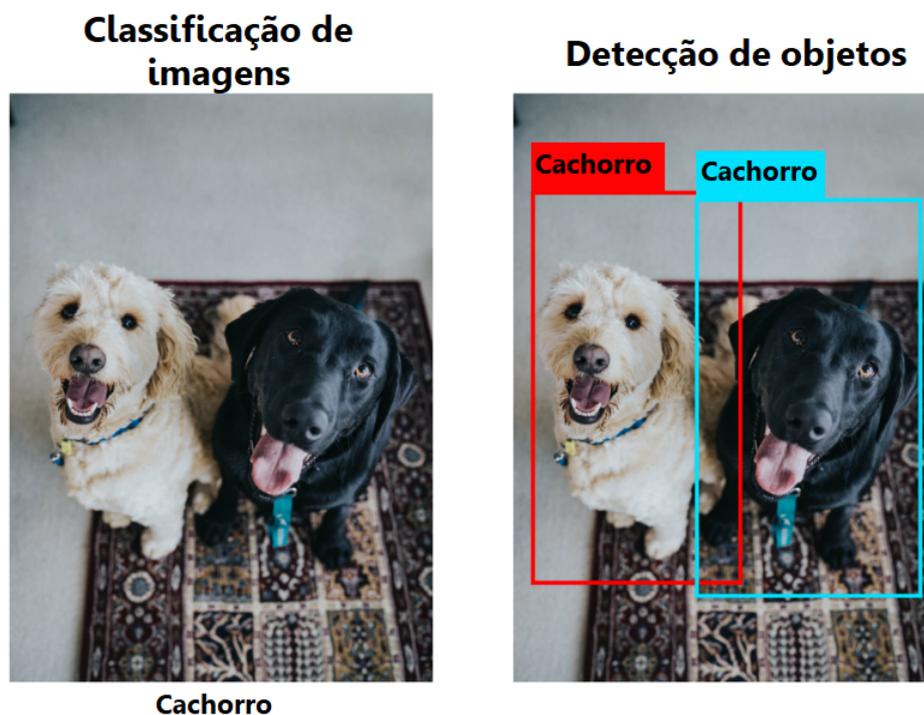
Para a classificação de imagens, os algoritmos geralmente se baseiam em redes neurais convolucionais (CNNs) projetadas para extrair automaticamente características relevantes das imagens em diferentes níveis de abstração. A quantidade crescente de dados de treinamento e o aprimoramento das arquiteturas de redes neurais têm impulsionado significativamente a precisão das tarefas de classificação de imagens nos últimos anos, tornando essa técnica uma ferramenta essencial em diversas aplicações (VAZ, 2023).

### **2.3.1.2 Detecção**

Segundo Olivatto (2021), a detecção de objetos envolve identificar a presença e localização de objetos específicos dentro de uma imagem ou vídeo. Esse processo é frequentemente realizado por meio da criação de caixas delimitadoras ao redor dos objetos detectados, destacando sua posição na cena visual.

Comparando a classificação e a detecção de objetos, a classificação é uma tarefa mais simples em que o objetivo é atribuir uma única categoria ou rótulo a uma imagem. Por exemplo, classificar uma imagem como "gato" ou "cachorro". Em contraste, a detecção de objetos vai além, identificando não apenas a categoria do objeto, mas também sua localização precisa, frequentemente representada por uma caixa delimitadora. A Figura 4 ilustra a diferença entre as tarefas de classificação e detecção.

Figura 4 – Diferenças entre classificação de imagens e detecção de objetos



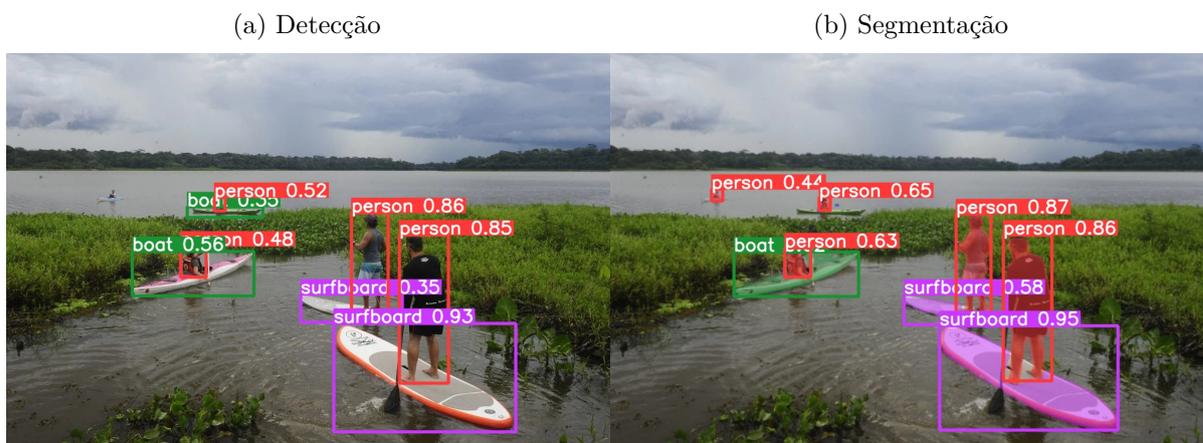
Fonte: Adaptado de Kanjee (2021)

A detecção é mais complexa, pois exige a capacidade de identificar e delimitar múltiplos objetos em uma única imagem. Essa distinção é fundamental em cenários onde é crucial não apenas saber o que está na imagem, mas também onde cada objeto se encontra.

### 2.3.1.3 Segmentação

A segmentação de imagens é uma tarefa avançada, a qual consiste na subdivisão de uma imagem em regiões ou segmentos com base em características visuais semelhantes, como cor, textura, intensidade e contornos. Diferentemente da detecção de objetos, a segmentação não apenas identifica a presença de objetos, mas também determina a forma e o contorno exato de cada objeto na imagem. Na Figura 5 é possível comparar os resultados entre as tarefas de detecção e segmentação.

Figura 5 – Exemplo de aplicação para as tarefas de detecção e segmentação de objetos



Fonte: Elaborado pelo autor

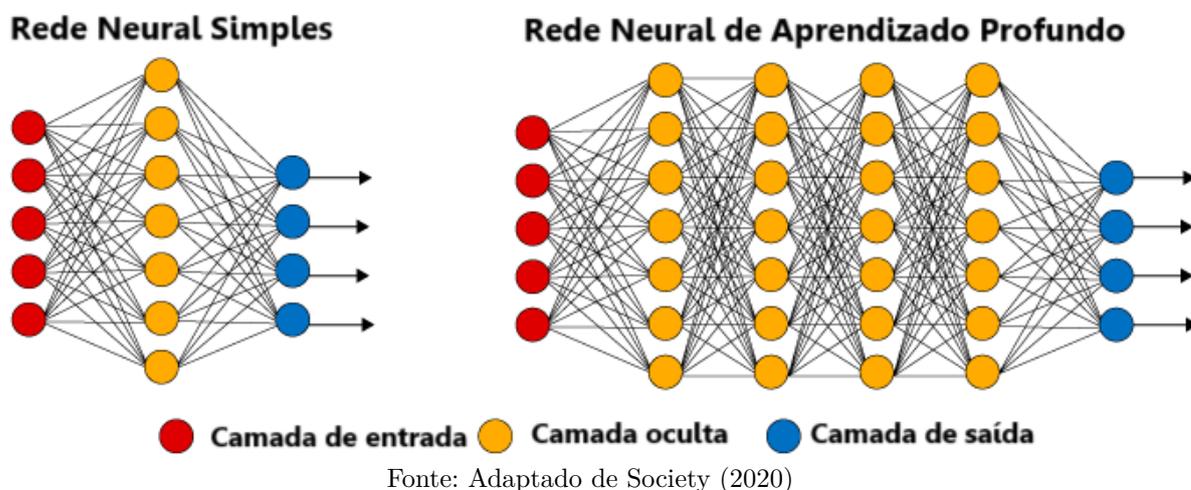
Nesse contexto, a segmentação de imagens desempenha um papel crucial em várias aplicações, desde a detecção de objetos em tempo real até o processamento de imagens médicas, contribuindo para avanços significativos em uma variedade de campos.

### 2.3.2 Redes Neurais Convolucionais

As Redes Neurais Convolucionais CNN são uma classe especializada de arquiteturas de aprendizado profundo ideais para reconhecimento de padrões em tarefas de visão computacional, por exemplo. A estrutura fundamental das CNNs inclui camadas de convolução que aplicam filtros a regiões locais da imagem para capturar características visuais como bordas, texturas e padrões mais complexos (MEIRELLES, 2023).

Essas características extraídas são progressivamente combinadas em camadas subsequentes por meio de operações de *pooling* ou agrupamento, que reduzem a dimensionalidade enquanto preservam as informações essenciais. Através dessa hierarquia de camadas, as CNNs são capazes de aprender representações cada vez mais abstratas e complexas das imagens, permitindo uma identificação precisa de objetos e padrões. Na Figura 6 é possível observar e comparar a estrutura entre uma rede neural simples e uma rede neural de aprendizado profundo.

Figura 6 – Estrutura de uma Rede Neural Simples e Rede Neural de Aprendizado Profundo

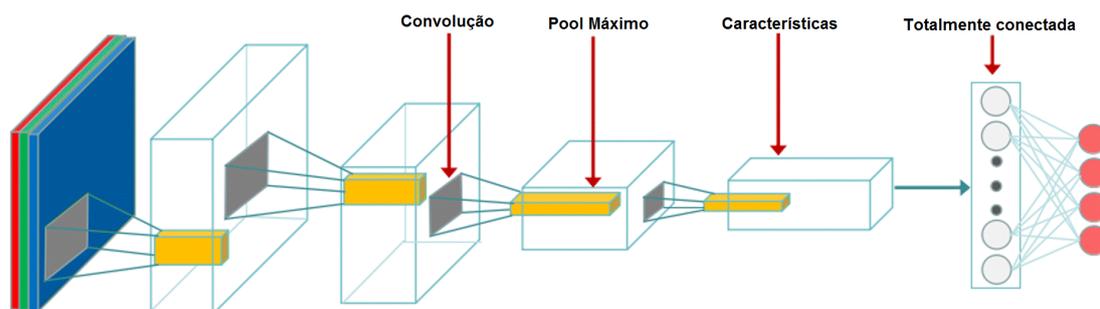


As aplicações das CNNs são vastas e abrangem uma variedade de setores. No campo da visão computacional, as CNNs são usadas para tarefas de classificação, detecção de objetos, onde podem localizar e identificar objetos específicos em uma imagem, e para segmentação semântica, que envolve a atribuição de rótulos a diferentes partes de uma imagem.

### 2.3.3 Arquitetura de uma Rede Neural Convolucional

A estrutura básica de uma CNN consiste em camadas convolucionais, camadas de pooling para subamostragem e camadas totalmente conectadas para tomar decisões finais. Vadera e Ameen (2022) definem CNN como uma evolução da rede Perceptron multicamadas (MLP), cuja organização das conexões entre os neurônios é inspirada no arranjo presente no córtex visual de animais. Cada neurônio, assim, responde a estímulos em regiões limitadas do espaço, denominadas campos receptivos. A Figura 7 oferece uma representação visual da arquitetura e do fluxo de processamento característico de uma CNN.

Figura 7 – Representação da arquitetura e processos de uma CNN



Fonte: Adaptado de Peng et al. (2019)

Essa arquitetura hierárquica e modular torna as CNNs altamente eficazes na extração de informações visuais, tornando-as essenciais para muitas aplicações que envolvem análise de imagens e vídeos.

### 2.3.3.1 Camada Convolutiva

As camadas convolucionais desempenham um papel central na extração de características visuais. Cada camada convolutiva é composta por um conjunto de filtros (ou *kernels*) que são aplicados a regiões locais da imagem de entrada. Esses filtros são projetados para detectar características específicas, como bordas, texturas ou padrões, e deslizam sobre a imagem por meio de operações de convolução (ALMEIDA; BORGES, 2021).

Durante a convolução, os valores da imagem são ponderados de acordo com os pesos do filtro, gerando um mapa de características que destaca a presença dessas características na imagem, Figura 8. Esses mapas de características são combinados em camadas posteriores para capturar informações mais abstratas e complexas, permitindo a identificação de objetos e padrões de maneira eficaz (ZHANG et al., 2021).

Figura 8 – Exemplo de aplicação de uma camada de convolução

<b>Entrada</b>	*	<b>Kernel</b>	=	<b>Saída</b>																	
<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>0</td><td>1</td><td>2</td></tr> <tr><td>3</td><td>4</td><td>5</td></tr> <tr><td>6</td><td>7</td><td>8</td></tr> </table>	0	1	2	3	4	5	6	7	8	*	<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>0</td><td>1</td></tr> <tr><td>2</td><td>3</td></tr> </table>	0	1	2	3	=	<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>19</td><td>25</td></tr> <tr><td>37</td><td>43</td></tr> </table>	19	25	37	43
0	1	2																			
3	4	5																			
6	7	8																			
0	1																				
2	3																				
19	25																				
37	43																				

Fonte: Adaptado de Zhang et al. (2021)

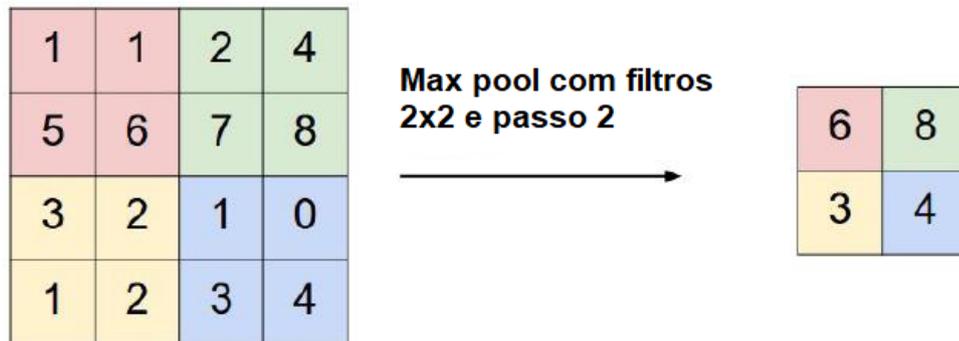
Além disso, as camadas convolucionais são frequentemente seguidas por funções de ativação não lineares, como a *Rectified Linear Activation* (ReLU), que introduzem não linearidades na rede, permitindo que ela capture relações complexas entre os dados (NAYAK et al., 2020). Em resumo, as camadas convolucionais são responsáveis por extrair e hierarquizar características visuais, permitindo que as CNNs sejam altamente eficazes em tarefas de visão computacional, como reconhecimento de objetos e análise de imagens.

### 2.3.3.2 Camada de Pooling

Essas camadas operam selecionando um valor representativo de um grupo de valores adjacentes em um mapa de características, o que reduz o tamanho espacial dos

dados enquanto mantém as informações essenciais. O método mais comum de *pooling* é o *max pooling*, onde o valor máximo de um grupo de valores é selecionado, destacando as características acentuadas. A Figura 9 exemplifica a aplicação da técnica de *max pooling*.

Figura 9 – Exemplo de aplicação de uma camada *Max Pooling*



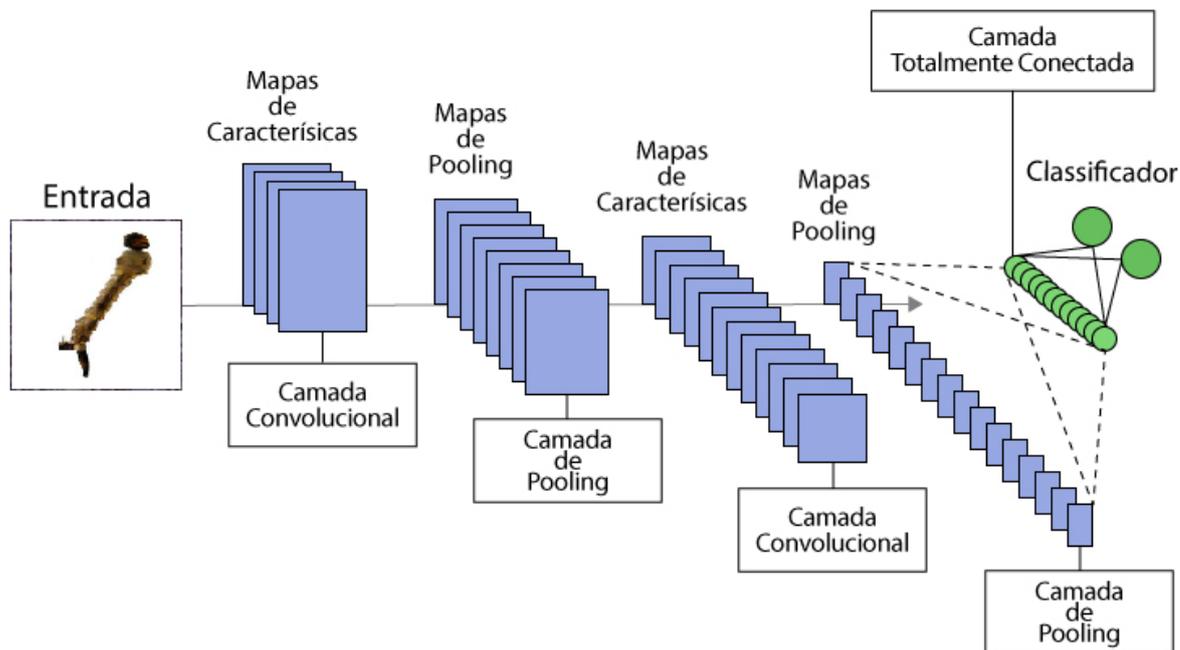
Fonte: Adaptado de Backes (2019)

Ao reduzir a resolução espacial dos mapas de características, essas camadas ajudam a capturar informações abstratas e invariantes, permitindo que a rede identifique padrões independentemente de pequenas variações na posição ou escala dos objetos na imagem. Isso é particularmente útil em tarefas de classificação de objetos, onde os detalhes exatos da localização não são tão críticos quanto as características gerais do objeto (ZHANG et al., 2021).

### 2.3.3.3 Camada Totalmente Conectada

Nas CNNs, após as camadas de convolução e *pooling* terem extraído características visuais de uma imagem, as camadas totalmente conectadas agrupam e combinam essas informações para realizar tarefas específicas, como classificação ou detecção de objetos. Cada neurônio em uma camada totalmente conectada está conectado a todos os neurônios da camada anterior, permitindo a interação e combinação abrangente das características aprendidas (CUNHA, 2020). A Figura 10 demonstra a interconexão entre as camadas de convolução, *pooling* e totalmente conectadas de uma CNN.

Figura 10 – Ilustração da arquitetura de uma CNN com camadas convolucionais, de pooling, totalmente conectada e de saída



Fonte: Adaptado de Cunha (2020)

No entanto, o uso excessivo de camadas totalmente conectadas pode aumentar o número de parâmetros da rede, levando ao risco de *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento. Portanto, o equilíbrio entre camadas convolucionais, de pooling e totalmente conectadas é crucial para alcançar um modelo eficaz e geralmente aplicável em tarefas de aprendizado profundo.

## 2.3.4 Exemplos de CNNs

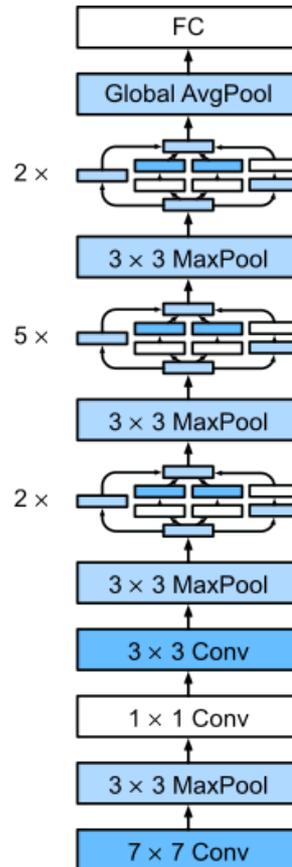
A popularização das CNNs revolucionou a área de visão computacional, em virtude de apresentarem uma abordagem altamente eficaz para o processamento de imagens. Com marcos como o desempenho da AlexNet no desafio ImageNet em 2012 (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), seguida pela introdução de arquiteturas como a GoogLeNet, VGGNet e ResNet, as CNNs se tornaram a estrutura principal de várias aplicações, desde reconhecimento facial até diagnósticos médicos assistidos por imagem (NAYAK et al., 2021; REZA; DONG; QIAN, 2021).

### 2.3.4.1 Inception

A rede neural denominada Inception, GoogLeNet, foi desenvolvida pela equipe do Google para participar do desafio ImageNet *Large Scale Visual Recognition Competition* (ILSVR) em 2014 (SZEGEDY et al., 2015). Esta rede usa uma pilha de um total de 9

blocos iniciais e um pool médio global para gerar suas estimativas, conforme demonstrado na Figura 11.

Figura 11 – Arquitetura da CNN Inception



Fonte: (ZHANG et al., 2021)

O grande diferencial desta arquitetura deu-se ao fato de que ao invés usar apenas convoluções tradicionais com tamanhos de filtro fixos, utiliza-se de uma combinação de filtros de diferentes tamanhos em paralelo, permitindo que a rede capture informações em várias escalas.

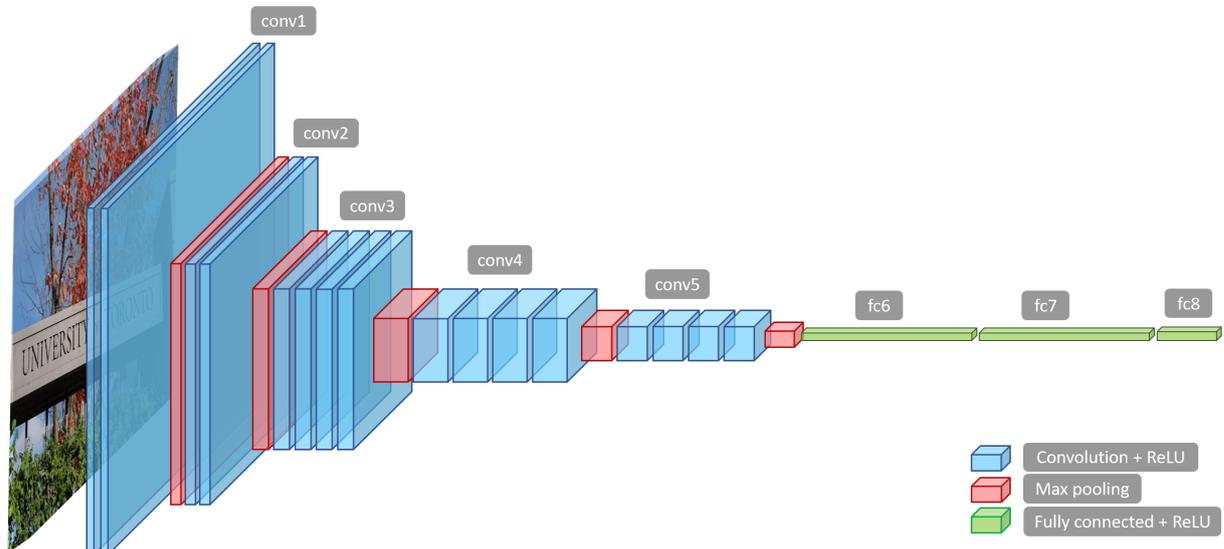
Sua abordagem inovadora influenciou o desenvolvimento subsequente de várias outras arquiteturas de rede neural, contribuindo para o avanço do campo de aprendizado profundo e visão computacional (LIU et al., 2021).

#### 2.3.4.2 VGG

Desenvolvida por Simonyan e Zisserman (2014), a arquitetura de CNN VGG19 (*Visual Geometry Group*) se destaca por sua profundidade, consistindo em 19 camadas, incluindo 16 camadas convolucionais e 3 camadas totalmente conectadas. Além disso, a VGG19 utiliza filtros convolucionais de tamanho reduzido (3x3) em várias camadas,

seguidos por camadas de pooling para reduzir a dimensão espacial. A Figura 12 ilustra a arquitetura da CNN VGG19.

Figura 12 – Arquitetura da rede VGG 19



Fonte: (Objax Developers, 2020)

Essa abordagem resulta em uma representação rica de características, porém com um grande número de parâmetros. Embora a VGG19 seja superada por arquiteturas mais recentes em termos de eficiência computacional, suas características extraídas ainda são amplamente usadas como base em muitas aplicações de visão computacional e transferência de aprendizado (KHAN et al., 2021; IKECHUKWU et al., 2021).

### 2.3.4.3 ResNet

A ResNet-50 é uma arquitetura de rede neural convolucional profunda que faz parte da família ResNet (Redes Residuais). Essa estrutura apresentou a concepção de blocos residuais, os quais contribuem para a mitigação do desafio do desvanecimento do gradiente em redes de grande profundidade (BASODI et al., 2020). A Figura 13 ilustra a arquitetura da CNN ResNet-50.



localização aproximada dos objetos, mas também podem conter informações sobre as classes e a probabilidade de confiança dos objetos detectados, Figura 14.

Figura 14 – Mapa de saída de um sistema detector com caixas delimitadoras



Fonte: (KATHURIA, 2018)

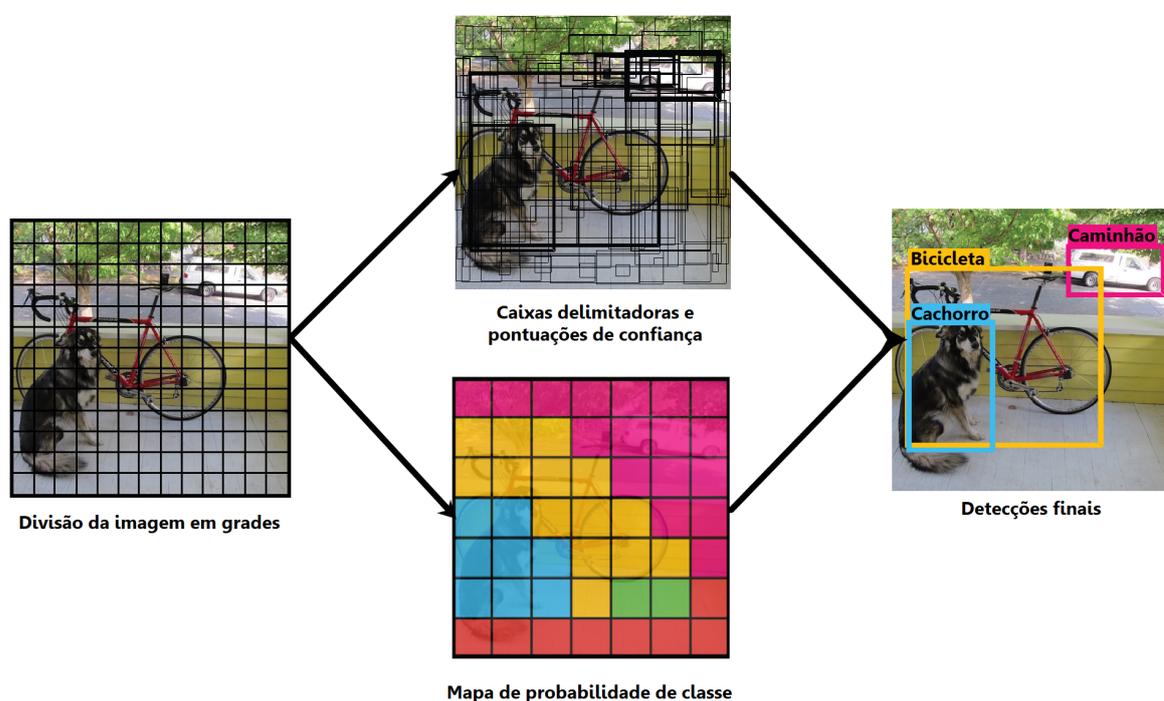
As aplicações dos algoritmos de detecção de objetos são vastas e impactam em diversos ramos. Em veículos autônomos, esses algoritmos são essenciais para detectar pedestres, outros veículos e obstáculos nas estradas, contribuindo para uma condução mais segura e eficiente, enquanto na medicina, podem auxiliar na identificação de anomalias em exames médicos. Com contínuos avanços em tecnologias de aprendizado de máquina e visão computacional, os algoritmos de detecção de objetos estão moldando nossa interação com o mundo digital de maneiras inovadoras e impactantes.

## 2.4.1 YOLO

O algoritmo YOLO, *You Only Look Once*, é uma técnica revolucionária na área de visão computacional, com uma abordagem inovadora na detecção de objetos em geral. Ao contrário de métodos tradicionais que dividem a detecção em múltiplas etapas, o YOLO realiza a detecção de forma direta e eficiente, ao prever tanto as coordenadas das caixas delimitadoras quanto as classes dos objetos em uma única passada pela rede neural (REDMON et al., 2016).

Essa abordagem tem se destacado pela sua capacidade de equilibrar velocidade e precisão, tornando-se fundamental em aplicações de detecção em tempo real (TERVEN; CORDOVA-ESPARZA, 2023). Na detecção de objetos, o YOLO divide a imagem em uma grade e, para cada célula da grade, estima as caixas delimitadoras que cercam os objetos presentes, juntamente com as classes correspondentes. Isso permite que o YOLO identifique e localize múltiplos objetos simultaneamente, proporcionando eficiência em cenários de monitoramento e análise visual (REIS et al., 2023b). A Figura 15 fornece a visão geral da metodologia YOLO para detecção de objetos.

Figura 15 – Detecção com o algoritmo YOLO



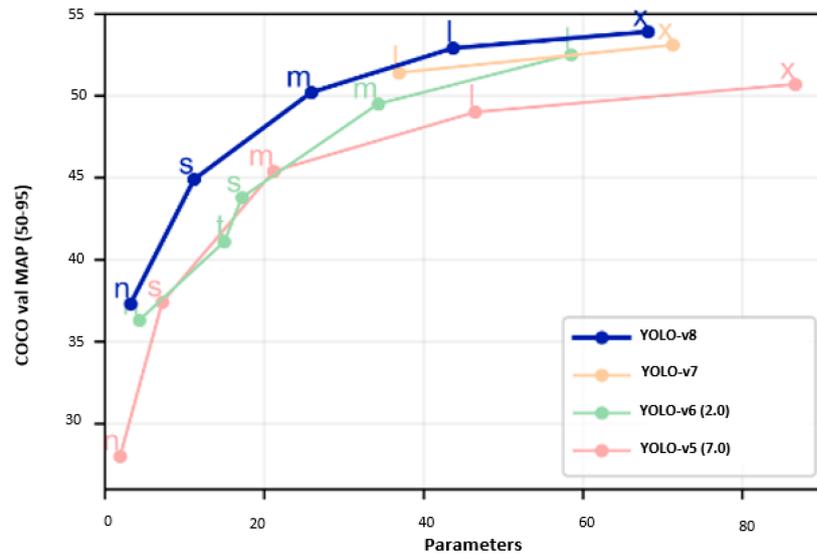
Fonte: Adaptado de Redmon et al. (2016)

Atualmente, o algoritmo YOLO apresenta 8 versões, desenvolvidas entre os anos de 2016 a 2023. A seguir cada versão é descrita de forma resumida e com seus respectivos avanços na área de visão computacional.

- YOLO v1 (2016): Introduziu a detecção de objetos em uma única passada, mas teve problemas de precisão em objetos pequenos.
- YOLO v2 (2017): Melhorou a precisão com detecções em várias escalas e treinamento em um conjunto de dados mais amplo.
- YOLO v3 (2018): Aumentou a precisão com detecção em diferentes resoluções e tamanhos de caixas de detecção.
- YOLO v4 (2020): Continuou a melhorar precisão e velocidade com otimizações na arquitetura, ativações Leaky ReLU e estratégias de treinamento.
- O YOLOv5 (2020) aprimorou ainda mais o desempenho do modelo, incorporando recursos como otimização de hiperparâmetros, rastreamento integrado de experimentos e exportação automática para formatos populares.
- O YOLOv6 (2022), lançado em 2022 pela Meituan, está em uso extensivo nos robôs autônomos de entrega da empresa.
- O YOLOv7 (2022) expandiu suas capacidades e propôs algumas mudanças na arquitetura que aumentaram a precisão sem afetar a velocidade de inferência, apenas o tempo de treinamento.
- A versão mais recente da família YOLO, o YOLOv8 (2023) da Ultralytics é um modelo que se baseia no êxito das versões anteriores. Ele traz novos recursos e aprimoramentos para elevar o desempenho, a flexibilidade e a eficiência. O YOLOv8 suporta uma ampla gama de tarefas de visão de IA, incluindo detecção, segmentação, estimativa de pose, rastreamento e classificação. Essa versatilidade possibilita que os usuários explorem os recursos do YOLOv8 em diversas aplicações e áreas.

A Figura 16 demonstra um comparativo da precisão média atingida com relação dos submodelos desenvolvidos das últimas versões do modelo YOLOv5 a YOLOv8. Percebe-se que a versão mais recente, YOLOv8, apresentou os maiores valores de precisão em comparação com as outras, levando em consideração a quantidade similar de parâmetros.

Figura 16 – Comparação entre os modelos YOLO mais recentes



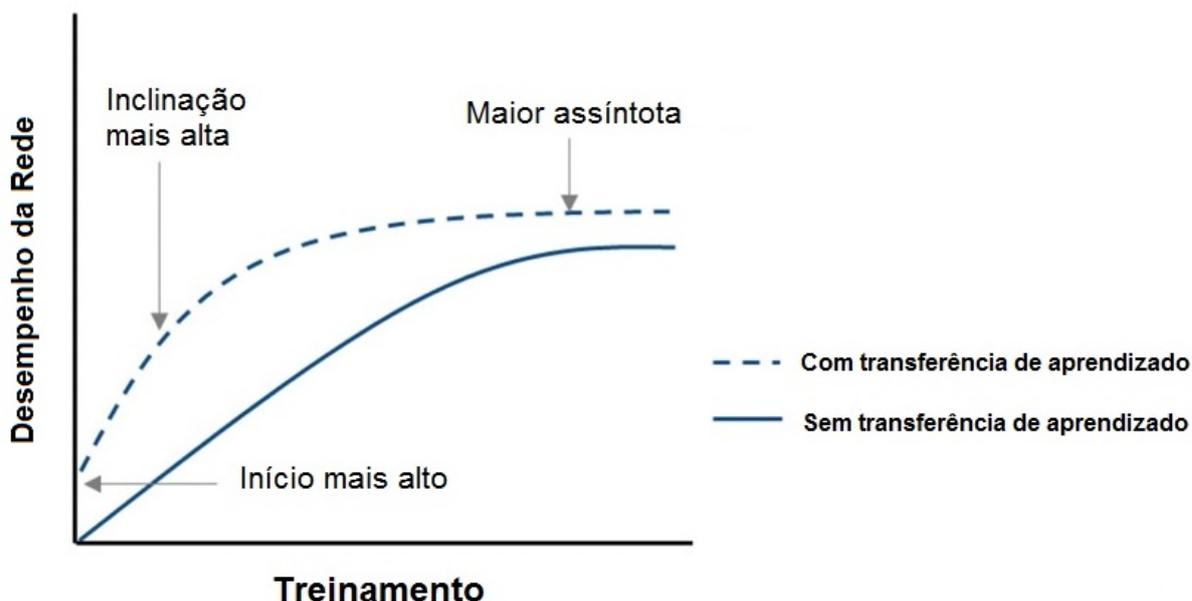
Fonte: (JOCHER et al., 2022)

O YOLO é notável por sua capacidade de capturar informações contextuais, tornando-o apto a discernir entre objetos sobrepostos ou parcialmente ocultos, contribuindo para uma detecção mais precisa. Ademais, a segmentação de objetos é outra vertente importante da visão computacional, onde o objetivo é não apenas detectar, mas também delinear as bordas precisas de cada objeto na imagem. Em sua versão mais recente, o YOLOv8 apresenta técnicas de segmentação para proporcionar a compreensão mais detalhada das formas e contornos dos objetos (MOHAN; ARUNMOZHI; RAJINIKANTH, 2023).

## 2.5 Transferência de Aprendizado

A transferência de aprendizado é uma técnica que utiliza o conhecimento adquirido por uma rede pré-treinada em uma tarefa específica e o aplica em uma nova tarefa relacionada (IRUNGU et al., 2023). A utilização de um modelo pré-treinado oferece várias vantagens, destacando-se principalmente a diminuição do custo computacional e da quantidade de dados requerida ao aplicar a transferência de aprendizado a CNNs (MATHWORKS, 2019). Na Figura 17, é ilustrado o desempenho estimado de CNNs através de um comparativo entre redes com e sem a incorporação da estratégia de transferência de aprendizado.

Figura 17 – Desempenho da redes com transferência de aprendizado



Fonte: Adaptado de Mathworks (2019)

Nesse contexto, os conjuntos de dados ImageNet e COCO se destacam como essenciais para aplicação desta técnica. O ImageNet corresponde a um amplo conjunto de imagens criado para aplicação na pesquisa de *softwares* voltados ao reconhecimento de objetos. Este dataset é composto por mais de 14 milhões de imagens anotadas manualmente em mais de 20.000 categorias e com as respectivas indicações dos objetos retratados e, em pelo menos um milhão de imagens, caixas delimitadoras também são fornecidas (MORID; BORJALI; FIOL, 2021).

Já o dataset COCO possui um amplo conjunto de dados de reconhecimento de imagens para tarefas de detecção, segmentação e rotulagem de objetos. O dataset possui mais de 330.000 imagens, devidamente rotuladas entre 80 categorias de objetos e incluem legendas descrevendo o conteúdo das imagens. Além disso, ressalta-se que as imagens do COCO frequentemente retratam cenas complexas com vários objetos em configurações naturais, o que ajuda os modelos a entender os objetos no contexto (LIN et al., 2015).

## 2.6 Métricas de Avaliação

As métricas de avaliação desempenham um papel essencial na quantificação objetiva do desempenho de modelos e algoritmos em diversas tarefas, permitindo uma avaliação precisa e comparativa. Essas métricas fornecem medidas quantitativas que refletem a qualidade das previsões ou resultados. Ao fornecer *insights* sobre a eficácia e confiabilidade das abordagens, as métricas de avaliação auxiliam na seleção e no ajuste de modelos, bem

como na otimização de parâmetros, contribuindo para a melhoria contínua e refinamento das soluções (PADILLA; NETTO; SILVA, 2020).

A matriz de confusão é uma ferramenta importante e amplamente utilizada para avaliação de sistemas de classificação de dados, pois permite analisar de forma rápida e intuitiva o desempenho de cada sistema. Os valores que compõem a matriz são obtidos fornecendo os segmentos do conjunto de teste ao método de classificação e comparando sua predição com a classe correta de cada segmento.

Segundo (HASNAIN et al., 2020), a matriz de confusão é uma métrica efetiva em modelos de classificação, ao mostrar o número de classificações corretas versus as classificações preditas para cada classe, sobre um conjunto de dados. A Tabela 1 demonstra os elementos contidos em uma matriz de confusão para um problema de classificação binária, utilizando-se das classes Positivo e Negativo. Na diagonal principal constam os elementos que representam as classificações corretas, Verdadeiro Positivo (VP) e Verdadeiro Negativo (VN), e na diagonal secundária constam os elementos que representam as classificações incorretas, Falso Positivo (FP) e Falso Negativo (FN).

Tabela 1 – Matriz de Confusão para duas classes

		Esperada	
		Positivo	Negativo
Prevista	Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Fonte: Adaptado de Souza et al. (2020)

A partir da matriz de confusão, diversas métricas podem ser obtidas para medir a qualidade de classificação. Nesse sentido, (SOUZA et al., 2020) descreve as principais métricas para avaliação e validação em sistemas de classificação de imagens. Para validação das CNNs, as seguintes métricas foram avaliadas neste trabalho:

- Acurácia: razão entre a quantidade de classificações corretas sobre o total de classificações realizadas, Equação (2.1).

$$Acc. = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.1)$$

- Precisão: razão entre a quantidade de classificações positivas realizadas em relação ao total de classificações positivas previstas, Equação (2.2).

$$Prec. = \frac{VP}{VP + FP} \quad (2.2)$$

- Sensitividade: razão entre a quantidade de classificações positivas corretas em relação ao total de classificações reais, Equação (2.3).

$$Sens. = \frac{VP}{VP + FN} \quad (2.3)$$

- F-score: é uma métrica que combina a precisão e a sensibilidade em uma única medida e consiste na média harmônica entre a precisão e a sensibilidade, Equação (2.4).

$$F1 = 2 * \frac{Prec. * Sens.}{Prec. + Sens.} \quad (2.4)$$

Além das métricas voltadas para a tarefa de classificação, no que diz respeito à tarefa de detecção e segmentação, as métricas mAP (*mean Average Precision*) e MSE (*Mean Squared Error*) se destacam para validação da eficácia desses tipos de soluções.

#### MEAN AVERAGE PRECISION (mAP)

A mAP é uma métrica amplamente utilizada para avaliar o desempenho de modelos em tarefas de detecção de objetos. Ele mede a precisão média em vários níveis de *recall*, ou seja, a habilidade do modelo em recuperar corretamente objetos de interesse. A mAP é obtida ao calcular a precisão para diferentes valores de *threshold* de confiança das detecções e, em seguida, calcular a média dessas precisões (ZHENG et al., 2021).

Os valores variam entre 0 e 1, ou 0 a 100%, onde um valor maior indica um desempenho melhor na detecção e localização de objetos. A fórmula da mAP é dada pela Equação (2.5).

$$mAP = \frac{1}{Q} \sum_{q=1}^Q AP_q \quad (2.5)$$

onde:

- *mAP* é a Média da Precisão Média.

- $Q$  é o número total de consultas ou tarefas de recuperação.
- $AP_q$  é a Precisão Média para a consulta  $q$ .

### MEAN SQUARED ERROR (MSE)

O *Mean Squared Error* MSE é uma métrica comumente usada em tarefas de regressão e medição de erro em visão computacional. Esta métrica quantifica a média dos quadrados das diferenças entre os valores previstos pelo modelo e os valores reais (QI et al., 2020). Matematicamente, o MSE é encontrado através da soma do quadrado das diferenças para cada par de valores e, em seguida, divisão pelo número total de pares. A fórmula do MSE é dada pela Equação (2.6).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.6)$$

onde:

- $n$  é o número de amostras nos dados de teste.
- $y_i$  representa o valor real do alvo para a  $i$ -ésima amostra.
- $\hat{y}_i$  representa o valor previsto pelo modelo para a  $i$ -ésima amostra.

Logo, quanto menor o valor do MSE, melhor o ajuste do modelo aos dados, indicando uma menor diferença média entre as previsões e os valores reais.

## 2.7 Considerações Finais

Neste capítulo, procedeu-se à fundamentação teórica de todos os conceitos e técnicas empregados ao longo deste estudo, visando aprimorar a compreensão dos próximos capítulos. Na sequência, Capítulo 3, são expostas as pesquisas que abordam temáticas correlatas à presente investigação.

## 3 Trabalhos Correlatos

### 3.1 Considerações Iniciais

Este capítulo tem o objetivo de apresentar os principais trabalhos relacionados as tarefas de detecção, classificação e segmentação de objetos, visão computacional e arquiteturas relacionadas ao controle vetorial dos mosquitos do gênero *Aedes*, com ênfase em soluções voltadas para as larvas deste mosquito.

### 3.2 Levantamento do Estado da Arte

Para levantamento da literatura relacionada ao tema deste trabalho, realizou-se a pesquisa no portal de periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Segundo CAPES et al. (2020), o portal consiste em uma biblioteca virtual concebida para viabilizar o acesso global, atualizado e de qualidade à produção científica. Abrangendo todas as áreas do conhecimento, a plataforma disponibiliza bases de dados textuais e de referências, contando com mais de 50.000 títulos de periódicos de alcance nacional e internacional. Além disso, oferece à comunidade universitária – alunos, docentes, pesquisadores e técnicos – um dos mais vastos acervos bibliográficos do mundo, compreendendo artigos, teses, patentes, trabalhos de eventos, livros eletrônicos e outros recursos essenciais.

Para organizar de forma mais didática o levantamento realizado, utilizou-se da ferramenta VOSviewer. De acordo com Eck e Waltman (2011), este *software* é destinado à visualização e análise de dados bibliométricos, abrangendo artigos científicos, suas referências e citações correspondentes. Por meio dessa ferramenta, é possível realizar a representação gráfica da interligação de citações entre os artigos, bem como a identificação dos principais autores, instituições e tópicos de pesquisa em um campo específico. Adicionalmente, permite a elaboração de mapas da colaboração entre pesquisadores e grupos de estudo, contribuindo para a detecção de tendências nas variadas áreas do conhecimento (ARRUDA et al., 2022).

A pesquisa consistiu na utilização dos descritores CNN, *Aedes*, Larvae, Convolutional Neural Networks, Mosquito e YOLO. A busca retornou um total de 87 trabalhos em diferentes repositórios. O intervalo de tempo estudado compreendeu os anos de 2019 a 2023, últimos cinco anos. Em seguida, foi construída a rede bibliométrica, baseada cocorrência das palavras-chave destes trabalhos, a qual está disposta na Figura 18.



obter resolução suficiente para identificar corpos d'água potencialmente colonizados por *Ny. darlingi*. Esta abordagem permite uma classificação altamente precisa da assinatura espectral de corpos d'água que abrigam *Ny. darlingi* no contexto da região amazônica.

O trabalho de Garcia et al. (2019) introduz uma abordagem que utiliza uma CNN para identificar quais elementos nas imagens são ovos de mosquito *Aedes*. Os pesos de uma rede treinada de 10 classes são usados como pesos iniciais na CNN proposta. O treinamento é baseado no otimizador SGD. Para avaliação de desempenho, os autores utilizam o índice de Jaccard, também conhecido como interseção sobre união, e é usado para medir o quanto a localização da caixa delimitadora do modelo difere de sua localização real. Esse índice demonstrou a CNN foi capaz de identificar 91% dos ovos presentes nas imagens de validação.

Silva e Jayalal (2020) apresentam um modelo de visão computacional automatizado baseado na CNN ResNet50 para classificação de larvas do mosquito *Aedes*. O modelo realiza a classificação das imagens submetidas entre as classes “*Aedes*” ou “não-*Aedes*”. As imagens foram adquiridas através de um *smartphone* com câmera acoplada. O modelo se demonstrou capaz de identificar imagens de larvas de *Aedes* e não *Aedes* separadamente com uma precisão de 86,65%. Além disso, com o uso de técnicas de pré-processamento, o nível de precisão foi aumentado para 98,76% para imagens ampliadas.

Os autores Surya et al. (2022) apresentam um estudo comparativo entre soluções de visão computacional para identificar larvas de mosquitos, visando mitigar a propagação de doenças transmitidas por estes. O estudo compara diferentes modelos, incluindo CNNs e o *Vision Transformer* (ViT), para determinar a maneira mais eficaz de distinguir os mosquitos *Aedes* e *Culex*. Os modelos foram treinados em um conjunto de dados de imagens de larvas de mosquitos e seu desempenho foi avaliado com base em métricas como acurácia, precisão e sensibilidade. O estudo constatou que o ViT superou as CNNs na classificação das larvas do mosquito, atingindo uma precisão de 98,5%.

Em Hubalde, Padilla e Santos (2021) é conduzida uma pesquisa com o objetivo de contribuir para a supressão precoce do vetor da dengue. Para tanto, foi proposto sistema utilizando o algoritmo YOLO para detectar e classificar larvas de mosquito da espécie *Aedes aegypti*. Os resultados obtidos demonstraram a eficácia desse sistema, que foi capaz de identificar a maioria das amostras de larvas submetidas aos testes. Os valores médios dos erros quadráticos foram registrados em 0,45 para larvas de *Aedes* e 0,77 para larvas não-*Aedes*, indicando a confiabilidade do sistema no reconhecimento dessas categorias.

O trabalho de Kittichai et al. (2021) propõe uma solução para classificar e localizar simultaneamente as espécies do gênero de mosquitos capturados nas imagens coletadas. Para tanto, são utilizados imagens de mosquitos pertencentes às classes *Aedes*, *Culex*, *Armigeres*, *Mansonia* e *Anopheles*. A solução é baseada nos modelos tiny YOLOv2, YOLOv2 and YOLOv3. Os valores mAP obtidos variaram entre 73,80% a 85,9%.

O sistema proposto por Hossain et al. (2022) para detecção de larvas de *Aedes* consiste em três módulos principais: aquisição de imagens, segmentação do corpo da larva e classificação da larva. Inicialmente, o módulo de aquisição de imagens captura a imagem de entrada, verifica sua qualidade e realiza a normalização das cores. Então, no módulo de segmentação, cada corpo de larva é separado da imagem de entrada para criar uma região de interesse (ROI) para cada larva. Finalmente, no módulo de classificação, cada larva é classificada como *Aedes* ou não *Aedes* usando técnicas de aprendizado, como aprendizado de transferência e modelos de empilhamento.

Os estudos mencionados anteriormente oferecem abordagens diversas de controle vetorial na mesma área desta dissertação e introduzem conceitos pertinentes relacionados à pesquisa proposta. A Tabela 2 sumariza de forma concisa os trabalhos abordados, juntamente com suas limitações correspondentes.

Tabela 2 – Resumo dos Trabalhos Correlatos

Referência	Objetivos	Lacunas
(CARRASCO-ESCOBAR et al., 2019)	Identificar corpos d'água potencialmente colonizados por mosquitos transmissores de malária, como <i>Ny. Darlingi</i> .	O estudo se limita aos corpos d'água e não trabalha especificamente com a identificação das larvas
(KITTIKHAJ et al., 2021)	Classificar e localizar simultaneamente as espécies de mosquitos	O dataset utilizado apresenta somente imagens individuais de mosquitos
(GARCIA et al., 2019)	Identificar quais elementos nas imagens são ovos de mosquito <i>Aedes</i>	Dataset composto por um número reduzido de imagens (300) e falta de comparação com outras arquiteturas de CNNs
(SILVA; JAYALAL, 2020)	Propor de um sistema computacional automatizado baseado na ResNet50 para classificação de larvas do mosquito <i>Aedes</i> .	Dataset composto por um número reduzido de imagens (238) e limitado a imagens individuais de larvas <i>Aedes</i>
(SURYA et al., 2022)	Determinar a maneira mais eficaz de distinguir os mosquitos <i>Aedes</i> e <i>Culex</i> .	Utilização de CNNs com baixa profundidade e falta de informações sobre as imagens utilizadas
(HOSSAIN et al., 2022)	Detectar efetivamente as larvas de <i>Aedes</i>	Dataset composto por imagens padronizadas em relação à distância de captura
(HUBALDE; PADILLA; SANTOS, 2021)	Detectar e classificar larvas de mosquito da espécie <i>Aedes aegypti</i>	Número limitado de métricas utilizadas para validação da solução

Este trabalho busca preencher as lacunas encontradas na literatura relacionada ao controle vetorial dos mosquitos *Aedes*, especificamente no que diz respeito às larvas. A maioria dos trabalhos apresentam como deficiência a limitação do *dataset* utilizado para

conduzir os testes. Nesse sentido, este trabalho apresenta uma metodologia para criação de um conjunto de dados próprio, abordando essa limitação.

Além disso, o estudo explora um conjunto de técnicas de visão computacional, incluindo o uso de redes neurais convolucionais (CNNs) e a arquitetura YOLO (You Only Look Once), para realizar a classificação, detecção e segmentação das larvas do mosquito. Essas abordagens avançadas permitem um melhor entendimento e monitoramento das larvas, contribuindo para o desenvolvimento de estratégias mais eficazes no controle desses vetores de doenças transmitidas por mosquitos.

### **3.3 Considerações Finais**

Este capítulo apresentou os trabalhos correlatos que nortearam a realização dessa pesquisa e que serviram como base para o desenvolvimento dos modelos propostos. A seção seguinte, Capítulo 4, detalha a metodologia desenvolvida neste trabalho.

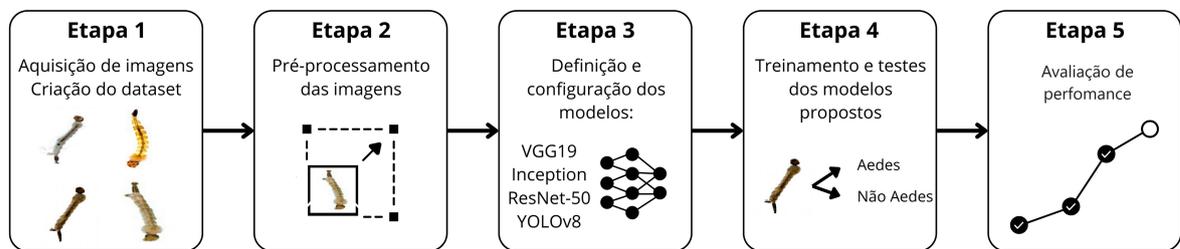
## 4 Materiais e Métodos

### 4.1 Considerações Iniciais

Neste capítulo é apresentada uma visão geral das etapas do processo metodológico envolvido no desenvolvimento deste trabalho. A metodologia consiste nas etapas de criação do conjunto de dados (dataset), pré-processamento das imagens, confecção e treinamento dos modelos. Para apresentar uma solução mais abrangente à problemática de controle vetorial, foram confeccionados três modelos, sendo um para cada tarefa entre classificação, detecção e segmentação das larvas.

A Figura 19 ilustra a metodologia final proposta neste estudo. A primeira etapa consiste no processo de pesquisa de bases públicas que contenham imagens de larvas de mosquitos Aedes. Após aquisição das imagens, estas foram pré-processadas e submetidas aos modelos propostos para classificação, detecção e segmentação das larvas. Por fim, busca-se avaliar a performance dos modelos através da análise das métricas de avaliação.

Figura 19 – Metodologia final a ser implementada no processo de monitoramento e detecção de larvas de mosquitos do gênero Aedes.



Fonte: Elaborado pelo autor

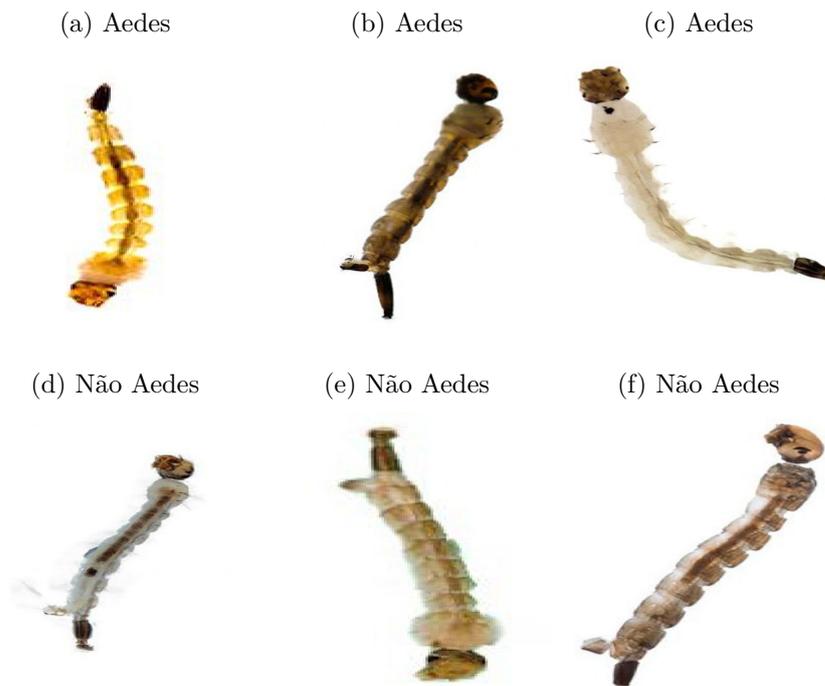
Resumidamente, a metodologia empregada no presente trabalho buscou viabilizar uma solução capaz de detectar e identificar larvas de mosquitos do gênero Aedes, utilizando como base redes neurais convolucionais (VGG19, Inception e ResNet-50) e o algoritmo de detecção de objetos (YOLO). Para tanto, os modelos propostos foram aplicados em um conjunto de dados criado através da junção de imagens de fontes diversas e com anotações manuais.

### 4.2 Conjunto de dados

Diante da limitação em encontrar bases públicas com quantidades significativas de imagens adequadas para o propósito deste estudo, tornou-se necessário criar um conjunto

de dados (*dataset*) próprio. O *dataset* foi formado por imagens selecionadas de um recorte do conjunto de dados disponível de Hossain et al. (2022) e de imagens retiradas de bases públicas diversas, contendo larvas dos mosquitos *Aedes*, *Anopheles* e *Culex*. O *dataset* encontra-se disponível em (SILVA, 2023). A Figura 20 representa algumas imagens utilizadas para confecção do *dataset*.

Figura 20 – Imagens presentes no *dataset*.



Fonte: Adaptado de Hossain et al. (2022)

O *dataset* é composto por 710 imagens, sendo 420 para a classe *Aedes* e 290 para a classe Não *Aedes*. Além disso, foram distribuídas em 60% para treinamento, 20% para validação e 20% para teste de acordo com as boas práticas para o desenvolvimento de modelos de machine learning.

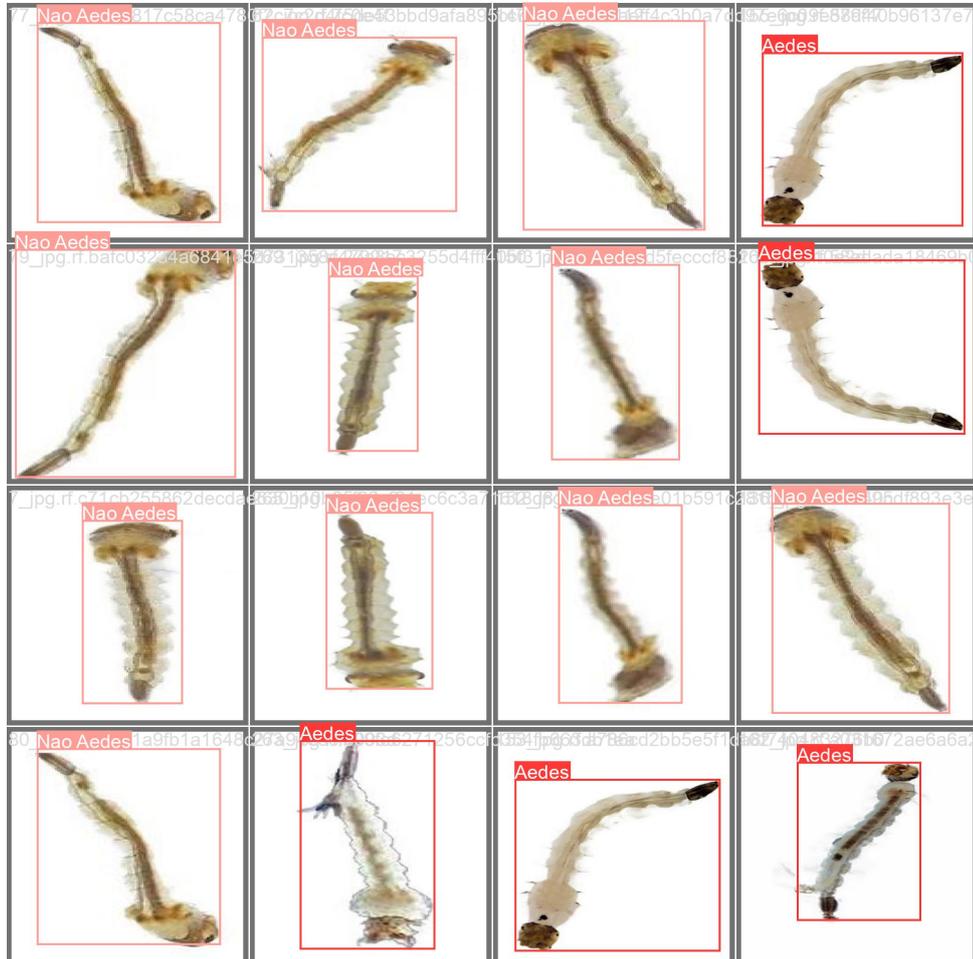
### 4.3 Anotação e Pré-processamento das imagens

Inicialmente, as imagens selecionadas foram categorizadas em *Aedes*, quando há presença de larva desse mosquito, e Não *Aedes*, quando há presença de outros tipos de larvas. Em seguida, foram orientadas e redimensionadas para a resolução 224x224 pixels para entrada nas CNNs e 640x640 pixels, tamanho necessário para a imagem de entrada na CNN YOLO.

A anotação das imagens foi realizada manualmente com o auxílio da plataforma Roboflow (DWYER et al., 2022), a qual facilita a anotação de imagens para treinar o modelo e inclui vários recursos complementares (REIS et al., 2023a). Essa etapa teve a

duração estimada de 15 dias e, ao final, foram contabilizadas 789 anotações de larvas. A Figura 21 apresenta algumas imagens rotuladas que compõe o *dataset* criado.

Figura 21 – Imagens rotuladas após o pré-processamento



Fonte: Elaborado pelo autor

## 4.4 Desenvolvimento dos modelos

### 4.4.1 Classificadores com CNNs

Para classificação, utilizou-se das arquiteturas VGG19, Inception e ResNet-50 para criação dos modelos, descritas na subseção 2.3.4. Os modelos propostos foram desenvolvidos após os resultados obtidos através de um estudo prévio entre as CNNs Inception, VGG-19 e ResNet-50, as quais foram direcionadas para classificação de larvas (SILVA et al., 2023). Dessa forma, optou-se pela seleção e confecção dessas arquiteturas com adequação dos parâmetros ao *dataset* criado. Alguns dos hiperparâmetros utilizados para o treinamento do modelo estão descritos na Tabela 3.

Tabela 3 – Parâmetros de treinamento das CNNs

Parâmetro	Valor
Épocas	100
Batch Size	32
Optimizer	Adam
Learning Rate	1e-5
Função de Ativação	Softmax

Fonte: Elaborado pelo autor

#### 4.4.2 Dectectores com YOLO

Conforme descrito na subsecção 2.4.1, o algoritmo YOLO é uma estratégia promissora para detecção de objetos em diversas áreas de estudo. Portanto, para as tarefas de detecção e segmentação, foi selecionado este algoritmo em sua versão mais recente, YOLOv8, por possuir ferramentas especificamente voltadas para estas tarefas e amplos testes junto à comunidade científica.

Para os modelos usando YOLO voltados à detecção e segmentação, foram utilizados os modelos `yolov8s.pt` e `yolov8s-seg.pt`, respectivamente. Alguns dos hiperparâmetros utilizados para o treinamento dos modelos estão descritos na Tabela 4.

Tabela 4 – Principais parâmetros de treinamento do YOLO voltado para detecção e segmentação

Parâmetro	Valor
Épocas	100
Batch Size	16
Optimizer	SGD
Learning Rate	0.01
Patience	50

Fonte: Elaborado pelo autor

### 4.5 Treinamento dos modelos

O treinamento de CNNs tem um custo computacional considerável, tendo como pré-requisitos principais a presença de uma significativa capacidade de memória e unidades de processamento gráfico (GPUs) de alto desempenho. Diante disso, optou-se pela aplicação da técnica de transferência de aprendizado e utilização da plataforma Google Colaboratory, como forma de mitigar tais limitações.

Para o treinamento dos modelos utilizou-se de redes pré-treinadas nos seguintes datasets: ImageNet, para as CNNs (VGG19, Inception e ResNet-50), e COCO (*Common Objects in Context*) para YOLOv8.

## 4.6 Avaliação de Performance

Após o treinamento e testes dos modelos, foi realizada a avaliação do desempenho através das métricas descritas na seção 2.6. Para as redes neurais foi avaliado o comportamento da acurácia e função *Loss* ao longo das 100 épocas, além das métricas de precisão, sensibilidade e F-score. De forma análoga, para os modelos YOLOv8 foram analisadas as métricas de mAP e MSE, seguidas das métricas de precisão e sensibilidade.

## 4.7 Considerações Finais

Este capítulo teve como objetivo analisar os elementos das arquiteturas propostas no contexto da tarefa detecção de larvas de mosquitos. Foi detalhado o fluxo e cada etapa integrante da solução: dataset, pré-processamento, confecção, treinamento e análise de desempenho dos modelos desenvolvidos. No Capítulo 5 serão apresentados os resultados obtidos através dos treinamentos para cada modelo e um comparativo do desempenho entre estes.

# 5 Resultados e Discussão

## 5.1 Considerações Iniciais

O presente capítulo apresentará os resultados obtidos a partir da aplicação da metodologia proposta neste trabalho no que tange a detecção e identificação de larvas de mosquitos *Aedes*. Os resultados obtidos através do treinamento dos modelos propostos, aplicados ao dataset criado, foram avaliados mediante as métricas de avaliação citadas na seção 2.6, considerando cada uma das três tarefas designadas: classificação, detecção e segmentação.

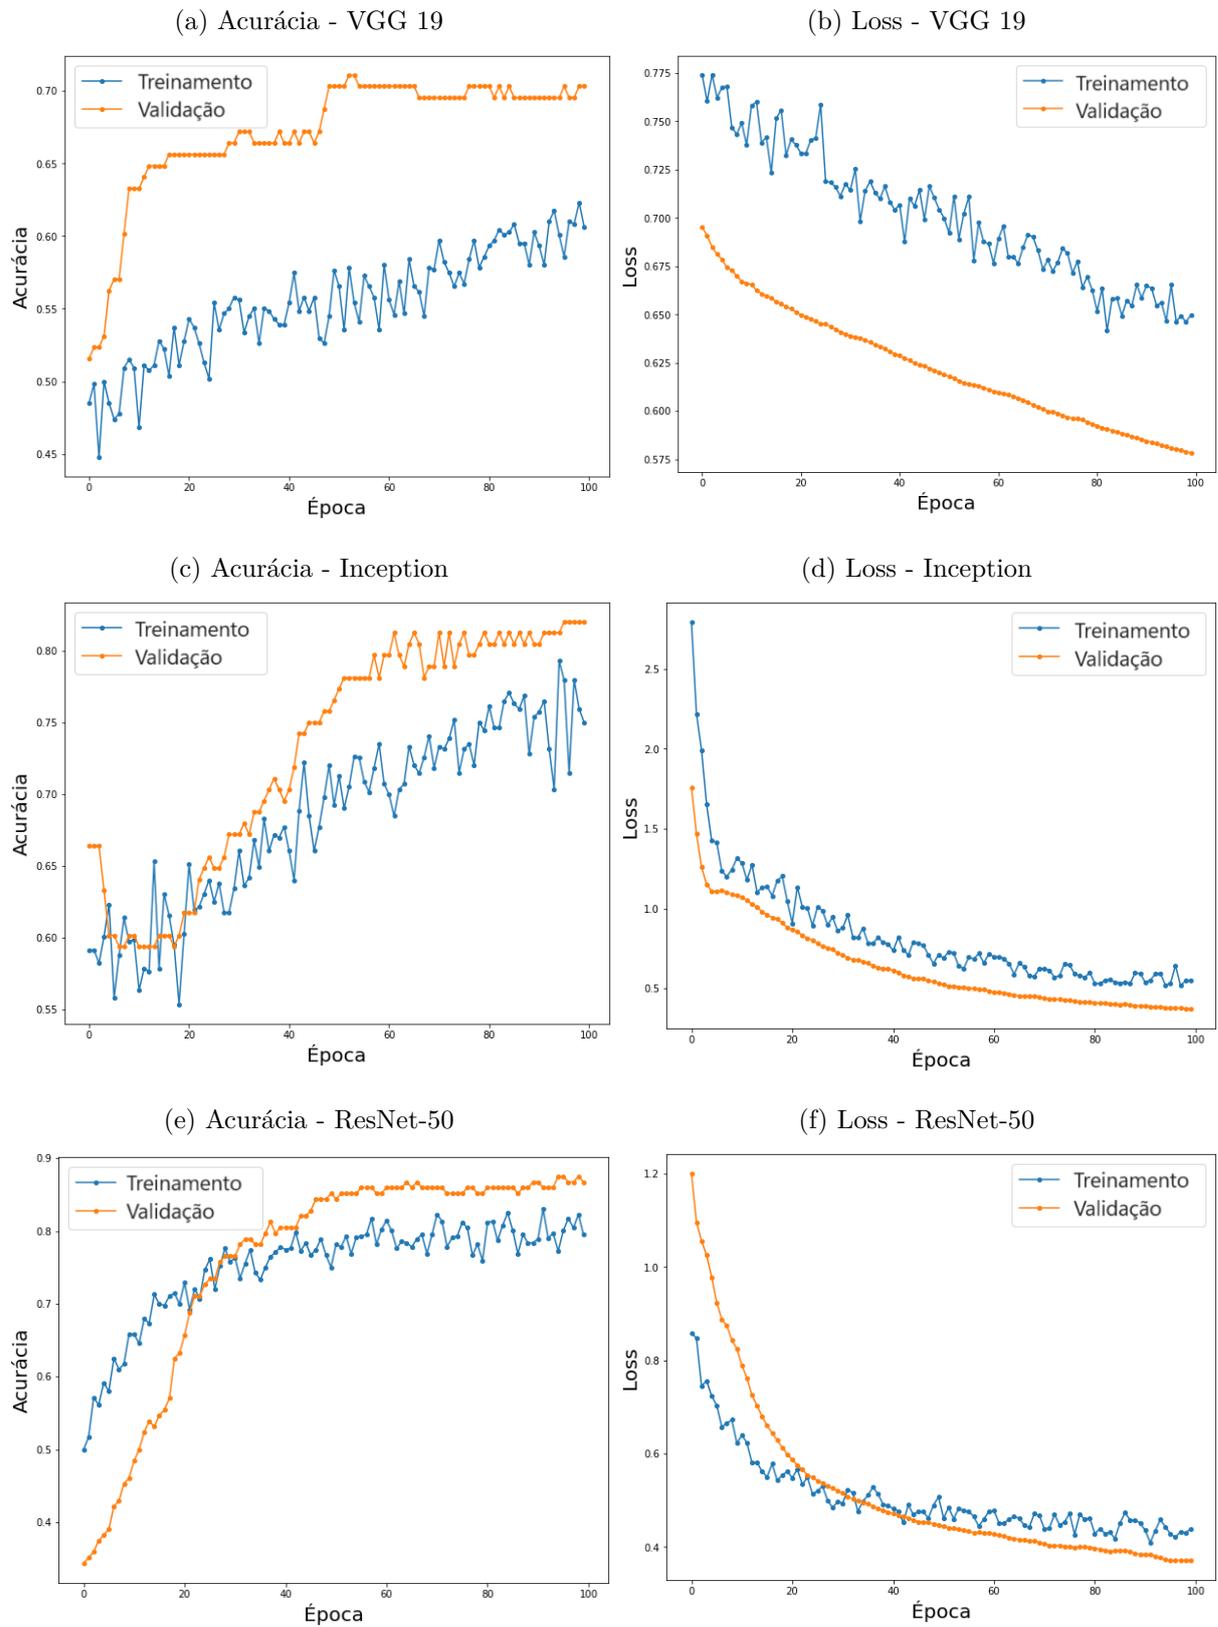
## 5.2 Classificação

Para a tarefa de classificação, a performance dos modelos classificadores baseados nas CNNs VGG19, Inception e ResNet-50 foi avaliada por meio das métricas de acurácia, da função de perda (*Loss*), tanto nos estágios de treinamento quanto nos de teste. Os valores correspondentes de acurácia e loss para cada uma das CNNs estão representados de forma gráfica na Figura 22.

Com base nos resultados obtidos, foi possível constatar que a técnica de transferência de aprendizado foi capaz de proporcionar generalização para a tarefa de classificação. O treinamento foi capaz de aprimorar os classificadores conforme observado nos gráficos de acurácia e loss. Com o objetivo de efetuar uma comparação entre as CNNs, a Figura 23 ilustra a análise das acurácias e loss alcançados por cada uma delas e a Tabela 5 exhibe os valores detalhados para as métricas estudadas.

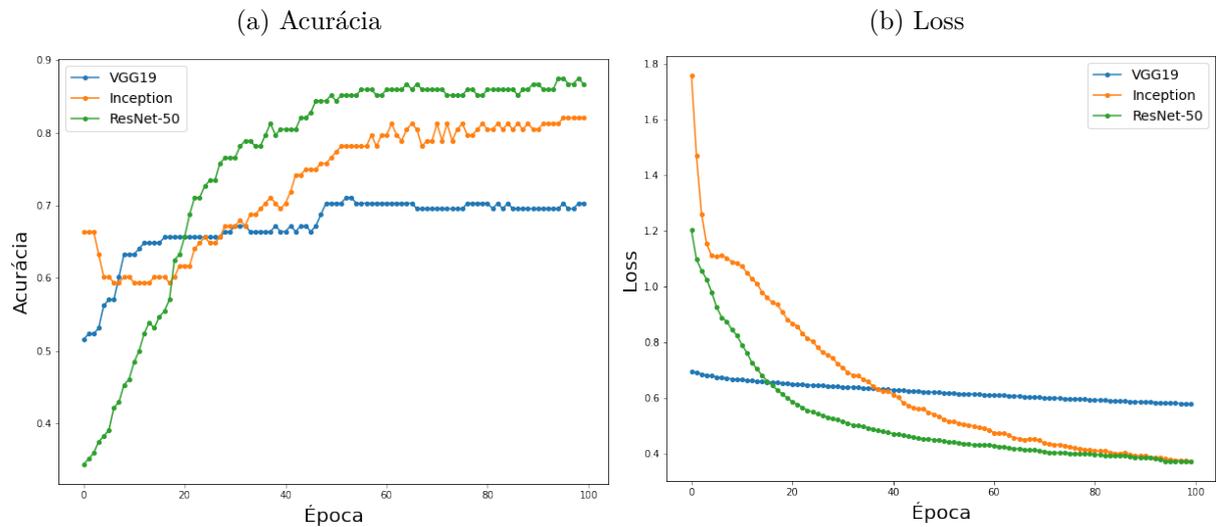
Observa-se que a arquitetura VGG19 alcançou a maior precisão para a classe *Aedes*, porém, apresentou piores valores para as demais métricas. Além disso, as redes Inception e ResNet-50 demonstraram o melhor desempenho em relação as demais métricas. O modelo com a CNN ResNet-50 se destacou como o melhor classificador de larvas, dentre os propostos.

Figura 22 – Resultados obtidos para as CNNs



Fonte: Elaborado pelo autor

Figura 23 – Comparação da Acurácia e Loss obtidos para os classificadores propostos



Fonte: Elaborado pelo autor

Tabela 5 – Métricas das arquiteturas de CNN propostas

Arquitetura	Classe	Acc.	Prec.	Sens.	F-score
VGG19	Aedes	70,31%	<b>0,96</b>	0,64	0,77
	Não Aedes		0,22	0,81	0,35
Inception	Aedes	82,03%	0,89	0,79	0,84
	Não Aedes		0,66	0,81	0,72
ResNet-50	Aedes	<b>86,71%</b>	0,93	<b>0,82</b>	<b>0,87</b>
	Não Aedes		<b>0,71</b>	<b>0,87</b>	<b>0,78</b>

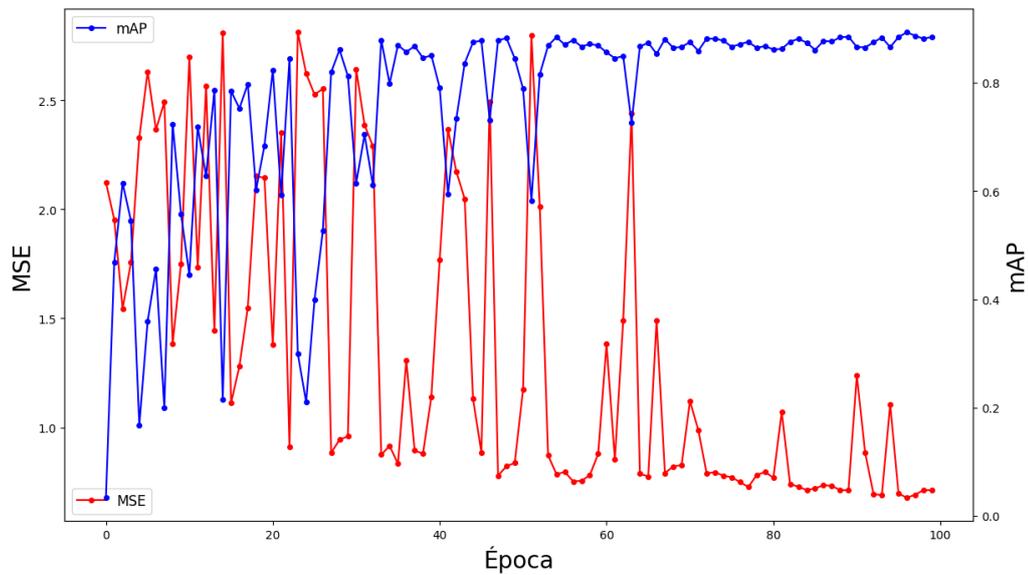
Fonte: Elaborado pelo autor

### 5.3 Detecção

Para o detector proposto, baseado no algoritmo YOLO, os resultados foram avaliados por meio da métrica mAP (*Mean Average Precision*). Essa métrica mede a qualidade geral do detector de objetos em relação às suas inferências e quanto maior o valor de mAP obtido por um detector, maior é a confiança em suas previsões e detecções.

A Figura 24 apresenta o comportamento do treinamento em relação a mAP@0.5, ao longo das 100 épocas. Adicionalmente, obteve-se o valor do erro quadrático médio (*Mean Squared Error* - MSE), o qual representa a capacidade do algoritmo de detectar o centro de um objeto e o quão assertiva a caixa delimitadora prevista cobre um objeto.

Figura 24 – mAP e MSE obtidos para o detector YOLO



Fonte: Elaborado pelo autor

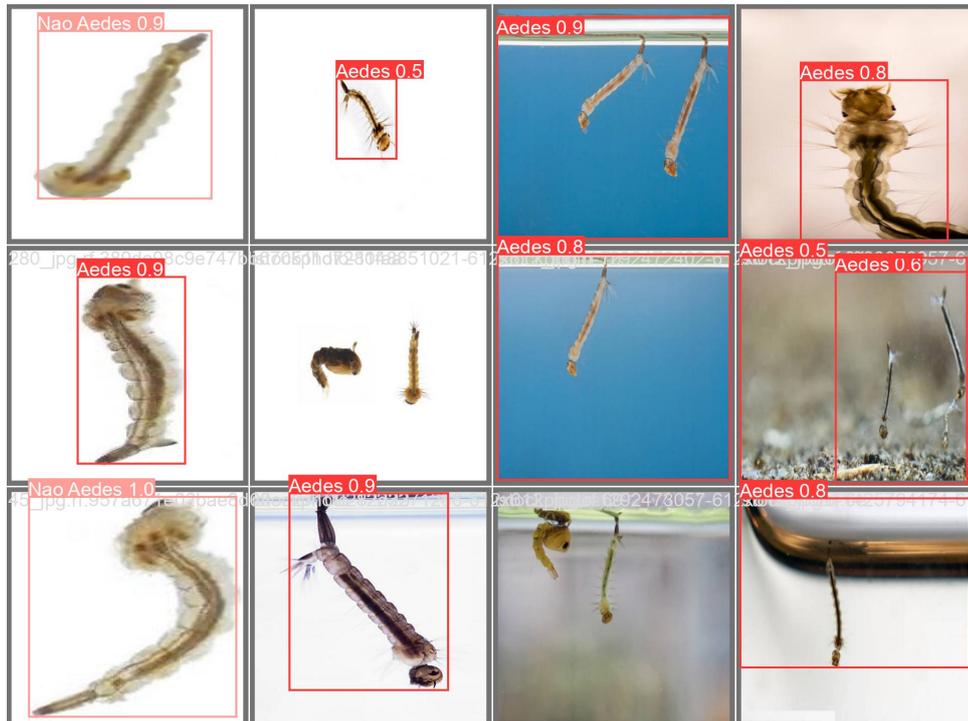
Para ambas as métricas, os valores oscilaram com maior frequência até a época 75. A partir dessa época os valores passaram a sofrer leves oscilações e convergiram para os seguintes valores finais: mAP@0.5 de 0.883 e MSE de 0.71133. A Tabela 6 apresenta as métricas detalhadas para cada classe e a Figura 25 apresenta um conjunto de classificações realizadas pela solução proposta para o dataset utilizado.

Tabela 6 – Resultados obtidos para o detector YOLO

Arquitetura	Classe	mAP	Prec.	Sens.
yolov8x.pt	Aedes	88,30%	0,879	0,667
	Não Aedes		0,995	1

Fonte: Elaborado pelo autor

Figura 25 – Classificações realizadas pelo detector YOLO



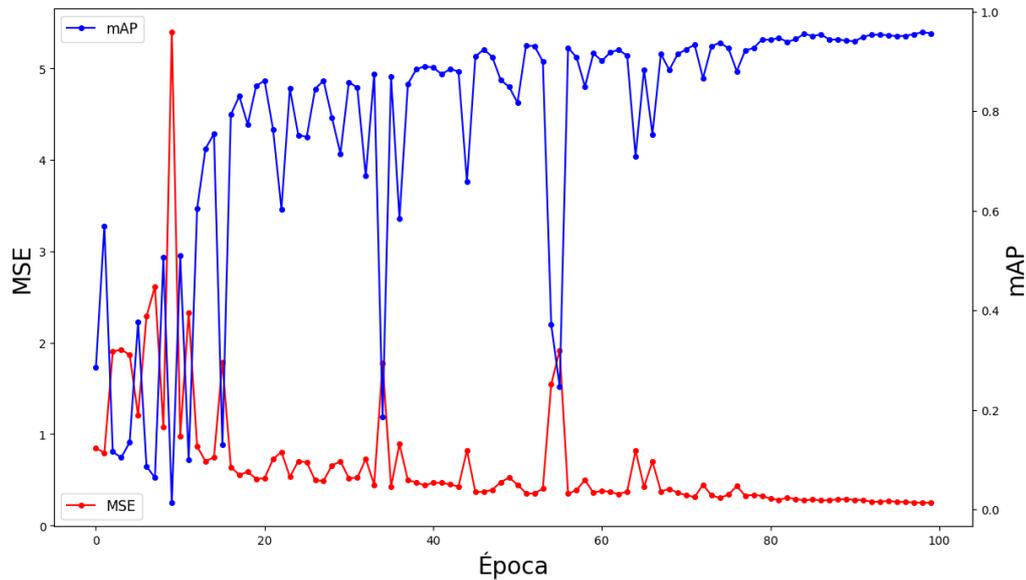
Fonte: Elaborado pelo autor

Ao analisar detalhadamente as detecções indicadas pelo modelo, Figura 24, é possível observar que duas imagens não foram classificadas nas classes indicadas para o dataset, Aedes e Não Aedes. Além disso, percebe-se que algumas caixas delimitadoras foram amplamente maiores que as larvas e ocupando grande parte da imagem, o que denota certa dificuldade para precisão em suas classificações.

## 5.4 Segmentação

De forma semelhante ao detector anterior, para a tarefa de detecção e segmentação, a Figura 26 ilustra o comportamento do treinamento em relação a mAP@0.5 e MSE, ao longo de 100 épocas. Inicialmente, até a época 65, os valores apresentam grandes variações de valores, sendo somente a partir a época 80 que os valores passaram a convergir.

Figura 26 – mAP e MSE obtidos para o detector YOLO com segmentação



Fonte: Elaborado pelo autor

Os valores finais alcançados foram de 0.957 para mAP@0.5 e 0.2109 para MSE, os quais denotam ampla capacidade de assertividade pelo algoritmo. A Tabela 7 detalha os valores alcançados para as métricas deste modelo.

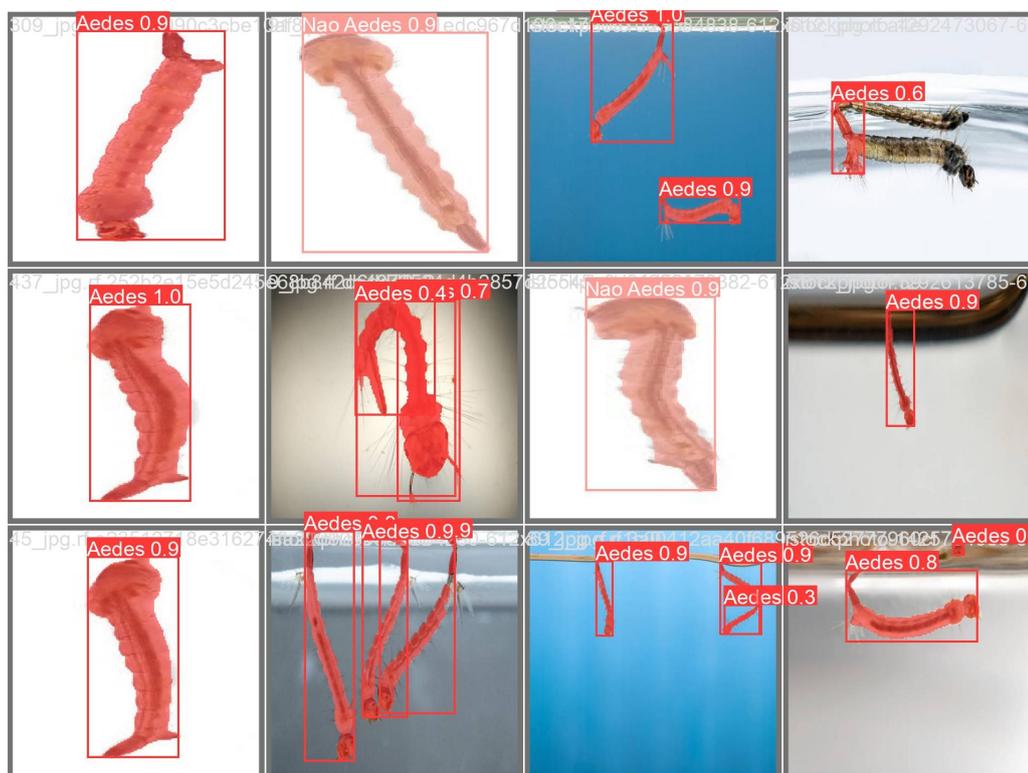
Tabela 7 – Resultados obtidos para o detector YOLO com segmentação

Arquitetura	Classe	mAP	Prec.	Sens.
yolov8s-seg.pt	Aedes	95,70%	0,946	0,94
	Não Aedes		1	0,966

Fonte: Elaborado pelo autor

Conforme pode ser observado na Figura 27, é possível constatar um conjunto de classificações realizadas pela modelo com a técnica de segmentação para as larvas do mosquito. Nota-se então que, em comparação ao modelo anterior, este modelo foi capaz realizar detecções mais precisas, com caixas delimitadores e regiões bem delimitadas. Contornando assim a dificuldade do modelo anterior.

Figura 27 – Classificações realizadas pelo modelo com segmentação



Fonte: Elaborado pelo autor

A predição deste modelo apresentou, além da maior precisão para o processo de classificação e detecção, a capacidade de identificação de múltiplas larvas e larvas parciais, como pode ser verificado na Figura 28.

Figura 28 – Classificações de múltiplas larvas pelo modelo com segmentação



Fonte: Elaborado pelo autor

## 5.5 Comparativo

Embora as algumas métricas para os modelos baseados em CNN e YOLO tenham sido distintas, a Tabela 8 fornece uma comparação entre os resultados obtidos para as soluções propostas. Em resumo, a acurácia é mais apropriada para tarefas de classificação e a métrica mAP é essencial para avaliar a qualidade das detecções de objetos em imagens. Ambas as métricas têm suas vantagens e limitações e, em problemas de detecção de objetos, uma alta mAP geralmente se reflete em uma acurácia relativamente alta, mas a mAP oferece uma avaliação mais completa e precisa da qualidade das detecções.

Tabela 8 – Métricas de avaliação obtidas em cada modelo

Modelo	Tarefa	Classe	Acurácia	mAP	Prec.	Sens.
VGG19	Classificação	Aedes	0.7031	-	<b>0,96</b>	0,64
		Não Aedes			0,22	0,81
Inception	Classificação	Aedes	0.8203	-	0,89	0,79
		Não Aedes			0,66	0,81
ResNet50	Classificação	Aedes	<b>0.8671</b>	-	0,93	<b>0,82</b>
		Não Aedes			<b>0,71</b>	<b>0,87</b>
yolov8x.pt	Detecção	Aedes	-	0.883	0,879	0,667
		Não Aedes			0,995	<b>1</b>
yolov8s-seg.pt	Detecção e Segmentação	Aedes	-	<b>0.957</b>	<b>0,946</b>	<b>0,94</b>
		Não Aedes			<b>1</b>	0,966

Fonte: Elaborato pelo autor

Por fim, através do comparativo acima, identificou-se que os modelos VGG19 e yolov8x.pt apresentaram os melhores resultados para a precisão da classe "Aedes" e Sensibilidade da classe "Não Aedes", respectivamente. No entanto, os modelos ResNet-50 e yolov8s-seg.pt (detector com segmentação) foram os que alcançaram os melhores desempenhos gerais, levando em consideração as métricas de avaliação utilizadas e tarefas indicadas neste trabalho.

## 5.6 Considerações Finais

Este capítulo apresentou os resultados dos modelos propostos para as tarefas de classificação, detecção e segmentação de larvas de mosquitos do gênero Aedes. Os resultados demonstraram que o modelo usando a CNN ResNet-50 foi o mais promissor para a tarefa de classificação em comparação ao das CNNs Inception e VGG19. Já entre os modelos usando o algoritmo YOLOv8, ambos se demonstraram promissores para as tarefas de detecção e segmentação, tendo o modelo com segmentação alcançado o maior desempenho e contornado dificuldades enfrentadas no detector sem esta técnica.

O capítulo seguinte, Capítulo 6, apresenta as considerações finais deste trabalho, possíveis as dificuldades encontradas durante seu desenvolvimento e aponta possíveis direcionamentos para pesquisas futuras.

## 6 Conclusões

Neste trabalho foram apresentados modelos voltados à tarefa de classificação, detecção e segmentação de larvas de mosquitos do gênero *Aedes*, tendo como base técnicas de visão computacional: redes neurais convolucionais e algoritmos de detecção de objetos. Para tanto, foram confeccionados modelos baseados nas CNNs VGG19, Inception e ResNet-50 e algoritmo de detecção de objetos (YOLO). As duas arquiteturas foram submetidas a um conjunto de treinamento próprio e com anotações manuais.

As principais métricas de avaliação utilizadas para validar as soluções foram a acurácia, para classificação, e mAP@0.5, para detecção e segmentação. Para a tarefa de classificação o modelo baseado na CNN ResNet-50 alcançou o melhor desempenho com acurácia de 86,71%. Já para as tarefas de detecção e segmentação, ambos os modelos se apresentaram promissores com os valores de 88,3% e 95,7% de mAP@0.5, respectivamente.

O modelo com segmentação conseguiu se apresentar como a solução mais promissora dado sua capacidade precisa para identificar as larvas dos mosquitos *Aedes* e a elevada mAP alcançada nos testes. Além disso, embora seja necessário aprimorar o detector e aumentar o tamanho do dataset, o resultado geral alcançado foi satisfatório para o propósito deste trabalho, com um nível razoável de precisão.

Pôde-se observar que os modelos conseguiram atingir o objetivo e se apresentaram como soluções promissoras direcionadas ao cenário de detecção e identificação de larvas de mosquitos *Aedes*. Portanto, a implementação dos modelos aliados a uma vasta rede de captura de imagens, pode auxiliar no rastreamento e monitoramento das populações e incidência de mosquitos em ambientes urbanos.

Com esses dados o poder público pode empregar ações para identificar áreas de alto risco e direcionar estratégias de controle de vetores de maneira mais assertiva. Essa abordagem, além de contribuir para a redução das doenças transmitidas por mosquitos *Aedes*, pode auxiliar na otimização dos esforços de controle através do emprego inteligente de recursos.

### 6.1 Trabalhos Futuros

Com o propósito de prosseguir com a pesquisa desenvolvida, a seguir são apresentadas potenciais direcionamentos para investigações futuras:

- Criação de um dataset com uma quantidade mais significativa de imagens de larvas do mosquito *Aedes*;

- Normalizar a quantidade de imagens para cada classe do conjunto de dados através da técnica de Aumentos de dados;
- Realizar uma investigação detalhada quanto a otimização dos hiperparâmetros para os modelos propostos, utilizando-se da biblioteca Keras;
- Desenvolver novos modelos com diferentes CNNs, principalmente para redes ResNets com profundidades superiores a 50;
- Desenvolver novos modelos com outros algoritmos de detecção de objetos;
- Aplicar estratégias de *ensemble* com a combinação dos resultados obtidos nos modelos, em busca de aprimorar o desempenho e a robustez da solução;
- Desenvolver uma solução *web* ou *mobile* disponível para testes junto ao público em geral;

## 6.2 Trabalhos Publicados

Publicações realizadas relativas à pesquisa durante o mestrado:

SILVA, R. C. Teixeira, C. A. M. Francês, C. R. L. Identificação de Larvas de Mosquitos do Gênero *Aedes* Utilizando Redes Neurais Convolucionais. In: IV Congresso Brasileiro Interdisciplinar em Ciência e Tecnologia. Anais do IV CoBICET-Resumo Expandido, online. [S.l.: s.n.], 2023.

SILVA, R. C. Teixeira, C. A. M. Francês, C. R. L. Modelo de Classificação e Detecção de Larvas de Mosquitos *Aedes* Usando YOLO. In: XIII Conferência Nacional em Comunicações, Redes e Segurança da Informação, 2023.

SILVA, R. C. Teixeira, C. A. M. Francês, C. R. L. Um Estudo Comparativo entre Redes Neurais Convolucionais e YOLO como Estratégias de Controle do *Aedes Aegypti*. In: XIII Conferência Nacional em Comunicações, Redes e Segurança da Informação, 2023.

## 6.3 Dificuldades Encontradas

Durante a realização deste estudo, alguns desafios foram enfrentados e estão elencados abaixo:

- O tamanho das larvas dos mosquitos do gênero *Aedes* é expressivamente reduzido, variando entre 2 a 8 mm de comprimento a depender do estágio. Logo, a qualidade da imagem se configurou como um fator imprescindível para que os modelos fossem capazes de extrair as características;

- A quantidade de imagens disponíveis para a temática estudada, em bases públicas, é assustadoramente ínfima em comparação com outras abordagens, como a detecção do inseto adulto;
- A maioria das imagens de larvas encontradas apresentaram características homogêneas, despertando um desafio ainda maior em localizar imagens para elevar a diversidade do dataset e elevar a capacidade de generalização dos modelos propostos;
- Embora hajam ferramentas que auxiliem o processo de anotação das imagens, este processo ainda é minucioso e, conseqüentemente, moroso;
- O ambiente de execução utilizado, Google Colaboratory, foi essencial para mitigar o custo computacional exigido para as etapas de treinamento. Porém, apesar de ser disponibilizada uma GPU para uso, há limitações de tempo de uso e demanda, ocasionando interrupções frequentes durante a execução dos testes.

# Referências

- ALMEIDA, L. d.; BORGES, M. V. d. S. Estudo comparativo de redes neurais convolucionais para a classificação da qualidade de imagens de documentos de identidade. 2021. Citado na página 15.
- AMINUDDIN, M. A. M. et al. Urban microclimate impacts on aedes mosquitoes' life cycle: A concept paper. *Environment-Behaviour Proceedings Journal*, v. 8, n. 25, 2023. Citado na página 7.
- ARRUDA, H. et al. Vosviewer and bibliometrix. *Journal of the Medical Library Association: JMLA*, Medical Library Association, v. 110, n. 3, p. 392, 2022. Citado na página 29.
- BACKES, A. *Deep Learning: Redes Neurais Convolucionais*. 2019. Disponível em: <<https://www.facom.ufu.br/~backes/pgc204/Aula11-RedesConvolucionais.pdf>>. Acesso em: 9 aug. 2023. Citado na página 16.
- BASODI, S. et al. Gradient amplification: An efficient way to train deep neural networks. *Big Data Mining and Analytics*, TUP, v. 3, n. 3, p. 196–207, 2020. Citado na página 19.
- BROCK, A. et al. High-performance large-scale image recognition without normalization. In: PMLR. *International Conference on Machine Learning*. [S.l.], 2021. p. 1059–1071. Citado na página 20.
- BRUNO, M. E. et al. Desenvolvimento de um modelo de classificação de imagens de larvas de mosquitos usando deep learning. Florianópolis, SC., 2023. Citado na página 2.
- CAPES, P. P. et al. Portal periódicos capes. Disponível em: <http://www.periodicos.capes.gov.br/ez88.periodicos.capes.gov.br/index.php>, 2020. Citado na página 29.
- CARRASCO-ESCOBAR, G. et al. High-accuracy detection of malaria vector larval habitats using drone-based multispectral imagery. *PLoS neglected tropical diseases*, Public Library of Science San Francisco, CA USA, v. 13, n. 1, p. e0007105, 2019. Citado 3 vezes nas páginas 8, 30 e 32.
- CASTRO, P. da S. et al. *Pesquisa e Inovação em Ciências da Saúde*. [S.l.]: Bookerfield Editora, 2022. Citado na página 1.
- CAVALLI, F. S. et al. Controlling the vector aedes aegypti and handling dengue fever bearing patients/control do vetor aedes aegypti e manejo dos pacientes com dengue. *Revista de Pesquisa Cuidado é Fundamental Online*, v. 11, n. 5, p. 1333–1339, 2019. Citado na página 8.
- CEVIDANES, A. et al. Invasive aedes mosquitoes in an urban—peri-urban gradient in northern spain: evidence of the wide distribution of aedes japonicus. *Parasites & Vectors*, BioMed Central, v. 16, n. 1, p. 1–10, 2023. Citado na página 6.
- CHEN, R. E.; DIAMOND, M. S. Dengue mouse models for evaluating pathogenesis and countermeasures. *Current opinion in virology*, Elsevier, v. 43, p. 50–58, 2020. Citado na página 4.

- CONSTANT, L. E. et al. Overview on chikungunya virus infection: from epidemiology to state-of-the-art experimental models. *Frontiers in Microbiology*, Frontiers, v. 12, p. 744164, 2021. Citado na página 6.
- CUNHA, L. C. d. Redes neurais convolucionais e segmentação de imagens: uma revisão bibliográfica. 2020. Citado 2 vezes nas páginas 16 e 17.
- DIAS, Í. K. R. et al. Ações educativas de enfrentamento ao aedes aegypti: revisão integrativa. *Ciência & Saúde Coletiva*, SciELO Brasil, v. 27, p. 231–242, 2022. Citado na página 8.
- DIAS, L. O. et al. *Vigilância sindrômica: estudo epidemiológico da doença febril aguda em casos suspeitos de arboviroses no estado do Rio de Janeiro*. Tese (Doutorado) — Instituto Oswaldo Cruz, 2020. Citado na página 4.
- DOURADO, J. de M.; ARAÚJO, C. S. de; GODÓI, I. P. D. Hospitalizações, óbitos e gastos com dengue entre 2000 e 2015 na região norte do Brasil. *Revista Brasileira Interdisciplinar de Saúde*, 2020. Citado na página 5.
- DWYER, B. et al. *Roboflow (version 1.0)[software]*. 2022. Citado na página 35.
- DYGALO, V.; LYASHENKO, M.; POTAPOV, P. Ways for improving efficiency of computer vision for autonomous vehicles and driver assistance systems. In: *2019 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*. [S.l.: s.n.], 2019. p. 1–5. Citado na página 11.
- ECK, N. J. V.; WALTMAN, L. Vosviewer manual. *Manual for VOSviewer version*, v. 1, n. 0, 2011. Citado na página 29.
- FERNANDES, M. S.; CORDEIRO, W.; RECAMONDE-MENDOZA, M. Detecting aedes aegypti mosquitoes through audio classification with convolutional neural networks. *Computers in Biology and Medicine*, Elsevier, v. 129, p. 104152, 2021. Citado na página 1.
- GARCIA, P. S. C. et al. Acquisition of digital images and identification of aedes aegypti mosquito eggs using classification and deep learning. In: *2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. [S.l.: s.n.], 2019. p. 47–53. Citado 2 vezes nas páginas 31 e 32.
- HASNAIN, M. et al. Evaluating trust prediction and confusion matrix measures for web services ranking. *IEEE Access*, IEEE, v. 8, p. 90847–90861, 2020. Citado na página 26.
- HOSSAIN, M. S. et al. Aedes larva detection using ensemble learning to prevent dengue endemic. *BioMedInformatics*, MDPI, v. 2, n. 3, p. 405–423, 2022. Citado 3 vezes nas páginas 7, 32 e 35.
- HUBALDE, A. M.; PADILLA, D. A.; SANTOS, D. A. C. A yolo-based approach for aedes aegypti larvae classification and detection. In: *2021 6th International Conference on Image, Vision and Computing (ICIVC)*. [S.l.: s.n.], 2021. p. 161–167. Citado 2 vezes nas páginas 31 e 32.
- IKECHUKWU, A. V. et al. Resnet-50 vs vgg-19 vs training from scratch: A comparative analysis of the segmentation and classification of pneumonia from chest x-ray images. *Global Transitions Proceedings*, Elsevier, v. 2, n. 2, p. 375–381, 2021. Citado na página 19.

- IQBAL, H. *HarisIqbal88/PlotNeuralNet v1.0.0*. Zenodo, 2018. Disponível em: <<https://doi.org/10.5281/zenodo.2526396>>. Citado na página 20.
- IRUNGU, J. et al. A cnn transfer learning-electrocardiogram (ecg) signal approach to predict covid-19. In: IEEE. *2023 15th International Conference on Computer and Automation Engineering (ICCAE)*. [S.l.], 2023. p. 367–371. Citado na página 24.
- JOCHER, G. et al. *ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation*. Zenodo, 2022. Disponível em: <<https://doi.org/10.5281/zenodo.7347926>>. Citado na página 24.
- KANJEE, R. *Beginner's Guide To Object Detection*. 2021. Disponível em: <<https://www.linkedin.com/pulse/beginners-guide-object-detection-ritesh-kanjee/>>. Acesso em: 10 aug. 2023. Citado 2 vezes nas páginas 12 e 20.
- KATHURIA, A. *How to implement a YOLO (v3) object detector from scratch in PyTorch: Part 1*. 2018. Disponível em: <<https://blog.paperspace.com/how-to-implement-a-yolo-object-detector-in-pytorch/>>. Acesso em: 9 aug. 2023. Citado na página 21.
- KHAN, M. S. M. et al. Cataract detection using convolutional neural network with vgg-19 model. In: IEEE. *2021 IEEE World AI IoT Congress (AIIoT)*. [S.l.], 2021. p. 0209–0212. Citado na página 19.
- KHONGWICHIT, S. et al. Chikungunya virus infection: molecular biology, clinical characteristics, and epidemiology in asian countries. *Journal of Biomedical Science*, BioMed Central, v. 28, n. 1, p. 1–17, 2021. Citado na página 6.
- KITTICHAJ, V. et al. Deep learning approaches for challenging species and gender identification of mosquito vectors. *Scientific reports*, Nature Publishing Group UK London, v. 11, n. 1, p. 4838, 2021. Citado 2 vezes nas páginas 31 e 32.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, 2012. Citado na página 17.
- KUBO, H. K. L. et al. Impacto da pandemia do covid-19 no serviço de saúde: uma revisão de literatura. *InterAmerican Journal of Medicine and Health*, v. 3, 2020. Citado na página 4.
- KUMAR, S. et al. Human-inspired camera: A novel camera system for computer vision. In: *2021 18th International SoC Design Conference (ISOCC)*. [S.l.: s.n.], 2021. p. 29–30. Citado na página 10.
- LIN, T.-Y. et al. *Microsoft COCO: Common Objects in Context*. 2015. Citado na página 25.
- LIU, Z. et al. Deep learning framework based on integration of s-mask r-cnn and inception-v3 for ultrasound image-aided diagnosis of prostate cancer. *Future Generation Computer Systems*, Elsevier, v. 114, p. 358–367, 2021. Citado na página 18.
- LÖWY, I. *Zika no Brasil: história recente de uma epidemia*. [S.l.]: SciELO-Editora FIOCRUZ, 2019. Citado na página 5.

- MARTÍNEZ, M. P. Desenvolvimento de um sistema automático de classificação de documentos com base em modelos de machine learning. 2022. Citado na página 11.
- MATHWORKS. *Transfer Learning*. 2019. Disponível em: <<https://www.mathworks.com/discovery/transfer-learning.html>>. Acesso em: 12 nov. 2019. Citado 2 vezes nas páginas 24 e 25.
- MEENA, A. R. Review on surveillance and bionomics of (aedes mosquitoes) dengue vectors. *Int. J. Entomol. Res*, v. 5, p. 78–81, 2020. Citado na página 8.
- MEIRELLES, A. L. S. Aprendizado ativo efetivo e eficiente para análise de imagens em patologia utilizando aprendizado profundo. 2023. Citado na página 13.
- MOHAN, R.; ARUNMOZHI, R.; RAJINIKANTH, V. Deep-learning segmentation and recognition of tooth in thresholded panoramic x-ray. In: *2023 Winter Summit on Smart Computing and Networks (WiSSCoN)*. [S.l.: s.n.], 2023. p. 1–5. Citado na página 24.
- MONTANARI, R. *Detecção e classificação de objetos em imagens para rastreamento de veículos*. Tese (Doutorado) — Universidade de São Paulo, 2016. Citado na página 20.
- MORAIS, K. V. R. et al. As doenças emergentes e reemergentes e seus determinantes. *Brazilian Journal of Health Review*, v. 3, n. 4, p. 11227–11241, 2020. Citado na página 4.
- MOREIRA, D. C. I.; FEITOSA, G. A.; ABREU, C. R. de C. As doenças virais no mundo contemporâneo: uma revisão bibliográfica. *Revista JRG de Estudos Acadêmicos*, v. 5, n. 10, p. 247–257, 2022. Citado na página 1.
- MORID, M. A.; BORJALI, A.; FIOL, G. D. A scoping review of transfer learning research on medical image analysis using imagenet. *Computers in biology and medicine*, Elsevier, v. 128, p. 104115, 2021. Citado na página 25.
- NAYAK, D. R. et al. Deep extreme learning machine with leaky rectified linear unit for multiclass classification of pathological brain images. *Multimedia Tools and Applications*, Springer, v. 79, p. 15381–15396, 2020. Citado na página 15.
- NAYAK, S. R. et al. Application of deep learning techniques for detection of covid-19 cases using chest x-ray images: A comprehensive study. *Biomedical Signal Processing and Control*, Elsevier, v. 64, p. 102365, 2021. Citado na página 17.
- NEPOMUCENO, D. B.; BACHUR, T. P. R. *Atualidades em parasitologia humana*. [S.l.]: Amplla Editora, 2022. Citado na página 8.
- NUNES, V. d. S. Tópicos em visão computacional: uma revisão sistemática com aplicações em economia 4.0. Serra, 2023. Citado na página 11.
- Objax Developers. *Objax*. 2020. Disponível em: <<https://github.com/google/objax>>. Citado na página 19.
- OLIVATTO, T. F. Identificação automática de rampas de acessibilidade apoiada por visão computacional a partir de imagens panorâmicas street-level. Universidade Federal de São Carlos, 2021. Citado na página 11.
- PADILLA, R.; NETTO, S. L.; SILVA, E. A. D. A survey on performance metrics for object-detection algorithms. In: IEEE. *2020 international conference on systems, signals and image processing (IWSSIP)*. [S.l.], 2020. p. 237–242. Citado na página 26.

- PENG, J. et al. Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from ct imaging. *European radiology*, Springer, p. 1–12, 2019. Citado na página 14.
- PEREIRA, V. S.; SILVA, B. N. da. Saúde pública: princípios e práticas. *Livros da Editora Integrar*, 2023. Citado na página 6.
- QI, J. et al. On mean absolute error for deep neural network based vector-to-vector regression. *IEEE Signal Processing Letters*, IEEE, v. 27, p. 1485–1489, 2020. Citado na página 28.
- QUEIROZ, S. M. S. Estratégias e prática de combate ao surto do zika vírus: uma revisão integrativa. 2020. Citado na página 5.
- REDMON, J. et al. *You Only Look Once: Unified, Real-Time Object Detection*. 2016. Citado na página 22.
- REIS, D. et al. *Real-Time Flying Object Detection with YOLOv8*. 2023. Citado na página 35.
- REIS, G. et al. Avaliação de técnicas de detecção de pedestres para veículos autônomos. In: SBC. *Anais do XXII Workshop em Desempenho de Sistemas Computacionais e de Comunicação*. [S.l.], 2023. p. 61–72. Citado na página 22.
- REZA, S. R.; DONG, X.; QIAN, L. Robust face mask detection using deep learning on iot devices. In: IEEE. *2021 IEEE International Conference on Communications Workshops (ICC Workshops)*. [S.l.], 2021. p. 1–6. Citado na página 17.
- ROCHA, J. D. C. et al. A platform for monitoring student commuting in the use of school transport in smart cities - a facial recognition based approach. In: *2023 International Conference on Smart Applications, Communications and Networking (SmartNets)*. [S.l.: s.n.], 2023. p. 1–6. Citado na página 10.
- SANTOS, P. A. d. et al. Aprendizagem investigativa sobre a dengue empregando a educação steam e métodos ativos no ensino médio. Universidade Federal de Mato Grosso, 2020. Citado na página 5.
- SCHABAT, F. M.; BUSATO, M. A. et al. Políticas e práticas de controle de aedes aegypti: Percepções de agentes de combate a endemias. *Interfaces Científicas-Saúde e Ambiente*, v. 9, n. 2, p. 292–302, 2023. Citado na página 2.
- SILVA, G. M. et al. Desafios para o desenvolvimento de vacinas contra a dengue na atualidade: Uma problemática em saúde pública. *Brazilian Journal of Case Reports*, v. 2, n. Suppl. 3, p. 106–111, 2022. Citado na página 5.
- SILVA, R. d. C. Open Source Dataset, *Larvae Aedes Segmentation Yolo Dataset*. Roboflow, 2023. <<https://universe.roboflow.com/ufpa-4qzhl/larvae-aedes-segmentation-yolo>>. Visited on 2023-09-26. Disponível em: <<https://universe.roboflow.com/ufpa-4qzhl/larvae-aedes-segmentation-yolo>>. Citado na página 35.
- SILVA, R. d. C.; JUNIOR, J. J. H. F.; FRANCES, C. R. L. Aplicação de redes neurais convolucionais em imagens de tomografia computadorizada para o pré-diagnóstico de doenças respiratórias agudas: Covid-19 e pneumonia viral. *Anais do Congresso Brasileiro Interdisciplinar em Ciência e Tecnologia*, v. 4, aug 2023. Citado na página 11.

- SILVA, R. d. C. et al. Identificação de larvas de mosquitos do gênero aedes utilizando redes neurais convolucionais. In: . [S.l.: s.n.], 2023. Citado na página 36.
- SILVA, W. D. M. D.; JAYALAL, S. Dengue mosquito larvae identification using digital images. In: *2020 International Research Conference on Smart Computing and Systems Engineering (SCSE)*. [S.l.: s.n.], 2020. p. 31–36. Citado 2 vezes nas páginas 31 e 32.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. Citado na página 18.
- SOCIETY, S. C. *Simplifying the Difference: Machine Learning vs Deep Learning*. 2020. Disponível em: <<https://www.scs.org.sg/articles/machine-learning-vs-deep-learning>>. Acesso em: 19 aug. 2023. Citado 3 vezes nas páginas 9, 10 e 14.
- SOUSA, S. S. da S. et al. Características clínicas e epidemiológicas das arboviroses epidêmicas no Brasil: Dengue, chikungunya e zika. *Revista Eletrônica Acervo Saúde*, v. 23, n. 7, p. e13518–e13518, 2023. Citado na página 4.
- SOUZA, J. A. C. de et al. Acurácia das métricas de validação da classificação de imagens. Universidade Federal de Minas Gerais, 2020. Citado na página 26.
- SURYA, A. et al. A mosquito is worth 16x16 larvae: Evaluation of deep learning architectures for mosquito larvae classification. *arXiv preprint arXiv:2209.07718*, 2022. Citado 2 vezes nas páginas 31 e 32.
- SZEGEDY, C. et al. Going deeper with convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 1–9. Citado na página 17.
- TERVEN, J.; CORDOVA-ESPARZA, D. A comprehensive review of yolo: From yolov1 to yolov8 and beyond. *arXiv preprint arXiv:2304.00501*, 2023. Citado na página 22.
- VADERA, S.; AMEEN, S. Methods for pruning deep neural networks. *IEEE Access*, IEEE, v. 10, p. 63280–63300, 2022. Citado na página 14.
- VALLE, D. et al. *Aedes de A a Z*. [S.l.]: SciELO-Editora FIOCRUZ, 2021. Citado 2 vezes nas páginas 1 e 8.
- VAZ, G. C. Aplicação de modelos de deep learning para qualificação da área da engenharia biomédica: Um estudo de caso de visão computacional em imagens de raio-x da região torácica. 2023. Citado na página 11.
- VIEGAS, L. L.; VENTURA, D. d. F. L.; NUNES, J. Uma leitura crítica das emergências em saúde global: o caso da epidemia de zika de 2016. *Ciencia & saúde coletiva*, SciELO Brasil, v. 27, p. 4075–4084, 2022. Citado na página 4.
- WERMELINGER, E. D. Reflexões sobre a profilaxia dos arbovírus na América Latina. *Revista Panamericana de Salud Pública*, Pan American Health Organization, v. 43, 2019. Citado na página 1.
- YAMAZAKI, M. et al. Yet another accelerated sgd: Resnet-50 training on imagenet in 74.7 seconds. *arXiv preprint arXiv:1903.12650*, 2019. Citado na página 20.

- ZAVADZKI, S. et al. Computational intelligence techniques used for stock market prediction: a systematic review. *IEEE Latin America Transactions*, IEEE, v. 18, n. 04, p. 744–755, 2020. Citado na página 10.
- ZHANG, A. et al. Dive into deep learning. *arXiv preprint arXiv:2106.11342*, 2021. Citado 3 vezes nas páginas 15, 16 e 18.
- ZHENG, W. et al. Se-ssd: Self-ensembling single-stage object detector from point cloud. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2021. p. 14494–14503. Citado na página 27.
- ZULFA, R. et al. Updating the insecticide resistance status of aedes aegypti and aedes albopictus in asia: a systematic review and meta-analysis. *Tropical Medicine and Infectious Disease*, MDPI, v. 7, n. 10, p. 306, 2022. Citado na página 1.