

UNIVERSIDADE FEDERAL DE SANTA CATARINA - CENTRO TECNOLÓGICO
DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA

**Desenvolvimento de um Modelo de Classificação de Imagens de Larvas
de Mosquitos usando *Deep Learning***

Bruno Manarin Espíndola

Florianópolis

2023

Universidade Federal de Santa Catarina
Departamento de Informática e Estatística

Desenvolvimento de um Modelo de Classificação de Imagens de Larvas de Mosquitos usando *Deep Learning*

Trabalho de Conclusão de Curso de Graduação em Sistemas de Informação, do Departamento de Informática e Estatística, do Centro Tecnológico da Universidade Federal de Santa Catarina, requisito parcial à obtenção do título de Bacharel em Sistemas de Informação.

Autor: Bruno Manarin Espíndola

Orientadora: Prof.^a Dr.^a rer. nat. Christiane Gresse von Wangenheim, PMP

Florianópolis

2023

RESUMO

A dengue é uma doença endêmica que somou mais de dois milhões de casos no continente americano no ano de 2022. Portanto, o controle da doença é essencial para o bem-estar da população. Um dos métodos mais eficazes contra a dengue é impedir a formação de criadouros do mosquito *Aedes aegypti*, vetor da doença. Campanhas de saúde pública que alertam a população sobre os perigos de deixar recipientes com água parada em suas casas ajudam na prevenção dos criadouros. No entanto, a identificação dos criadouros de mosquito ainda é um problema, pois a população muitas vezes não possui conhecimento suficiente para distinguir se as larvas encontradas são, de fato, do mosquito vetor da dengue.

Uma possível solução para esse problema é o desenvolvimento de um modelo utilizando *deep learning* (DL) que identifica a espécie dos mosquitos por meio de fotos das larvas. Já existem modelos de DL que classificam larvas, principalmente distinguindo apenas entre *Aedes* vs. não *Aedes*. No entanto, em alguns casos, esses modelos possuem níveis de acurácia muito baixos, além de serem desenvolvidos especificamente para imagens de microscópio. Assim, o objetivo geral deste trabalho é desenvolver um modelo de classificação de imagens de larvas de mosquitos capaz de distinguir larvas de *Aedes aegypti*, *Aedes albopictus* e *Culex sp.* Serão adotadas técnicas de *deep learning* para automatizar a classificação a partir de fotos de larvas tiradas com a câmera do celular.

Como parte do trabalho, foi criado um conjunto de imagens de larvas de mosquitos em parceria com o Laboratório de Transmissores de Hematozoários da UFSC e a Coordenação de Referência Laboratorial (CRLAB/LACEN/SC). São realizados experimentos com diferentes modelos de redes neurais, como o EfficientNetB0 e o ResNet18, para comparar seu desempenho. Os resultados obtidos revelaram uma acurácia de 90,5%, demonstrando que esses modelos foram os mais eficazes. Com isso, espera-se contribuir para a prevenção da dengue.

ABSTRACT

Dengue is an endemic disease that accounted for over two million cases in the American continent in 2022. Therefore, controlling the disease is essential for the well-being of the population. One of the most effective methods against dengue is to prevent the breeding of the *Aedes aegypti* mosquito, the disease vector. Public health campaigns that alert the population about the dangers of leaving containers with stagnant water in their homes help in preventing breeding sites. However, the identification of mosquito breeding sites is still a problem, as the population often lacks sufficient knowledge to determine if the found larvae are indeed those of the dengue vector mosquito.

One possible solution to this problem is the development of a model using deep learning (DL) that identifies the species of mosquitoes through photos of the larvae. DL models already exist that classify *larvae*, primarily distinguishing between *Aedes* vs. *non-Aedes*. However, in some cases, these models have very low levels of accuracy, as they are specifically developed for microscope images. Therefore, the general objective of this work is to develop a model for classifying images of mosquito larvae capable of distinguishing *Aedes aegypti*, *Aedes albopictus*, and *Culex sp. larvae*. *Deep learning* techniques will be adopted to automate the classification using photos of *larvae* taken with a mobile phone camera.

As part of the work, a set of mosquito *larvae* images was created in partnership with the Laboratory of Hematozoan Transmitters at UFSC and the Reference Laboratory Coordination (CRLAB/LACEN/SC). Experiments are conducted with different neural network models to compare their performance, such as EfficientNetB0 and ResNet18. The results obtained revealed an accuracy of 90.5%, indicating that these models were the most effective for the given task. This is expected to contribute to the prevention of dengue.

LISTA DE FIGURAS

Figura 1 - Comparativo de casos confirmados de dengue em 2019,2020,2021 e 2022 no Brasil.	6
Figura 2 - Casos de dengue por população de 100.000 no período janeiro-março de 2023	12
Figura 4 - Mapa de casos de dengue em Santa Catarina	14
Figura 5 - Casos de dengue em Florianópolis por semana epidemiológica	14
Figura 6 - O ciclo de vida dos mosquitos usando o mosquito doméstico comum (“pernilongo”) como exemplo.	15
Figura 7 - Estádio larval do Aedes aegypti	16
Figura 8 - Diferenças na morfologia dos ovos e larvas de diferentes gêneros de mosquito.	19
Figura 9 - Estrutura e camadas de uma rede neural profunda	23
Figura 10 - Visão geral do processo iterativo de ML centrado em humanos	24
Figura 11 - Camadas de uma CNN	26
Figura 12 - Arquiteturas e desempenhos das ResNets com o ImageNet	27
Figura 13 - Resnet-34	28
Figura 14 - Convolução separável em profundidade	29
Figura 15 - Arquitetura do MobileNet.	30
Figura 16 - Diferentes métodos de dimensionamento versus dimensionamento composto	31
Figura 17 - Exemplo de matriz de confusão.	33
Figura 18 - Tamanho dos modelos vs. Acurácia.	34
Figura 19 - Comparação da acurácia e tamanho de modelos.	35
Figura 20 - Quantidade de artigos relevantes ao assunto publicados nos últimos 10 anos.	43
Figura 21 - Pesquisas separadas por espécie/gênero de mosquitos	44
Figura 22 - Quantidade de imagens no conjunto de dados por pesquisa	47

LISTA DE TABELAS

Tabela 1 - Diferenças morfológicas na cabeça das larvas de mosquitos de diferentes espécies	20
Tabela 2 - Diferenças morfológicas do tórax das larvas de mosquitos de diferentes espécies	20
Tabela 3 - Diferenças morfológicas no sifão das larvas de mosquitos de diferentes espécies	21
Tabela 4 - Termos de busca utilizados no protocolo de revisão	39
Tabela 5 - String de busca para cada fonte.	39
Tabela 6 - Número de artigos identificados por repositório e por fase de seleção.	
Tabela 7 - Informações sobre os dados encontrados nas pesquisas	46
Tabela 8 - Informações sobre o treinamento dos trabalhos encontrados	49
Tabela 9 - Métricas de avaliação dos trabalhos encontrados	50
Tabela 10 - Requisitos para desenvolver um modelo de Machine Learning	53
Tabela 11 - Objetivo, risco e requisitos de um modelo de Machine Learning	54
Tabela 12 - Conjunto de dados coletados para o treinamento dos modelos	55
Tabela 13 - Exemplos de imagens coletadas no conjunto de dados separadas por categoria	55
Tabela 14 - Resultado dos treinamentos de diferentes modelos	74
Tabela 15 - Resultado da validação dos modelos	74

SUMÁRIO

1. Introdução	8
1.1 Contextualização	8
1.2 Objetivos	10
1.2.1 Objetivo geral	10
1.2.3 Objetivos Específicos	10
1.2.4 Premissas e restrições	11
1.3. Metodologia de pesquisa	11
1.3.1 Etapa 1 – Fundamentação teórica	11
1.3.2 Etapa 2 – Estado da arte	11
1.3.3 Etapa 3 – Desenvolvimento do modelo de deep learning	11
1.4 Estrutura do documento	12
2. Fundamentação Teórica	14
2.1 Dengue e Espécies de Mosquitos	14
2.1.1 Dengue	14
2.1.2 Ciclo de vida dos mosquitos	16
2.1.3 Morfologia das larvas dos mosquitos	19
2.2 Classificação de Imagens com Deep Learning	24
2.2.1 Visão Geral	24
2.2.2 Processo de Desenvolvimento de Deep Learning	25
2.2.3 Tipos de redes neurais para classificação de imagens	27
2.2.3.1 ResNets	28
2.2.3.2 MobileNet	31
2.2.2.3 EfficientNet	33
2.2.2.4 Comparação do desempenho padrão de modelos	35
3. Estado da arte	38
3.1 Definição Do Protocolo De Revisão	38
3.2. Execução Da Busca	40
3.3 Resultados Da Revisão	41
3.1.1 Quais Extensões Existem?	42
3.1.2. Quais as características do conjunto de dados?	46
3.1.3. Como os modelos foram treinados?	49
3.1.4. Quais os desempenhos relatados?	50
3.4 Discussão	51
4. Desenvolvimento de modelo de classificação de larvas de mosquito	53
4.1 Requisitos	53
4.2 Preparação de dados	54
4.3 Treinamento	56
4.3.1 Treinamento com MobileNetv3	57
4.3.2 Treinamento com ResNet18	59
4.3.3 Treinamento com ResNet34	61
4.3.4 Treinamento com EfficientNetLite	63
4.3.5 Treinamento com EfficientNetB0	65

4.4 Testes de desempenho	66
4.4.1 Preparação do teste	67
4.4.2 Resultado dos testes com MobileNetV3	69
4.4.3 Resultado dos testes com Resnet18	70
4.4.4 Resultado dos testes Resnet34	71
4.4.5 Resultado dos testes EfficientNetLite	72
4.4.6 Resultado dos testes EfficientNetB0	73
4.5 Discussão	74
5. Conclusão	76
Cronograma	78
REFERÊNCIAS	78


1. Introdução

Este capítulo tem como objetivo apresentar uma contextualização sobre o que será apresentado no trabalho, assim como objetivos e metodologias de pesquisas utilizadas.

1.1 Contextualização

A dengue é uma doença febril aguda, causada por vírus, que é transmitido principalmente pelo *Aedes aegypti*, mosquito que também transmite a febre chikungunya e o zika vírus (KULARATNE, 2015). A transmissão se dá pela picada da fêmea deste mosquito infectado pelo vírus, que afeta as células musculares e os glóbulos brancos dos seres humanos, causando a doença (KULARATNE, 2015). A dengue pode ser grave, apresentando sintomas como febre, dor nas articulações e manchas pelo corpo (KULARATNE, 2015).

É uma doença endêmica nas Américas, África, Ásia e Oceania. A Organização Mundial da Saúde estima que, anualmente, ocorram 50 a 100 milhões de casos, sendo que 500 mil a 1 milhão desenvolvem a forma grave, que pode ser fatal (PAHO, 2020). No Brasil, a dengue é um problema de saúde pública. De acordo com o Ministério da Saúde, aproximadamente 544 mil casos foram registrados em 2021 e uma alta de 165,7% dos casos confirmados até maio de 2022 (MS, 2022).



Fonte: Sinan Online (banco de dados atualizado em 2/1/2023). Dados sujeitos a alteração.

*Dados referentes a SE 52.

Figura 1: Comparativo de casos confirmados de dengue em 2019,2020,2021 e 2022 no Brasil.

Fonte: (SINAN Online, 2023)

Em Santa Catarina, segundo o informe epidemiológico do governo do Estado, no período de 02 de janeiro a 01 de dezembro de 2022, foram identificados mais de 141.392 casos de dengue, com mais de 130 municípios considerados infestados até novembro (DIVE, 2023). Florianópolis é uma das situações graves, sendo dengue considerada uma epidemia na cidade (DIVE, 2023).

Estes dados indicam a importância da prevenção da doença para o bem-estar da população. Uma das formas de prevenção é a eliminação dos focos de larvas. Focos de larvas podem ser encontrados em depósitos naturais e recipientes com água parada, onde possibilitam a reprodução do mosquito. Vasos de flores, pneus, recipientes expostos à chuva são alguns dos exemplos de potenciais focos de dengue. Sendo assim, um dos atores importantes no controle à doença é a própria população, que evita que focos sejam formados nas residências e identificam acúmulos existentes.

Um dos fatores que agravam a proliferação das larvas é a falta de conhecimento da população em relação aos mosquitos (FUNASA, 2001). Nem sempre as larvas encontradas pela população são de *Aedes aegypti*. As regiões urbanas em Santa Catarina também concentram criadouros de *Aedes albopictus* ou mosquitos do gênero *Culex*, por exemplo. Por isso, a classificação morfológica das larvas de mosquitos pode ajudar na prevenção e controle desses focos.

O *Aedes* é um gênero de inseto holometábolo, ou seja, os mosquitos transmissores da doença passam pelo processo completo da metamorfose: ovos, larva, pupa, e fase adulta. A fase mais propícia para a determinação da espécie destes mosquitos pode ser a larval, já que tem diferenças morfológicas distintivas e visíveis, é de fácil coleta quando comparado a fase adulta e pode ser uma das fases mais duradouras da vida do inseto dependendo as condições climáticas onde se encontra (MARINHO et al., 2016).

Características anatômicas da larva, cor, cílios, comprimento do tubo de respiração, posicionamento na água são fatores levados em consideração para a caracterização do inseto, como é o caso da diferenciação de mosquitos dos gêneros *Culex* e *Aedes*. Normalmente é necessário a consulta a um especialista para se determinar se o foco encontrado é realmente de mosquitos da dengue com base numa análise no microscópio (GLOBE, 2022).

Uma solução alternativa pode ser a criação de um aplicativo móvel baseado em aprendizado de máquina que possibilita a classificação de modo eficaz por meio de uma fotografia de uma larva de mosquito encontrada pelo usuário. Isso faria com que o diagnóstico fosse rápido e acessível, além de não requerer conhecimento prévio sobre morfologia dos mosquitos por parte do cidadão que utilizará a ferramenta.

Já existem propostas para a criação de modelos de *Machine Learning (ML)* que são capazes de realizar esse tipo de reconhecimento e classificação morfológica das larvas, como, por exemplo, apresentado por de Silva, Jaylal (2020). Porém, nenhum desses modelos foram desenvolvidos no Brasil, além do mais, os modelos existentes não contam com a funcionalidade de um app inteligente que permite o manuseio por um cidadão não instruído.

Assim o objetivo do presente estudo é identificar se é possível o desenvolvimento de um aplicativo móvel inteligente que consegue de forma fácil classificar larvas dos mosquitos *Aedes aegypti*, *Aedes albopictus* e *Culex* por meio de fotos com um grau de precisão de no mínimo 95%.

1.2 Objetivos

Objetivo geral

O objetivo geral deste trabalho é desenvolver um modelo de classificação de imagens de larvas de mosquitos para classificar larvas de *Aedes aegypti*, *Aedes albopictus* e *Culex*. São adotadas técnicas de *deep learning* para automatizar a classificação a partir de fotos de larvas tiradas com a câmera do celular. Espera-se com um grau de acurácia de no mínimo 95%.

Objetivos Específicos

- O1.** Analisar a fundamentação teórica sobre mosquitos/dengue e *deep learning*.
- O2.** Analisar o estado da arte em relação a classificação de larvas de mosquito com *deep learning*.
- O3.** Desenvolver e avaliar um modelo utilizando *deep learning* para a classificação de larvas de mosquito.

Premissas e restrições

O trabalho é realizado de acordo com o regulamento vigente do Departamento de Informática e Estatística (INE – UFSC) em relação aos Trabalhos de Conclusão de Curso. O estudo realizado será limitado à classificação de larvas de *Aedes aegypti*, *Aedes albopictus* e *Culex*. Larvas de outras espécies de mosquito não serão consideradas.

1.3. Metodologia de pesquisa

A metodologia de pesquisa utilizada neste trabalho é dividida nas seguintes etapas:

Etapa 1 – Fundamentação teórica

Estudando, analisando e sintetizando os conceitos principais e a teoria referente aos temas a serem abordados neste trabalho é apresentado a fundamentação teórica utilizando a metodologia de revisão narrativa (CORDEIRO et al., 2007). Nesta etapa são realizadas as seguintes atividades:

A1.1 – Análise teórica sobre dengue e mosquitos

A1.2 – Análise teórica sobre *deep learning*

Etapa 2 – Estado da arte

Nesta etapa é realizado um mapeamento sistemático da literatura seguindo o processo proposto por Petersen et al. (2008) para identificar e analisar modelos de análise automatizado da originalidade de design de interfaces de usuário de apps atualmente sendo utilizados. Esta etapa é dividida nas seguintes atividades:

A2.1 – Definição do protocolo da revisão

A2.2 – Execução da busca e seleção de artigos relevantes

A2.3 – Extração e análise de informações relevantes

Etapa 3 – Desenvolvimento do modelo de *deep learning*

Nesta etapa é desenvolvido um modelo para classificação de imagens de larvas de mosquito, seguindo o processo de desenvolvimento de redes neurais/deep learning visão geral de um processo de *Machine Learning* (ML) interativo centrado no ser humano (AMERSHI, 2019). Esta etapa é dividida nas seguintes atividades:

A3.1 – Análise de requisitos

A3.2 – Preparação de conjunto de dados

A3.3 – Treinamento de alternativas de redes neurais e avaliação do desempenho

A3.4 – Predição/Inferência (teste com novas imagens)

1.4 Estrutura do documento

Para garantir uma compreensão aprofundada e atingir plenamente os objetivos deste trabalho, foi adotada uma estrutura dividida em capítulos interligados de forma complementar. O Capítulo 2 oferece uma sólida fundamentação teórica, explorando conceitos essenciais relacionados à dengue, espécies de mosquitos e classificação de imagens. Em seguida, o Capítulo 3 aborda o estado da arte da classificação de imagens de larvas de mosquitos utilizando técnicas de *Machine Learning*. O detalhamento do desenvolvimento dos modelos é apresentado no Capítulo 4. Por fim, o Capítulo 5 abrange as considerações finais, encerrando o trabalho de forma conclusiva.

2. Fundamentação Teórica

Neste capítulo são definidos os conceitos de dengue e espécies de mosquito e classificação e imagens.

2.1 Dengue e espécies de mosquitos

2.1.1 Dengue

A dengue é uma doença sistêmica viral transmitida aos seres humanos por meio de mosquitos do gênero *Aedes* (ZHAN et al., 2014). Essa doença apresenta um amplo espectro de sintomas, que vão desde a ausência de sintomas até sintomas semelhantes aos da gripe, como dores de cabeça, náuseas, dores no corpo e indisposição. Além disso, a dengue também pode se manifestar como dengue febril e, nos casos mais graves, como doença grave da dengue, caracterizada por manchas avermelhadas na pele, dores no peito, vômito e potencialmente fatal (ZHAN et al., 2014).

A dengue é considerada uma doença endêmica em muitos países tropicais e subtropicais, e registrou mais de 2 milhões de casos em 2022 e mais de 380 mil casos de janeiro a março de 2023 (ECDC, 2023). Os países mais afetados pela doença estão localizados na América do Sul e Central, incluindo Brasil, Peru, Colômbia, Nicarágua e Equador (ECDC, 2023).

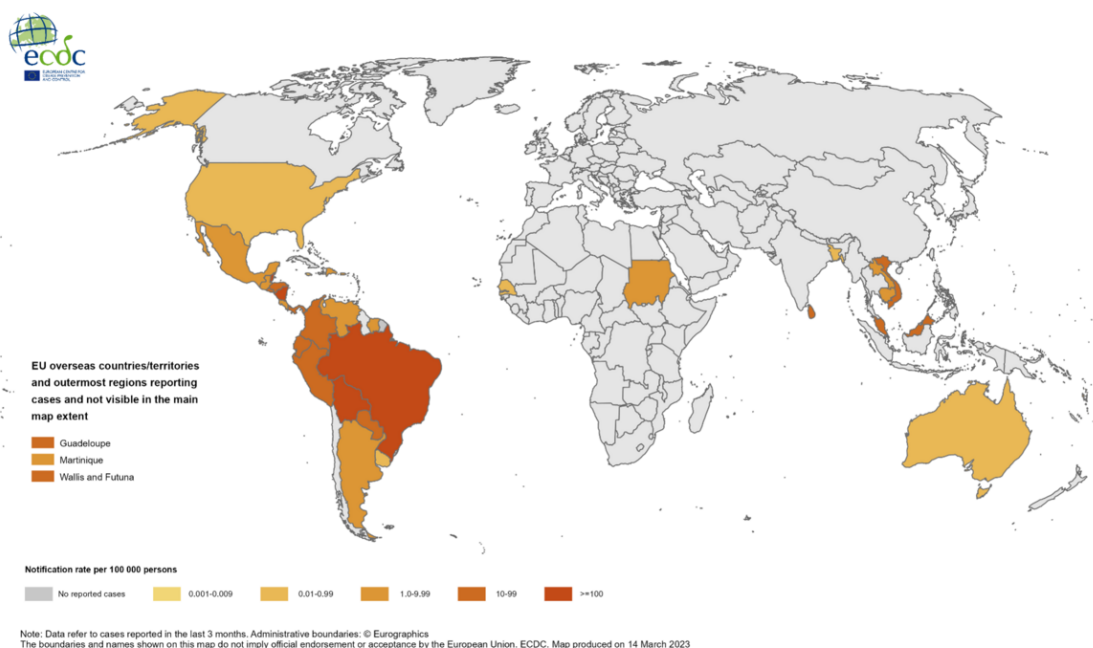


Figura 2: Casos de dengue por população de 100.000 no período Janeiro-Março de 2023.

Fonte: (ECDC, 2023)

O Brasil é o país com mais incidência de casos da doença no mundo, tendo quase duas milhões de pessoas afetadas apenas no ano de 2022 (ECDC, 2023). Os casos também vem aumentando, tendo alta de quase 150 mil casos e 66 mortes desde o ano de 2021, o que a define como um surto nacional (ECDC, 2023).

Em Santa Catarina os focos de mosquitos *Aedes aegypti* aumentaram 17,7% em 2022 comparado ao de 2021 e os casos de Dengue confirmados tiveram alta de 329% e afetam mais de 143 municípios, tendo 73 destes decretado o estado de epidemia da doença. Florianópolis, a capital, é o segundo município mais grave do Estado, tendo mais de 5 mil focos de mosquitos *Aedes aegypti* e mais de 8 mil casos confirmados em 2022 (Figura 3).

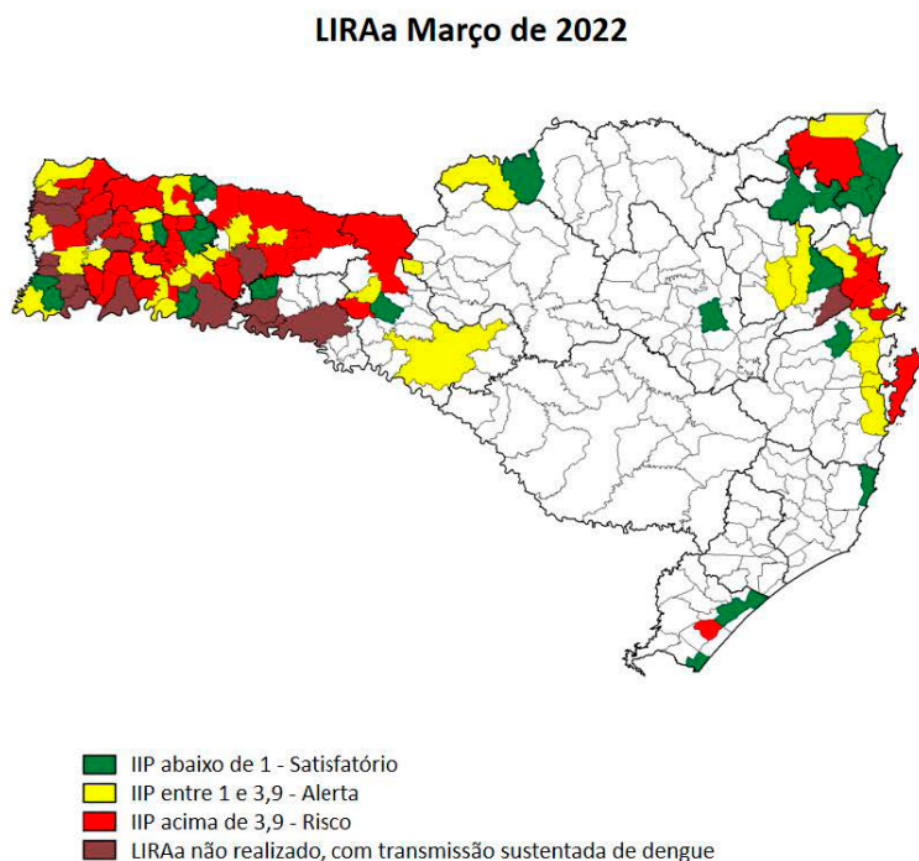


Figura 3: Situação dos municípios em relação a dengue, segundo Índice de Infestação Predial (IIP)

Fonte: (SINAN Online, 2023)

O Levantamento de Índice Rápido de Infestação por *Aedes aegypti* (LIRAA) em Santa Catarina, realizado em março de 2022 realizou inspeções em um total de 100.679 depósitos. Entretanto, na atividade de monitoramento do ano de 2023, foram inspecionados 126.003 depósitos, representando um aumento significativo de 25,2% na

quantidade de recipientes contendo água no ambiente, que são potenciais criadouros do mosquito *Aedes aegypti* (Figura 4).

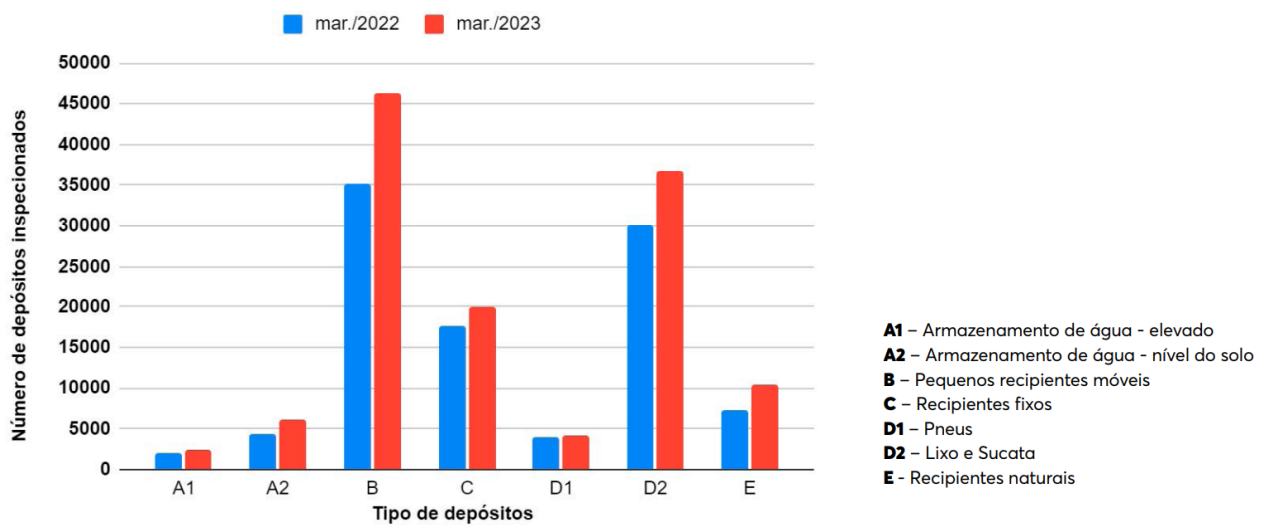


Figura 4: Número de depósitos inspecionados no LIRAa, março. Santa Catarina, 2022/2023*.

Fonte: (SINAN Online,2023)

Os casos de Dengue em Florianópolis durante o ano de 2022 seguiram o padrão observado em todo o Brasil, com um aumento substancial em comparação aos anos anteriores (Figura 5). No entanto, em 2023, a situação continua preocupante no município. Desde o início do ano, o LACEN de Florianópolis já realizou mais de 100.000 testes para dengue (SSSC, 2023). Também foram confirmados 12.009 casos de Dengue na região e infelizmente ocorreram 10 óbitos relacionados à doença (DIVE, 2023).

Novos casos por semana epidemiológica

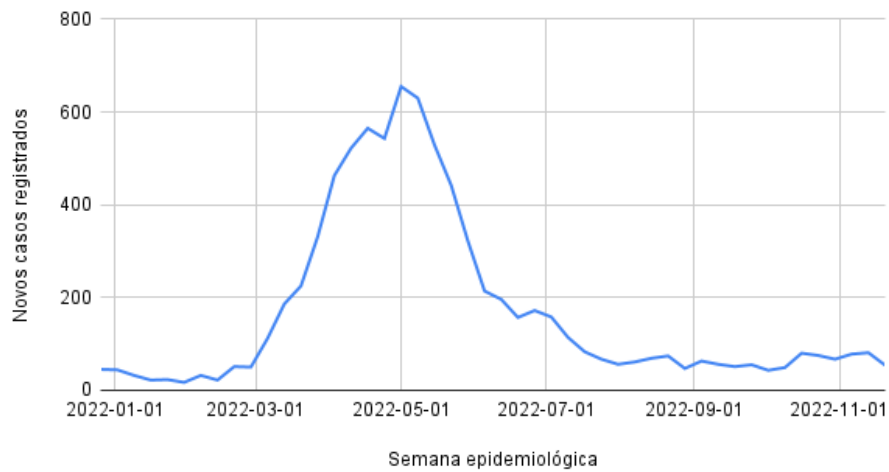


Figura 5: Casos de dengue em Florianópolis por semana epidemiológica

Fonte: Autor, 2022

2.1.2 Ciclo de vida dos mosquitos

O ciclo de vida dos mosquitos é normalmente formado por quatro fases: ovo, larva, pupa e fase adulta (CONSOLI, 1994). Os meios de reprodução entre os gêneros estudados são similares, normalmente tendo como requisito água parada (CONSOLI, 1994).




Figura 6: O ciclo de vida dos mosquitos usando o mosquito doméstico comum (“pernilongo”) como exemplo.

Fonte: (BIOGENTS, 2022).

O foco do trabalho são as espécies *Aedes aegypti*, *Aedes albopictus* e mosquitos do gênero *Culex*, visto que os criadouros dos mosquitos são os mais comuns da região urbana de Florianópolis e Santa Catarina, local onde a pesquisa foi realizada. A seguir, mais informações sobre o ciclo de vida e habitats de reprodução das espécies mencionadas.

Aedes

Fêmeas dos mosquitos *Aedes aegypti* e *Aedes albopictus* têm a capacidade de produzir entre 100 e 300 ovos por vez, e ao longo de suas vidas, podem gerar até cinco lotes de ovos (DENGUEVIRUS, 2022). Esses ovos são depositados em locais úmidos propícios a inundações temporárias, como buracos em árvores e recipientes artificiais, como tambores, baldes, vasos de plantas, pneus e outros recipientes que possam acumular água da chuva. Diferentemente da maioria das espécies de mosquitos, as fêmeas do *Aedes* colocam seus ovos de forma separada, distribuindo-os ao longo de horas ou dias, dependendo das condições adequadas. Esses ovos são geralmente depositados a diferentes distâncias acima da superfície da água.

Os ovos do *Aedes* têm uma forma alongada, lisa e aproximadamente um milímetro de comprimento. Após a postura, eles inicialmente apresentam uma coloração branca, mas em pouco tempo se tornam pretos e brilhantes (DENGUEVIRUS, 2022). Em climas quentes, o desenvolvimento dos ovos pode ocorrer em menos de dois dias, enquanto em regiões de clima temperado mais frio, esse processo pode levar até uma semana. Os ovos são capazes de sobreviver por longos períodos em estado seco, podendo permanecer viáveis por mais de um ano. No entanto, ao entrarem em contato com a água, eclodem imediatamente, o que dificulta o controle do vetor do vírus da dengue (DENGUEVIRUS, 2022).

Após a eclosão dos ovos, as larvas alimentam-se de partículas orgânicas presentes na água, como algas e outros organismos microscópicos (DENGUEVIRUS, 2022). A maior parte do estágio larval ocorre na superfície da água, mas elas podem nadar até o fundo dos recipientes quando perturbadas ou durante a alimentação. As larvas são comumente encontradas em áreas próximas às residências, em reservatórios naturais, pneus ou qualquer objeto que possa acumular água. O desenvolvimento larval é

influenciado pela temperatura ambiente. As larvas passam por quatro estágios, com um curto período nos três primeiros e até três dias no quarto estágio (DENGUEVIRUS, 2022).

As larvas do quarto estágio possuem aproximadamente oito milímetros de comprimento. Os machos têm um desenvolvimento mais rápido do que as fêmeas, e por isso, geralmente se transformam em pupas antes. Em condições de baixa temperatura, o *Aedes aegypti* pode permanecer no estágio larval por meses, desde que haja água suficiente disponível (DENGUEVIRUS, 2022).



Figura 7: Estádio larval do *Aedes aegypti*

Fonte: (DENGUEVIRUS, 2022)

Após o quarto estágio larval, a larva do mosquito entra na fase pupal. As pupas têm a capacidade de se mover e responder a estímulos (DENGUEVIRUS, 2022). Durante essa fase, as pupas não se alimentam e levam cerca de dois dias para se desenvolverem. Os adultos emergem das pupas ao ingerirem ar para expandir seus abdômens, abrindo assim a caixa pupal e iniciando um novo ciclo de vida (DENGUEVIRUS, 2022).

Culex

As fêmeas do gênero *Culex* têm a capacidade de depositar até 1000 ovos por vez (COVISA, 2020). Esses ovos são colocados em conjunto, formando uma estrutura semelhante a uma "jangada" (CONSOLI, 1994). Os criadouros preferenciais do gênero *Culex* são depósitos artificiais, como recipientes e áreas no solo, contendo água rica em matéria orgânica em decomposição e detritos, apresentando um aspecto sujo e desagradável. Esses criadouros são frequentemente encontrados em proximidade com

habitações, uma vez que o *Culex* se beneficia das modificações antrópicas no ambiente peridomiciliar.

As larvas do gênero *Culex* possuem uma posição angulada em relação à água, e diferenciam-se das outras espécies por apresentarem um tubo de ar maior e uma série de cílios (CONSOLI, 1994). Após alguns dias, as larvas se transformam em pupas, que são uma espécie de casulo onde o mosquito se desenvolve até atingir a fase adulta. Uma vez completada a fase de pupa, o mosquito adulto emerge da água, abandonando sua casca pupal, e inicia um novo ciclo reprodutivo da espécie (CONSOLI, 1994).

Nos gêneros de mosquitos mencionados anteriormente, as fêmeas se alimentam de sangue de outros animais para obter os nutrientes necessários à produção dos ovos, tornando-se assim vetores de doenças (FIOCRUZ, 2016). Embora seja possível que a fêmea também consuma sangue antes da cópula, sua voracidade aumenta significativamente durante o período de acasalamento, e cerca de três dias após a ingestão de sangue, elas estão prontas para o acasalamento (FIOCRUZ, 2016).

2.1.3 Morfologia das larvas dos mosquitos

Existem diferenças primordiais na morfologia das larvas de mosquitos entre diferentes gêneros e espécies (CONSOLI, 1994) como *Aedes*, *Anopheles* e *Culex* apresentados na Figura 8.

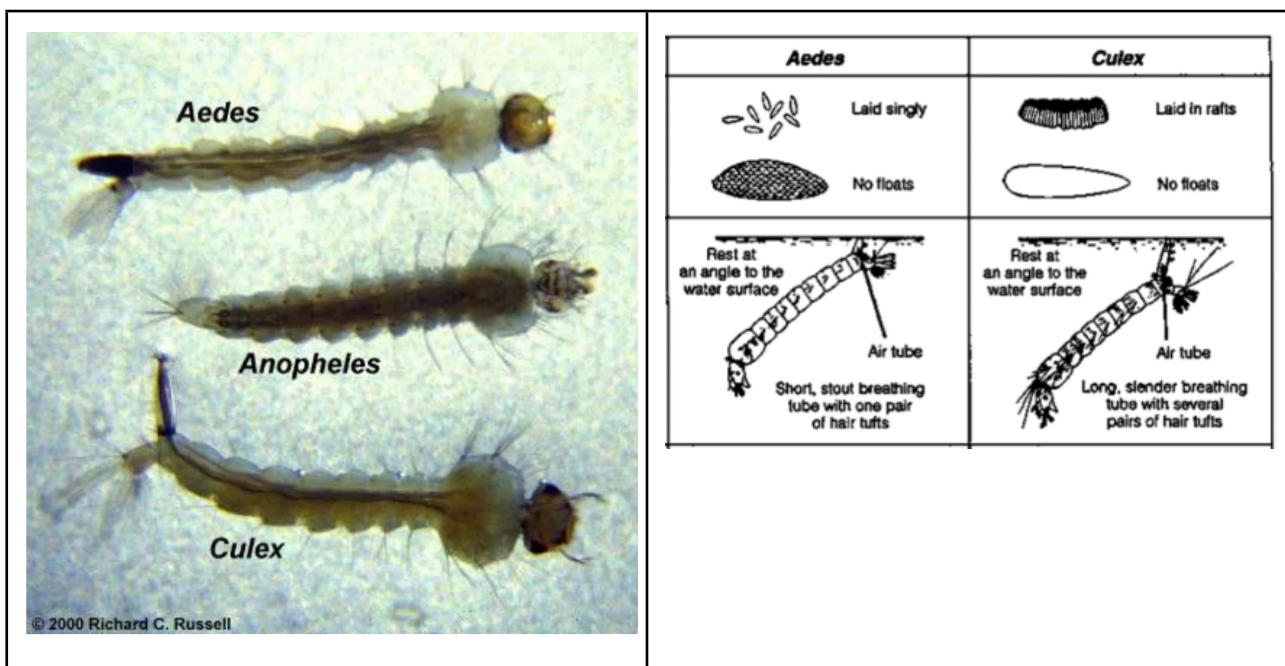


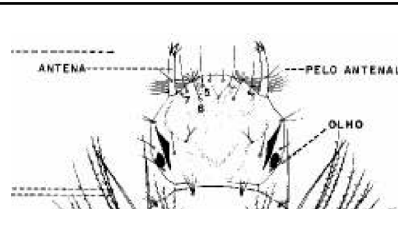
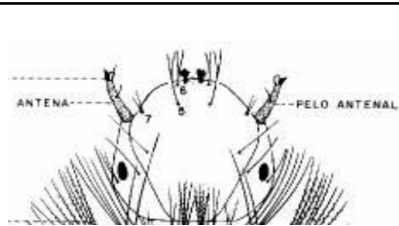
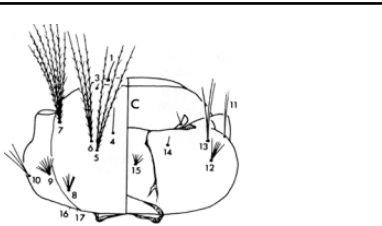
Figura 8: Diferenças na morfologia dos ovos e larvas de diferentes gêneros de mosquito.

Fonte: (WEBB, 2016)

Assim como os mosquitos adultos, as larvas também possuem três regiões distintas em seus corpos: cabeça, tórax e abdômen (CONSOLI, 1994). No entanto, as larvas dos mosquitos são adaptadas ao ambiente aquático e não possuem as características como pernas, asas e probóscide que são encontradas nos insetos adultos (CONSOLI, 1994). A cabeça das larvas é relativamente grande e possui uma estrutura esclerotizada, composta por um exoesqueleto endurecido (CONSOLI, 1994). A forma da cabeça pode variar, sendo alongada nos mosquitos do gênero *Anopheles* e mais larga nos gêneros *Aedes* e *Culex*. A cabeça também é equipada com dois olhos, duas antenas e um aparelho bucal em forma de escova ou pente. Os olhos das larvas são geralmente pequenos e simples, não possuindo a estrutura composta encontrada nos olhos dos insetos adultos. Eles estão localizados em ambos os lados da cabeça.

As antenas das larvas podem variar em comprimento, podendo ser curtas ou longas, dependendo da espécie (CONSOLI, 1994). Ao longo do comprimento das antenas, podem ser encontradas uma ou mais cerdas, que podem ser ramificadas ou não. As peças bucais das larvas são compostas por apêndices articulados derivados da mandíbula. A cabeça das larvas é coberta por um grande número de cerdas, que variam em comprimento e forma. A disposição, comprimento, ramificação e forma dessas cerdas são características utilizadas na identificação das larvas (CONSOLI, 1994).

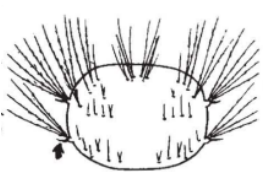
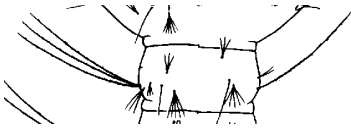
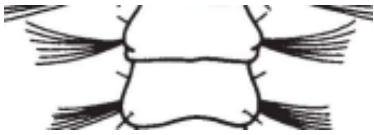
Tabela 1: Diferenças morfológicas na cabeça das larvas de mosquitos de diferentes espécies (CDC, 2013)

<i>Aedes aegypti</i>	<i>Aedes albopictus</i>	<i>Culex</i>
		
Cerda 7-C simples	Cerda 7-C ramificada. Antena mais curta que a cabeça; seta antenal 1-A simples; cabelos da cabeça 5 e 6 simples.	Cabeça sem bolsas laterais, com antena uniforme e com pelos singulares

O tórax é de forma elíptica, geralmente mais largo que a cabeça, e não possui apêndices (CONSOLI, 1994). As cerdas do tórax estão dispostas em três fileiras, que correspondem

às três subdivisões do tórax. As cerdas torácicas também são comumente utilizadas na identificação das larvas (CONSOLI, 1994).

Tabela 2: Diferenças morfológicas do tórax das larvas de mosquitos de diferentes espécies (CDC, 2013)

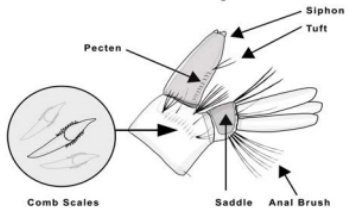
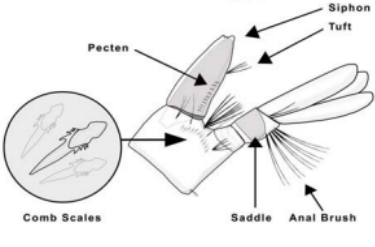
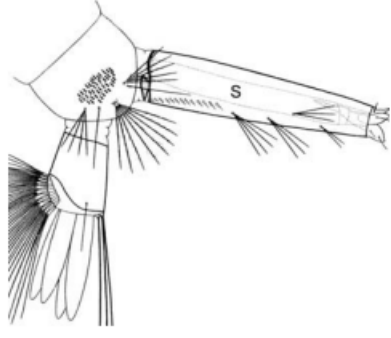
<i>Aedes aegypti</i>	<i>Aedes albopictus</i>	<i>Culex</i>
		
Escama de pente com espinha mediana longa, tórax com espinha lateral em forma de espinho	Larvas com pequenos ganchos discretos nas laterais do tórax	Espinhas medianas laterais longas, proeminentes e agrupadas

O abdômen das larvas é alongado, cilíndrico e composto por dez segmentos (CONSOLI, 1994). Segmentos do abdômen são denotados em algarismos romanos, iniciando no segmento mais anterior (Segmento I) e terminando no segmento anal (Segmento X). Os segmentos I a VII são bastante uniformes em tamanho e forma e juntos constituem a maior parte do corpo. O segmento VIII é geralmente menor que os sete segmentos anteriores, tem formato de pentágono e apresenta as escamas do pente e o sifão respiratório (quando presentes) (CONSOLI, 1994).

As escamas do pente são projeções semelhantes a espinhas que ocorrem em uma fileira ou trecho. Às vezes são carregadas em uma placa esclerotizada, chamada placa de pente. O número, forma e arranjo das escamas de pente são úteis na identificação de larvas, mas muitas vezes requerem alta ampliação (>50x).

O sifão respiratório é um tubo respiratório dorsal esclerotizado que contém os espiráculos respiratórios (CONSOLI, 1994). O sifão pode carregar um pecten, um fileira de espinhos (espículas) estendendo-se da base ventral do sifão até algum ponto ao longo de seu comprimento. O tamanho, forma e comprimento do sifão e do pecten variam de uma espécie para outra e são muito úteis na identificação de larvas de mosquito. Os membros do gênero *Anopheles* não possuem sifão, mas respiram por meio de um aparelho espiracular achatado no segmento VIII (CONSOLI, 1994).

Tabela 3: Diferenças morfológicas no sifão das larvas de mosquitos de diferentes espécies (CDC, 2013)

<i>Aedes aegypti</i>	<i>Aedes albopictus</i>	<i>Culex</i>
		
<p>Sifão com apenas um par de cerdas além da cerda sifonal 2-S. Formato do detalhe do pecten do sifão diferente das demais espécies</p>	<p>Sifão com apenas um par de cerdas além da cerda sifonal 2-S. Formato do detalhe do pecten do sifão diferente das demais espécies</p>	<p>Sifão com três ou mais pares de cerdas ventrais.</p>

O segmento IX é reduzido nas larvas de mosquito e não é discernível como um segmento distinto (CONSOLI, 1994). O segmento anal (Segmento X) contém as papilas anais, sela e escova ventral. As papilas anais são protuberâncias bulbosas e membranosas do exoesqueleto que atuam principalmente na osmorregulação. A sela, uma placa esclerotizada, pode cobrir apenas a porção dorsal do o segmento anal, ou pode circundá-lo completamente. A escova ventral é uma fileira de cerdas pareadas que se estendem ao longo na linha média ventral do segmento anal (CONSOLI, 1994).

2.2 Classificação de Imagens com *Deep Learning*

2.2.1 Visão Geral

Machine Learning (ML) (Aprendizado de máquina) é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana (SAS, 2019).

O ML utiliza de diversas técnicas, entre elas Redes Neurais Artificiais. Redes Neurais Artificiais são modelos computacionais baseados no funcionamento do sistema neural humano, ou seja, são capazes de aprender a partir de experiências prévias e inferir padrões ou realizar o aprendizado de máquina (NICHOLSON, 2019). Redes neurais são organizadas em camadas, iniciando pela camada de entrada, seguida por uma ou mais camadas ocultas e por fim a camada de saída. Cada neurônio tem conexão com outro, com associações de peso e valor, formando a rede. A saída do processo de aplicação de um algoritmo de aprendizagem em um conjunto de dados é nomeado modelo.

Modelos gerados por algoritmos de ML procuram melhorar sua aprendizagem e acurácia na resolução de problemas conforme vão processando mais dados (DEEPAI, 2019). O modelo é treinado a partir de dados, como imagens. O modelo treinado é capaz então de realizar previsões de como as características de um exemplo irão se comportar em determinado cenário, inclusive para valores que não estavam presentes em seus dados de treinamento.

Nesse contexto *Deep Learning* (DL), é caracterizado pelo uso de redes neurais profundas, o que melhorou drasticamente o estado da arte em áreas de reconhecimento de imagens (LECUN, 2015).




Figura 9: Estrutura e camadas de uma rede neural profunda

Fonte: (IBM, 2020)

O algoritmo de aprendizagem usa como entrada um conjunto de dados fornecidos como fonte para treinamento. Os dados utilizados podem ser originários de diversos meios, entre elas aplicações que usam imagens como entrada de dados.

A classificação de imagens é a habilidade de um computador de analisar uma imagem e identificar a “classe” em que a imagem se enquadra (ou uma probabilidade de a imagem fazer parte dessa ‘classe’.) Uma classe é essencialmente um rótulo, por exemplo, ‘carro’, ‘animal’, ‘edifício’.


Existem diferentes tipos de classificação de imagens: *Multi-label* e *Single-Label*. A diferença dos dois tipos de classificação é o número de classes que um objeto ou exemplo pode ter. Por exemplo, um modelo que prediz quais peças de roupa uma pessoa está utilizando necessita de uma classificação *Multi-label*, já que o reconhecimento de vários objetos ao mesmo tempo é necessário.

Existem diferentes tipos de aprendizagens, entre elas a aprendizagem supervisionada. Na aprendizagem supervisionada os dados do conjunto possuem rótulos que indicam a classe de cada um dos artefatos de entrada. Exemplos de aprendizagem supervisionada são algoritmos de classificação e regressão (BAŞTANLAR; ÖZUYSAL, 2013).

2.2.2 Processo de Desenvolvimento de *Deep Learning*

O desenvolvimento de modelos de *Deep Learning* deve seguir um processo sistemático como o apresentado na (Figura 10) com base em Amershi (2019) e Gresse von Wangenheim e von Wangenheim (2021).

Figura 10: Visão geral do processo iterativo de ML centrado em humanos



Fonte: (GRESSE VON WANGENHEIM E VON WANGENHEIM , 2021)

Análise de requisitos - Durante esta etapa, o objetivo principal do modelo DL e suas características alvo são especificadas, incluindo a caracterização das entradas e saídas esperadas.

Preparação de dados - Etapa em que os dados que serão consumidos pelo algoritmo são coletados, limpos e preparados. É preciso utilizar um conjunto de dados existente ou realizar a própria coleta dos dados. Após, é necessário fazer a limpeza dos dados, removendo dados incorretos e/ou repetidos. O tipo de dado pode variar dependendo do problema. Em aprendizagem supervisionada, os dados são rotulados. Os conjuntos de dados são divididos em conjunto de treinamento, usado para treinar o modelo, conjunto de validação, usado para comparar diferentes modelos e conjunto de teste, usado para avaliar o desempenho do modelo.

Treinamento do modelo - O algoritmo de aprendizado de máquina (ML) adquire conhecimento a partir de um conjunto de dados de treinamento e identifica padrões para criar um modelo que capture essas relações (CHOLLET, 2016). Para reduzir o tempo de treinamento, é possível utilizar o Transfer Learning com modelos pré-treinados, utilizando conjuntos menores de imagens (CHOLLET, 2016). O Transfer Learning envolve o pré-treinamento do modelo com imagens, como os ResNets 18 e 34, utilizando conjuntos de dados como o Imagenet (HE, 2015). Com essa abordagem, é possível obter resultados relevantes ao adicionar apenas algumas imagens ao modelo já existente. Uma maneira de aprimorar ainda mais o desempenho do Transfer Learning é através do Fine-Tuning,

que envolve o ajuste do modelo pré-treinado ao reorganizar as camadas da rede e treiná-lo novamente para uma tarefa similar (GUO et al., 2019).

Durante o treinamento do modelo, o desempenho é avaliado utilizando métricas como a função de perda (loss function) e a taxa de erro (error rate). A função de perda calcula a distância entre a saída atual do algoritmo e a saída esperada, fornecendo uma medida de como o algoritmo modela os dados (GUO et al., 2019). Já a taxa de erro representa a proporção de imagens que foram classificadas de forma incorreta. Essas métricas são utilizadas para avaliar a eficácia e o progresso do modelo durante o treinamento.

Avaliação do desempenho - Após o treinamento do modelo, é necessário avaliar seu desempenho para verificar sua capacidade de generalização em dados não conhecidos. O objetivo principal do modelo de aprendizado de máquina (ML) é aprender padrões gerais em vez de memorizar os dados de treinamento (ESCOVEDO, 2020). O treinamento do modelo é concluído quando os resultados atingem um nível satisfatório, mas é possível realizar iterações adicionais de atualização de parâmetros e treinamento para melhorar ainda mais a precisão do modelo.

Existem várias medidas que podem ser utilizadas para avaliar o desempenho do modelo. No caso de tarefas de classificação de imagens, é comum calcular a acurácia geral do modelo, que é a proporção de classificações corretas em relação ao total de exemplos. Além disso, a acurácia por categoria pode ser calculada para avaliar o desempenho do modelo em cada classe específica.

Outras métricas importantes incluem a precisão e o *recall*. A precisão é a proporção de exemplos classificados corretamente como positivos em relação ao total de exemplos classificados como positivos. Já o *recall* é a proporção de exemplos positivos reais que foram corretamente identificados pelo modelo. Essas métricas são úteis para avaliar o desempenho em problemas de classificação onde a identificação correta de positivos é importante.

Uma métrica que combina precisão e recall é o *F1 score*, que é a média harmônica entre essas duas medidas. O *F1 score* é uma métrica comumente utilizada para avaliar o equilíbrio entre precisão e recall em problemas de classificação.

Portanto, ao avaliar o desempenho do modelo de ML, é recomendado analisar medidas como acurácia, precisão, recall e *F1 score*, dependendo das características do problema e das metas de classificação desejadas (ESCOVEDO, 2020).

Predição - Um modelo de aprendizado de máquina adquire a capacidade de realizar previsões e inferências não apenas em dados semelhantes aos que foram utilizados durante o treinamento, mas também em novos dados nunca antes vistos. Isso inclui a capacidade de prever resultados em imagens nunca antes encontradas pelo modelo (RASCHKA, 2015).

Implantação do modelo - Nesta fase, o modelo pode ser exportado para ambientes de produção para ser utilizado em artefatos computacionais como aplicações web ou móveis.

2.2.3 Tipos de redes neurais para classificação de imagens

Um dos tipos de modelos de redes neurais são as Redes Neurais Convolucionais (CNN). É uma arquitetura de aprendizado profundo (DL) amplamente usada para classificação de imagens que extrai recursos locais e aprende diretamente deles usando convoluções, ou seja, a imagem original passa por filtros que a transformam por meio de combinações lineares dos pixels, e devido aos pesos que são estabelecidos nos filtros, é possível detectar características (PACHECO e PEREIRA, 2018). Uma CNN normalmente tem três camadas: uma camada convolucional, uma camada de *pooling* e uma camada totalmente conectada (Figura 11).




Figura 11: Camadas de uma CNN

Fonte: (KUMAR, 2022)

Camada convolucional. Nesta camada, a operação matemática de convolução é realizada entre a imagem de entrada e um filtro. Ao deslizar o filtro sobre a imagem de entrada, o produto escalar é obtido entre o filtro e as partes da imagem de entrada em relação ao tamanho do filtro. O resultado deste processo é um mapa de características, a partir do qual a rede pode reconhecer padrões e fazer uma classificação. O mapa de

recursos é alimentado a outras camadas para que possa ser usado para identificar mais características na imagem de entrada.

Camada de *pooling*. Essa camada reduz o tamanho espacial da imagem de entrada, facilitando o processamento e exigindo menos memória. O agrupamento também ajuda a reduzir o número de parâmetros e torna o treinamento mais rápido. Existem dois tipos principais de *pooling*: *pooling* máximo e *pooling* médio. O *pooling* máximo obtém o valor máximo de cada mapa de recursos, enquanto o *pooling* médio obtém o valor médio. As camadas de *pool* são normalmente usadas após as camadas convolucionais para reduzir o tamanho da entrada antes que ela seja alimentada para uma camada totalmente conectada.

Camada totalmente conectada. É um dos tipos mais básicos de camadas em uma rede neural convolucional (CNN). Como o nome sugere, cada neurônio em uma camada totalmente conectada é totalmente conectado a todos os outros da camada anterior. Camadas totalmente conectadas são normalmente usadas no final de uma CNN, quando o objetivo é pegar os recursos aprendidos pelas camadas anteriores e usá-los para fazer previsões.

2.2.3.1 ResNets

Um dos modelos CNN mais utilizados é o ResNet, que adotou o aprendizado residual para camadas empilhadas (HE, 2015). As CNNs profundas enfrentam o problema do gradiente de fuga, onde os gradientes calculados a partir da função de perda diminuem para zero devido a aplicações repetidas da regra da cadeia, dificultando o treinamento nas camadas iniciais. Isso satura a precisão da rede e aumenta o erro de treinamento, reduzindo efetivamente sua capacidade de generalização. A ResNet adiciona conexões de salto para permitir que os gradientes fluam das camadas finais para os filtros iniciais.

As conexões de salto com mapeamento residual também permitiram que ResNets otimizem e ganhem precisão com mais facilidade a partir do aumento da profundidade, removendo o gargalo anterior. ResNets mostraram um desempenho melhor do que CNNs comparativas, como redes VGG, GoogleNet e Inception.

Existem muitas variantes da arquitetura ResNet, ou seja, a mesma arquitetura mas com uma quantidade diferente de camadas, como p.ex. ResNet-18, ResNet-34, ResNet-50, ResNet-101, etc (Figura 12). O número após o nome da ResNet indica o número de camadas que é usado no modelo. Por exemplo, uma Resnet-18 usa 18 camadas de neurônios para fazer o processamento dos dados.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Figura 12: Arquiteturas e desempenhos das ResNets com o ImageNet

Fonte: (HE, 2015)

A Figura 13 apresenta como exemplo a arquitetura da ResNet34.

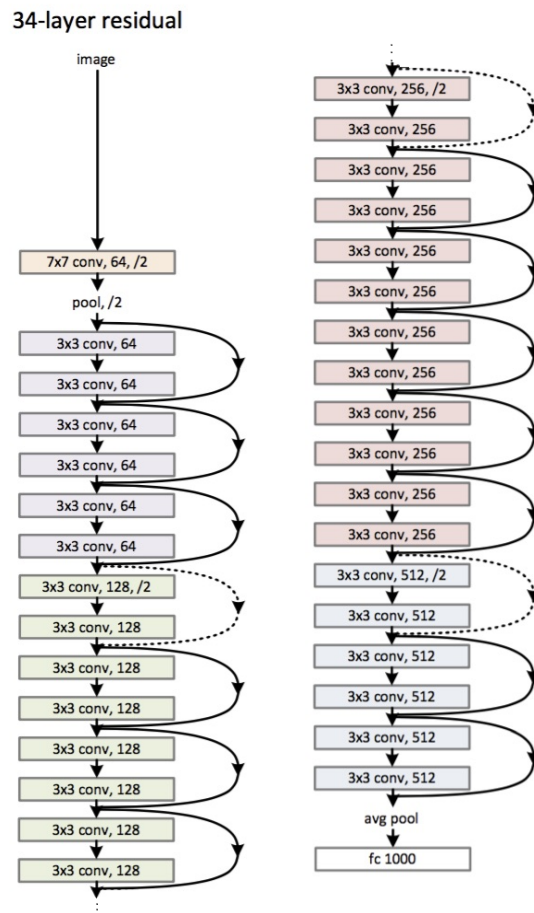


Figura 13: Resnet-34

Fonte: (SIDDHARTH, 2021)

A camada de entrada da rede (1) é uma camada de convolução com 64 filtros 7x7 e passo 2 para realizar o primeiro *downsampling*. O próximo grupo (2), com 6 camadas, realiza novas operações de convolução e transmite os dados para a segunda operação de *downsampling* na primeira camada do terceiro grupo (3). Após mais 7 camadas de convolução, uma terceira etapa de *downsampling* na primeira camada do quarto grupo (4), seguida de mais 11 camadas de convolução antes da última operação de *downsampling* na primeira camada do quinto grupo (5) de camadas convolucionais. Os dados finais passam por uma operação de global average pooling e são então transmitidos para a camada de saída (6); um perceptron totalmente conectado (1000 conexões) com *softmax*, que então gera o resultado numérico final. Após cada operação de *downsampling* o número de filtros é duplicado para preservar a complexidade temporal por camada.

2.2.3.2 MobileNet

MobileNet (HOWARD, 2017) um modelo pequeno, de baixa latência e baixo consumo energético parametrizado para atender diversos casos de uso. Tem foco em dispositivos embarcados e móveis que possuem capacidade de processamento limitada. É baseado em convoluções separáveis em profundidade, compostas por duas camadas: a convolução de profundidade e a convolução de ponto. A primeira camada é usada para filtrar os canais de entrada e a segunda camada é usada para combiná-los e criar um novo filtro (Figura 14).

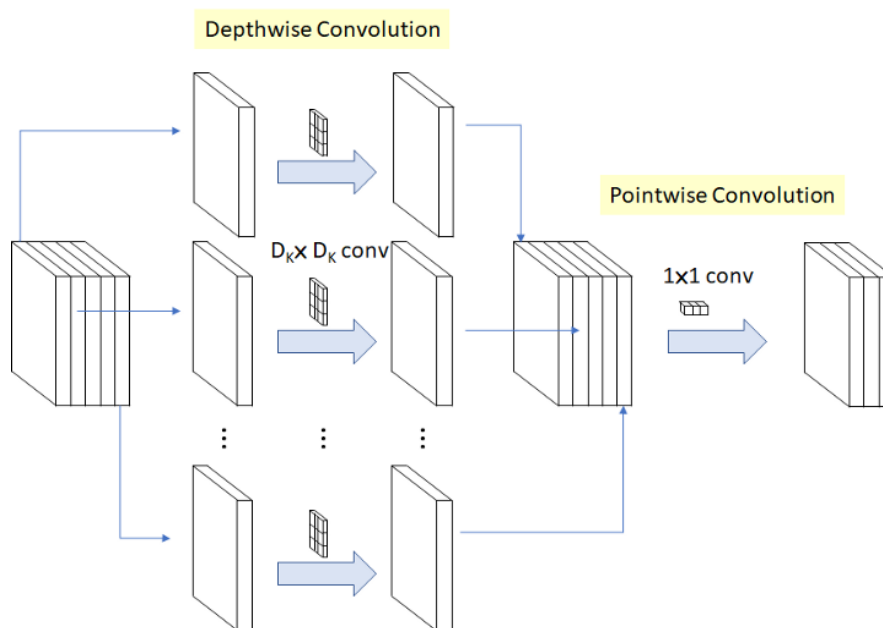


Figura 14: Convolução separável em profundidade

Fonte: (PUJARA, 2020)

As convoluções de profundidade são usadas para aplicar um único filtro em cada canal de entrada. Em uma convolução padrão os filtros são aplicados a todos os canais de entrada. Essa fatoração tem o efeito de redução drástica da computação e o tamanho do modelo (HOWARD, 2017).

Embora a arquitetura do MobileNet (Figura 15) seja pequena e computacionalmente pouco intensiva, possui dois hiperparâmetros globais opcionais para reduzir ainda mais o custo computacional. O multiplicador de largura e o multiplicador de resolução (Figura 15).

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5×	Conv dw / s1	$3 \times 3 \times 512$ dw
	Conv / s1	$1 \times 1 \times 512 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

Figura 15: Arquitetura do MobileNet.

Fonte: (HOWARD, 2017)

Além da versão original do MobileNet, existem as versões MobileNetV2 e MobileNetV3. A MobileNetV2 é muito semelhante ao MobileNet original, exceto que usa blocos residuais invertidos com recursos de gargalo. Ele tem uma contagem de parâmetros drasticamente menor do que o MobileNet original. MobileNets suportam qualquer tamanho de entrada maior que 32×32 de imagens, com tamanhos de imagem maiores oferecendo melhor desempenho. Já o MobileNetV3 conta com o AutoML para encontrar a melhor arquitetura possível em um espaço de pesquisa amigável para tarefas de visão computacional móvel (GOOGLE, 2022).

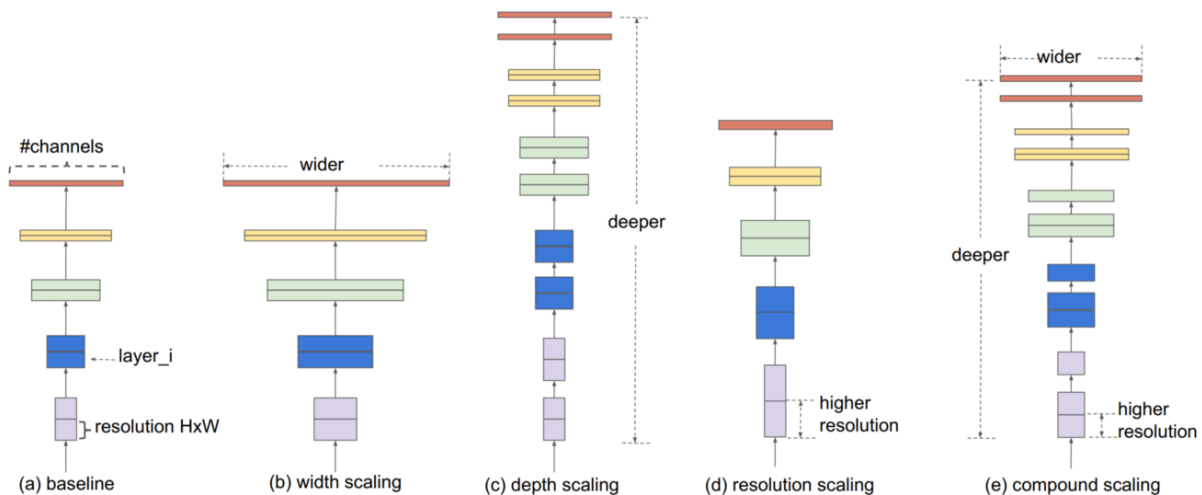
O *Google Teachable Machine* utiliza o modelo *MobileNet* "headless", no qual a última camada (que toma a decisão final sobre as 1.000 aulas de treinamento) foi removida, expondo o vetor de saída da camada anterior. O Teachable Machine trata esse vetor de saída como um descritor genérico para uma determinada imagem de câmera, chamado-o de vetor de incorporação.

2.2.2.3 EfficientNet

A EfficientNet (TAN,2019) é uma arquitetura de rede neural convolucional é um método de dimensionamento que dimensiona uniformemente a profundidade, largura e resolução de um modelo convolucional usando um coeficiente composto. Ao contrário da prática convencional que dimensiona arbitrariamente esses fatores, o EfficientNet dimensiona uniformemente a largura, a profundidade e a resolução da rede com um conjunto de coeficientes de dimensionamento fixos.

O EfficientNet é baseado na rede de linha de base desenvolvida pela pesquisa de arquitetura neural usando o framework AutoML MNAS. A rede é ajustada para obter a máxima precisão, mas também é penalizada se a rede for muito pesada computacionalmente. A arquitetura usa uma convolução de gargalo invertido móvel semelhante ao MobileNetV2, mas é muito maior devido ao aumento de FLOPS. Este modelo de linha de base é ampliado para obter a família de EfficientNets. O método de dimensionamento composto é mostrado na Figura 16.

Figura 16: Diferentes métodos de dimensionamento



dimensionamento versus dimensionamento composto Fonte: (TAN, 2019)

O método de dimensionamento composto é baseado na ideia de equilibrar as dimensões de largura, profundidade e resolução por meio de dimensionamento com uma proporção constante.

Existem outras versões do EfficientNet focadas em tornar o modelo mais leve e portátil, mantendo a tecnologia de convoluções de gargalo invertido móvel. Uma delas é o EfficientNet-Lite. O EfficientNet-Lite roda a partir do TensorFlow Lite e é projetado para obter desempenho considerável em CPUs móveis. Existem cinco variantes deste modelo, permitindo que os usuários escolham entre a opção de baixa latência/tamanho do modelo (EfficientNet-Lite0) e a opção de alta precisão (EfficientNet-Lite4).

2.2.2.4 Comparação do desempenho padrão de modelos

Geralmente o desempenho de modelos de classificação de imagens é avaliado em termos de acurácia, comumente usadas as métricas de acurácia, precisão, *recall* e *F1 Score*.

Essas métricas são baseadas nos diferentes erros comparando os valores previstos e reais: Verdadeiro positivo (VP) , Falso positivo (FP), Verdadeiro negativo (VN) e Falso negativo (FN).

- **Verdadeiro Positivo:** O verdadeiro positivo representa uma instância que está corretamente predita verdadeiramente. Por exemplo, uma larva de mosquito de *Aedes aegypti* que foi classificada corretamente como *Aedes aegypti*.
- **Verdadeiro Negativo:** O verdadeiro negativo representa uma instância predita corretamente de forma negativa. Um exemplo seria: uma larva foi predita como não sendo do mosquito *Aedes aegypti* e realmente ela não era.
- **Falso Positivo:** Representa uma predição que não está correta de maneira positiva. Exemplo, uma larva de mosquito foi classificada como *Aedes aegypti* (transmissor da dengue) mas era uma larva de mosquito do gênero *Culex* (não transmite a doença).
- **Falso Negativo:** Representa uma classificação errônea falsa. Por exemplo, uma larva de mosquito foi classificada como *Culex* (mosquito que não transmite a dengue) mas era *Aedes aegypti* (transmissor da doença).

As métricas podem ser visualizadas através de uma matriz de confusão, uma ferramenta que indica visualmente os possíveis erros do modelo treinado (Figura 17).

		Valor predito \hat{Y}	
		Negativo (0)	Positivo (1)
Valor Real	Negativo (0)	VN	FP
	Positivo (1)	FN	VP

Figura 17: Exemplo de matriz de confusão.

Fonte: (SCUDILIO, 2020)

A **acurácia** pode ser calculada pela quantidade classificada como Positivos e Negativos corretamente.

$$\text{Acurácia} = (TP + TN) / (TP + TN + FP + FN)$$

A **precisão** é a quantidade positiva classificada corretamente

$$\text{Precisão} = TP / (TP + FP)$$

O **recall** é a taxa de valores classificada como positiva, comparada com quantos deveriam ser.

$$\text{Recall} = TP / (TP + FN).$$

O **F1 Score** é calculado como a média harmônica entre Precisão e *Recall*

$$\text{F1 Score} = (2 * TP) / (2 * TP + FP + FN)$$

A Figura 18 apresenta uma comparação dos principais CNNs mencionados neste trabalho, utilizando o conjunto de dados ImageNet como base. O modelo mais robusto, EfficientNet (EfficientNetb7), demonstrou o melhor desempenho, alcançando aproximadamente 84,4% de precisão top-1 e 97,3% de precisão top-5 no ImageNet.




Figura 18: Tamanho dos modelos vs. Acurácia.

Fonte:(TAN, 2019)

Segundo o gráfico comparativo, a EfficientNet-B7 é mais precisa e mais rápida que todas as outras alternativas. A EfficientNet-B7 é 7,6x menor e 5,7x mais rápida que a ResNet-152, por exemplo. Isso é possível graças a tecnologia de dimensionamento composto implementada no modelo vencedor, o que projeta imagens de forma mais eficaz e com menos custo computacional. Leva-se em consideração, porém, que modelos com muitas camadas, como o EfficientNet-B7, SEnet, Resnet-152 ou Resnet-50 não são a melhor escolha em se falando de dispositivos com desempenho limitado, como aparelhos móveis devido a seu tamanho e dificuldade de adaptá-lo a um aplicativo.

Levando em consideração que no futuro visa se a implantação do modelo em um aplicativo móvel, as CNNs EfficientNet-B0, EfficientNet-Lite, Resnet-34, Resnet-18, MobileNetV2 são opções portáteis a dispositivos móveis, visto que produzem modelos a partir de um número reduzido de camadas. A Figura 19 representa o desempenho dos modelos EfficientNet-Lite, MobileNetV2 e Resnet-50 comparado ao seu tamanho.




Figura 19: Comparação da acurácia e tamanho de modelos.

Fonte: (GOOGLE, 2020)

a EfficientNet-Lite relata um desempenho maior em suas versões, porém o modelo mais portátil é o MobileNetV2 (Figura 19).

3. Estado da arte

Para levantar o estado da arte sobre quais pesquisas adotando *Deep Learning* para automaticamente classificar larvas de mosquito em imagens existem, foi conduzido um mapeamento sistemático seguindo os procedimentos propostos por Petersen *et al.* (2008).

3.1 Definição do protocolo de revisão

O objetivo desta revisão é responder à seguinte questão: quais pesquisas existem adotando *Deep Learning* para automaticamente classificar larvas de mosquito a partir de imagens? Essa pergunta de pesquisa é refinada nas seguintes questões de análise:

AQ1. Quais pesquisas existem em termos de classificação e quais as espécies classificadas?

AQ2. Como é formado o conjunto de dados e quantas imagens possui?

AQ3. Como os modelos foram treinados?

AQ4. Quais os desempenhos relatados?

Critérios de inclusão/exclusão. Foram consideradas somente pesquisas voltadas para a classificação de larvas de mosquitos a partir de imagens. Foram excluídas pesquisas não focadas em imagens de larvas (mosquitos adultos ou ovos), além de pesquisas com sons dos mosquitos, pesquisas sobre classificação de habitats/ninhadouros dos mosquitos, pesquisas relacionadas a plantas e pestes agropecuárias. Pesquisas sobre controle da população do *Aedes aegypti*, e malária, predição da população dos mosquitos também foram excluídos. Não foram consideradas também pesquisas que enfocam em outras tarefas a não ser classificação de imagens (detecção de objetos, uso de vídeos). Foram considerados somente trabalhos publicados nos últimos 10 anos.

Critérios de qualidade. Foram considerados apenas artigos ou materiais com informações suficientes, p.ex. resumos foram não considerados.

Fontes dos dados. Foram revisados todos os materiais e artigos disponíveis no ACM Digital Portal, IEEE, Scopus, que são importantes bibliotecas digitais acessíveis por meio do Portal Capes, tanto em inglês quanto em português. Além disso, uma busca foi realizada no Google Scholar, devido à sua capacidade de indexar um amplo conjunto de dados provenientes de diversas fontes (HADDAWAY et al., 2015). É importante ressaltar que, nessa área emergente, nem todos os artigos científicos das extensões criadas foram necessariamente publicados.

Definição da *string* de busca. A *string* de busca foi composta de conceitos relacionados à questão de pesquisa, incluindo sinônimos (Tabela 4).

Tabela 4: Termos de busca utilizados no protocolo de revisão

Termo	Sinônimo
Mosquito	<i>Aedes, Aedes aegypti, Aedes albopictus, Culex, Anopheles</i>
Deep learning	“Machine Learning”, “Artificial Intelligence”, “Image classification”, “Image recognition”, “Neural network”, “Convolutional network”
Larva	Larvae, Larval
Dengue	

A partir disso foi gerado o seguinte *string* de busca genérico:

(Mosquito OR *Aedes* OR *Culex* OR *Anopheles*) AND (“Deep learning” OR “Machine Learning” OR “Artificial Intelligence” OR “Image classification” OR “Image recognition” OR “Neural network” OR “Convolutional network”) AND (Larvae OR Larva OR Larval) AND Dengue.

A *string* de busca genérica foi adaptada para cada fonte de dados conforme apresentada na Tabela 5.

Tabela 5 - String de busca para cada fonte.

Fonte	String de busca
ACM	[[Abstract: mosquito] OR [Abstract: aedes] OR [Abstract: aedes aegypti or aedes albopictus]] AND [[Abstract: "deep learning"] OR [Abstract: "machine learning"] OR [Abstract: "artificial intelligence"] OR [Abstract: "image classification"] OR [Abstract: "image recognition"]] AND [[Abstract: larva] OR [Abstract: larvae] OR [Abstract: larval]] AND [Abstract: dengue] AND [E-Publication Date: (01/01/2013 TO *)]
IEEE	("Abstract":Mosquito OR "Abstract":Aedes OR "Abstract":Culex OR "Abstract":Anopheles) AND ("Abstract":"Deep learning" OR "Abstract":"Machine Learning" OR "Abstract":"Artificial Intelligence" OR "Abstract":"Image classification" OR "Abstract":"Image recognition" OR "Abstract":"Neural network" OR "Abstract":"Convolutional network") AND ("Abstract":Larvae OR "Abstract":Larva) AND ("Abstract":Dengue) Filters Applied: 2013 - 2023
SCOPUS	(TITLE-ABS-KEY ((mosquito OR aedes OR "Aedes Aegypti" OR "Aedes Albopictus") AND (larvae OR larva) AND ("Deep Learning" OR "Artificial Intelligence" OR "image classification" OR "image recognition") AND (Dengue)) Filters Applied: 2013 - 2023
Google Scholar	"Mosquito" OR "Aedes" "Larvae" OR "Larva" "Deep Learning" OR "image classification" OR "image recognition" Dengue -"social network" -maggots -drone -sound -acoustic -sattelite after:2013

3.2. Execução da busca

A pesquisa foi realizada em outubro de 2022 pelo autor e revisada pela orientadora (Tabela 6). As pesquisas retornaram poucos resultados, porém a maioria relevante para o trabalho proposto.

Tabela 6 - Número de artigos identificados por repositório e por fase de seleção.

Fonte	No. de resultados da busca	No. de resultados analisados	No. de resultados potencialmente relevantes	No. de resultados relevantes
IEEE	10	10	0	0
SCOPUS	12	12	6	4
IEEE	9	9	3	3
ACM Digital Library	12	12	1	0
Google Scholar	480	150	17	9
Total				16

Na primeira fase de análise, os títulos e resumos dos resultados da busca foram analisados, resultando em 16 artefatos potencialmente relevantes. No segundo estágio, os materiais foram lidos por inteiro, para assegurar sua relevância com respeito aos critérios de inclusão/exclusão. Foram excluídas pesquisas como, p.ex., Training of convolutional neural network using transfer learning for *Aedes Aegypti* larvae (FUAD, 2018) voltado a classificação de depósitos de água contendo ou não larvas de mosquito *Aedes*. Como resultado, 12 pesquisas foram consideradas relevantes (Tabela 6).

3.3 Resultados da revisão

De acordo com as perguntas de análises, as informações relevantes foram extraídas dos materiais encontrados

3.3.1 Quais pesquisas existem em termos de classificação e quais as espécies classificadas?

Tabela 14. Classificação de espécies nas extensões encontradas

Referência	Título do artigo	Espécies classificadas	País
(Arista-Jalife,2018)	Deep learning employed in the recognition of the vector that spreads dengue chikungunya and zika viruses	<i>Aedes and Non-Aedes</i>	México
(Arista-Jalife,2019)	<i>Aedes</i> mosquito detection in its larval stage using deep neural networks	<i>Aedes and Non-Aedes</i>	México
(Asmai, 2019)	Mosquito Larvae Detection using Deep Learning	<i>Aedes and Non-Aedes</i>	Malaysia
(Azman, 2020)	<i>Aedes</i> Larvae Classification and Detection (ALCD) System by Using Deep Learning	<i>Aedes Aegypti, Aedes Albopictus, Anopheles e Culex</i>	Malaysia
(De Silva, 2020)	Dengue mosquito larvae identification using digital images	<i>Aedes and Non-Aedes</i>	Sri Lanka
(Fuad, 2018)	Training of Convolutional Neural Network using Transfer Learning for <i>Aedes Aegypti</i> Larvae	<i>Aedes Aegypti and Non-Aedes</i>	Malaysia
(Hossain, 2022)	<i>Aedes</i> Larva Detection Using Ensemble Learning to Prevent Dengue Endemic	<i>Aedes and Non-Aedes</i>	Suiça
(Munoz, 2018)	Image Recognition of Disease-Carrying Insects: A System for Combating Infectious Diseases Using Image Classification Techniques and Citizen Science	<i>Aedes, Culex, Anopheles ou Desconhecido</i>	EUA
(Rajasekhar, 2021)	Identifying <i>Anopheles/Non-Anopheles</i> Larvae with AI Implications	<i>Anopheles and Non-Anopheles</i>	EUA

(Sanchez-Ortiz, 2017)	Mosquito Larva Classification Method Based on Convolutional Neural Networks	<i>Aedes and Non-Aedes</i>	México
(Surya, 2022)	A Mosquito is Worth 16x16 Larvae: Evaluation of Deep Learning Architectures for Mosquito Larvae Classification	<i>Aedes, Culex ou Desconhecido</i>	Não Informado
(Yanai, 2019)	Mosquito Larvae Image Classification based on DenseNet and Guided Grad-CAM	<i>Aedes and Non-Aedes</i>	Espanha

As pesquisas sobre classificação de larvas de mosquito usando *machine learning* têm sido um esforço recente da comunidade científica mundial, contando que nenhum dos artigos foi publicado por mais do que 5 anos atrás.




Figura 20: Quantidade de artigos relevantes ao assunto publicados nos últimos 10 anos.

Fonte: Autor, 2022

Observa-se que aparentemente existe a motivação e necessidade para este tipo de pesquisa, já que foram encontradas pesquisas similares que visam realizar a classificação de larvas com fim de prevenção de doenças causadas pelos mosquitos do gênero *Aedes*. A maioria das pesquisas trata apenas da classificação de larvas de mosquitos *Aedes* vs *Non-Aedes*, como detalha a Figura 21.




Figura 21: Pesquisas separadas por espécie/gênero de mosquitos

Fonte: Autor, 2022

Entre os trabalhos encontrados, sete abordam a classificação de larvas de *Aedes* versus *Non-Aedes*, o que sugere que realizar a classificação de mais espécies, como é o caso desta pesquisa, pode ser interessante. Um dos trabalhos identificados se dedica à classificação dos gêneros *Aedes*, *Anopheles* e *Culex*. No entanto, os resultados relatados não foram satisfatórios.

3.3.2. Quais as características do conjunto de dados?

A pesquisa foi realizada com os trabalhos selecionados anteriormente. Os resultados coletados foram compilados na tabela a seguir. As informações coletadas foram:

Tabela 7: Informações sobre os dados encontrados nas pesquisas

Referência	Tipo de imagens	Quantidade de imagens no conjunto de dados	Resolução	Técnicas de data augmentation aplicadas
(Arista-Jalife,2018)		570	Não informado	Sem data augmentation
(Arista-Jalife,2019)	Imagens de	916	(256 × 256)	Image cropping

	microscópio (zoom 60x)			
(Asmai, 2019)	Imagens de plataformas como Flickr.com e Shutterstock.com de larvas de mosquito no microscópio.	Não informado	Todos os dados serão padronizados convertendo o tamanho para 244×244×3 para todas as imagens com canal de cores RGB	Aplicam 20 rotações para cada imagem
(Azman, 2020)	Imagem capturada com a lente micro blips de um Smartphone Samsung	Não informado	Não informado	Não informado
(De Silva, 2020)	Imagens de microscópio (Zoom 60x) e imagens digitais com zoom	160 (imagens capturadas com microscópio) 238 (imagens capturadas com zoom)	Não informado	Não informado
(Hossain, 2022)	Fontes online e imagens capturadas com câmera fotográfica (65mm f/2.8 1-5× microlens)	900	Não informado	Segmentação das imagens
(Munoz, 2018)	Imagens de celular com microscópio acoplado	Conjunto de dados feito por uma equipe, fica em cloud (não há tamanho informada)	Não informado	<ul style="list-style-type: none"> • Rotação aleatória da imagem original em um intervalo de 0 a 60 graus. • Deslocamento horizontal e vertical aleatório em um intervalo de 0 a 1/10 do tamanho da imagem. • Cisalhamento aleatório em uma faixa de 0,20 radianos. • Inversão aleatória vertical ou horizontal
(Sanchez-Ortiz, 2017)	Microscópio	300	Não informado	Cortar a imagem (Cropping)
(Surya, 2022)	Imagens de microscópio retiradas da base de dados: GLOBE Mosquito Habitat Mapper database by Citizen Scientists throughout North America	10	Não informado	Não informado
(Yanai, 2019)	Microscópio	760	Não informado	Rotação, deslocamento de largura e altura, flip e zoom

(Yanai, 2019)	Imagens de microscópio retiradas da base de dados: GLOBE Mosquito Habitat Mapper database by Citizen Scientists throughout North America	155	Não informado	Não informado
---------------	--	-----	---------------	---------------

Todos os estudos incluídos neste conjunto de dados são compostos por imagens capturadas com a ajuda de um microscópio, zoom acoplado a um dispositivo móvel Android ou com o uso de zoom digital aplicado. Nenhum estudo foi encontrado que utilizasse imagens digitais sem o auxílio de zoom externo, como por exemplo o uso de um aplicativo móvel.

Em relação ao tamanho do conjunto de dados, a maioria dos estudos possui menos de 1.000 imagens, exceto pela pesquisa de Surya (2022), que utilizou mais de 10.000 imagens retiradas de uma base de dados já existente (Figura 22).




Figura 22: Quantidade de imagens no conjunto de dados por pesquisa

Fonte: Autor, 2022

3.3.3. Como os modelos foram treinados?

Tabela 8: Informações sobre o treinamento dos trabalhos encontrados

Referência	Modelo de DL	Épocas	Learning rate	Batch size
(Arista-Jalife,2018)	Modelo próprio (?)	570	0.000001	10
(Azman, 2020)	MobileNetV2	Não informado	Não informado	-
(Hossain, 2022)	VGG16, VGG19, ResNet50, ResNet152, InceptionV3	[10, 30, 50, 70, 100]	0.00001	[5, 10, 20, 30]
(Yanai, 2019)	DenseNet	150	0,01	Não informado
(Sanchez-Ortiz, 2017)	Resnet18, Resnet34	200	1	Não informado
(De Silva, 2020)	ResNet50	200	Não informado	Não informado
(Asmai, 2019)	VGG16, VGG19, ResNet50, InceptionV3	150	Não informado	Não informado
(Munoz, 2018)	Caffenet/AlexNet	Não informado	Não informado	Não informado
(Surya, 2022)	ViT-Base, CvT-13, ConvNeXT, ResNet-18	4 para todos menos o ViT, que foi 7	Não informado	Não informado
(Arista-Jalife,2019)	VGG-16 and VGG-19	1000	0.00001	Não informado

A tabela apresenta informações sobre o treinamento dos trabalhos encontrados, destacando os modelos de Deep Learning utilizados, o número de épocas, a taxa de aprendizado e o tamanho do lote (batch size). Observa-se uma variedade de modelos sendo empregados, como MobileNetV2, VGG16, VGG19, ResNet50, ResNet152, InceptionV3, DenseNet, ResNet18, ResNet34, Caffenet/AlexNet, ViT-Base, CvT-13, ConvNeXT e outros.

Em relação ao número de épocas, os valores variam de 4 a 1000, com a maioria dos trabalhos utilizando um intervalo entre 100 e 200 épocas. A taxa de aprendizado também apresenta uma variação, indo de 0,000001 a 1, sendo que em alguns casos não foi informada. O tamanho do lote (batch size) varia entre 5 e 30, embora em alguns trabalhos essa informação não tenha sido fornecida.

É interessante notar que alguns trabalhos não especificam a quantidade de épocas, taxa de aprendizado e tamanho do lote utilizados, o que dificulta a comparação direta entre eles. No entanto, a tabela fornece uma visão geral dos diferentes modelos e parâmetros adotados nas pesquisas relacionadas ao treinamento de modelos de Deep Learning para as respectivas tarefas estudadas.

3.3.4. Quais os desempenhos relatados?

Os desempenhos foram coletados a partir de dados relatados nos trabalhos relevantes.

Tabela 9: Métricas de avaliação dos trabalhos encontrados

Referência	Modelo de DL	Acurácia	Precisão	Recall	F1-Score
(Arista-Jalife,2018)	Modelo próprio (?)	91%	Não informado	Não informado	Não informado
(Arista-Jalife,2019)	e VGG-16 and VGG-19	88.50%	Não informado	Não informado	Não informado
(Asmai, 2019)	VGG16	81.29%	Não informado	Não informado	Não informado
	VGG19	87.26%			
	ResNet50	86.38%			
	InceptionV3	83.50%			
(Azman, 2020)	MobileNetV2	64.58%	88%	Não informado	Não informado
(De Silva, 2020)	ResNet50	86.65%	Não informado	Não informado	Não informado
(Hossain, 2022)	VGG16	95%	Não informado	Não informado	Não informado
	VGG19	95%			
	ResNet50	96%			
	ResNet152	94%			
	InceptionV3	88%			
(Munoz, 2018)	Caffenet/AlexNet	Não informado	100%	47,4%	Não informado
(Sanchez-Ortiz, 2017)	Alexnet	96.80%	30%	Não informado	Não informado
(Surya, 2022)	ViT-Base	0.6374	0.6061	0.6374	0.5868
	CvT-13	0.6400	0.6292	0.6400	0.6209
	ConvNeXT	0.6563	0.6386	0.6563	0.6355
	ResNet-18	0.5967	0.6034	0.5967	0.5756
(Yanai, 2019)	DenseNet 121	97%	97%	Não informado	Não informado

Os resultados da análise indicam que a maioria dos modelos de ML possui uma boa acurácia, porém as demais métricas não foram informadas ou não apresentaram resultados expressivos para o propósito desta pesquisa. Considerando o alto risco associado à implantação de um modelo de classificação de larvas de

mosquito da dengue, é crucial obter resultados confiáveis, pois erros podem ter consequências catastróficas para vidas humanas.

Além disso, observa-se que as métricas de Recall e F1 Score foram informadas apenas nos artigos de Surya (2022) e Munoz (2018). Por outro lado, trabalhos como os de Yanai (2019), Hossain (2022) e Sanchez-Ortiz (2017) apresentaram resultados consideráveis, uma vez que obtiveram uma acurácia superior a 0,95. No entanto, é importante mencionar que essas abordagens se limitaram à classificação de *Aedes* versus Non-*Aedes*, o que indica a necessidade de expandir a análise para outras espécies de mosquitos.

3.4 Discussão

Nos últimos cinco anos, foram realizadas pesquisas voltadas para o desenvolvimento de modelos capazes de classificar larvas de mosquitos do *Aedes aegypti*. No entanto, a maioria dessas pesquisas concentra-se na classificação de larvas de mosquitos *Aedes* e Non-*aedes*, não abordando especificamente a espécie *Aedes aegypti*. Isso vai contra o princípio de controle e prevenção da dengue, pois omite informações relevantes para o usuário.

Além disso, os modelos encontrados que abordam a espécie *Aedes aegypti* também não realizam a classificação de outros gêneros de mosquitos, como o *Culex*, que é encontrado na zona urbana de Florianópolis e Santa Catarina, por exemplo. Outra questão é o desempenho desses modelos. Os resultados obtidos para a classificação de outros gêneros de mosquitos não foram consideráveis, apresentando níveis de acurácia baixos (64), o que representa um risco significativo para os usuários e coloca vidas humanas em perigo.

A partir dessa análise do estado da arte, observa-se que ainda não há pesquisas relacionadas à classificação de larvas no Brasil, o que pode impactar a coleta de dados, uma vez que as espécies de mosquitos variam de acordo com o país em que a pesquisa foi realizada. A maioria dos trabalhos também utilizou conjuntos de dados relativamente pequenos, com quantidades consideravelmente baixas de imagens (155 a 916), com exceção do estudo de Surya (2022), que coletou mais de 10.000 imagens de fontes online.

Como a classificação de larvas é um processo complexo, a maioria das pesquisas utilizou de imagens de microscópio, zoom acoplado ou zoom digital (60x) para que se fizesse a distinção das larvas de mosquito, o que não funcionaria em um aplicativo móvel

destinado ao uso difundido, já que a maioria dos usuários não teriam acesso ao aparelhamento necessário para equipar suas câmeras com os requisitos necessários para realizarem as predições de maneira efetiva.

As CNNs mais comumente utilizadas são as ResNet-50 e VGG-16 e VGG-19, que são redes com uma grande quantidade de camadas convolucionais, o que também dificulta a portabilidade para dispositivos móveis. Nenhum dos trabalhos utilizou a EfficientNet, mesmo tendo um desempenho melhor segundo os dados apresentados no capítulo 2.2.2.4.

Em termos de desempenho observa-se que a maioria dos trabalhos não chegou a uma acurácia relevante (63-94%), visto que um modelo classificador de larvas de mosquito tem um alto risco pois envolve vidas humanas. Algumas, como (Yanai, 2019), (Hossain, 2022) e (Sanchez-Ortiz, 2017) relatam resultados de acurácia acima de 95%, mas não incluem métricas como Recall ou F1-Score.

Com base no levantamento do estado da arte, observa-se a ausência de um modelo de classificação de larvas de mosquito voltado para a região urbana de Santa Catarina, que seja acessível aos cidadãos por meio de um aplicativo de celular. Além disso, há a necessidade de um modelo que apresente uma acurácia e métricas de desempenho consideradas relevantes para os objetivos deste trabalho.

Ameaças à validade: No entanto, é importante reconhecer que existem ameaças à validade dos resultados neste mapeamento sistemático. Algumas ameaças identificadas foram abordadas por meio de estratégias para minimizar seus impactos:

Viés de publicação: Existe uma tendência de publicação de resultados positivos em detrimento dos resultados negativos, o que pode introduzir um viés nos mapeamentos sistemáticos. No entanto, dado que este mapeamento se concentra no estado da arte e não é influenciado significativamente por essa tendência, o viés de publicação não representa uma ameaça séria neste caso.

Identificação de estudos: Há o risco de omissão de estudos relevantes, o qual foi mitigado por meio da construção cuidadosa de uma estratégia de busca abrangente, que incluiu a utilização de sinônimos relevantes. Além disso, a busca foi conduzida em diversas bases de dados, contribuindo para a mitigação desse risco.

Seleção e extração de dados dos estudos: Foram adotadas medidas para mitigar as ameaças relacionadas à seleção e extração de dados. Isso incluiu a definição detalhada dos critérios de inclusão/exclusão e de qualidade, bem como o estabelecimento de um protocolo rigoroso para a seleção da revisão. Todo o processo de seleção foi realizado e

revisado com cuidado, visando garantir a consistência e a confiabilidade dos dados extraídos.

Essas estratégias foram aplicadas com o intuito de minimizar as ameaças à validade deste mapeamento sistemático, garantindo a confiabilidade e a robustez dos resultados obtidos.

4. Desenvolvimento de modelo de classificação de larvas de mosquito

4.1 Requisitos

Visa-se desenvolver um modelo de classificação de larvas de mosquito. Com objetivo de utilizar este modelo na prevenção da dengue visa se no futuro a implantação deste modelo em um aplicativo Android que permite a classificação a partir de fotos tiradas com a câmera de celular Android para possibilitar que usuários sem a expertise de classificação de larvas detectem se um existe um criadouro de mosquitos na sua residência.

Tabela 10: Requisitos para desenvolver um modelo de Machine Learning

<p>Qual é o problema/necessidade identificado?</p>	<p>A dengue é uma doença endêmica e o Brasil é o país com mais incidência de casos da doença no mundo, tendo quase duas milhões de pessoas afetadas apenas no ano de 2022. Um dos meios de prevenção é evitar que criadouros do mosquito <i>Aedes Aegypti</i>, vetor da doença, se proliferem e formem mosquitos que efetivamente aumentam o número de casos da doença. Normalmente, quando se é detectado um possível criadouro em uma residência (ponto que concentra água parada) com larvas de mosquito, a vigilância epidemiológica é chamada e despacha um profissional. O profissional vai até o local e coleta larvas, levando-as a um centro especializado onde verifica se as larvas são de fato do mosquito <i>Aedes aegypti</i>. O processo é manual e moroso, também requer expertise para que seja detectado de fato a espécie ou gênero do inseto. Um método mais eficiente poderia ajudar a agilizar o processo e, por consequência, evitar que criadouros da doença se formem. Assim, um aplicativo com ajuda de AI possibilitaria o acesso de um cidadão comum a uma ferramenta que faça essa classificação de maneira rápida e fácil.</p>
<p>Ponto de Vista (POV)</p>	<p>O cidadão PRECISA classificar larvas de mosquito do <i>Aedes aegypti</i> PORQUE quer evitar que um criadouro de mosquitos da dengue se forme em sua casa.</p>
<p>Como podemos (HMW)</p>	<p>COMO PODEMOS auxiliar o cidadão a descobrir se a larva de mosquito que encontrou em sua residência pode transmitir a dengue.</p>

De acordo com a notação de descrição de Mitchell (1997), o objetivo deste trabalho é desenvolver um modelo de *deep learning* portátil a um aplicativo móvel e capaz de aprender com a experiência (E) em relação a uma classe de tarefas (T) e com base na medida de desempenho (P). Especificamente, a tarefa (T) consiste em classificar corretamente as larvas de mosquito a partir de fotografias capturadas pela câmera de um dispositivo Android. A experiência (E) é composta por um conjunto de imagens de larvas

de mosquito dos gêneros *Aedes aegypti*, *Aedes albopictus*, *Culex*, bem como objetos não relacionados a larvas de mosquitos, todas elas devidamente rotuladas. Em termos de desempenho (P), espera-se alcançar uma acurácia superior a 95%. O objetivo final é melhorar o desempenho do aplicativo à medida que ele adquire mais experiência, proporcionando resultados precisos e confiáveis na classificação das larvas de mosquito.

Tabela 11: Objetivo, risco e requisitos de um modelo de *Machine Learning*

Objetivo do modelo de ML		
Tarefa	Classificar larvas de mosquitos <i>Aedes Aegypti</i> , <i>Aedes Albopictus</i> e mosquitos do gênero <i>Culex</i> por meio de imagens capturadas de um celular Android.	
Tipo da tarefa	Classificação de imagens (<i>Single-label</i>).	
Categorias	4 categorias	<i>Aedes aegypti</i> <i>Aedes Albopictus</i> <i>Culex sp</i> <i>Non-mosquito</i>
Contexto de uso	O modelo é utilizado por um cidadão como prevenção para a formação de criadouros do mosquito <i>Aedes aegypti</i> em sua residência.	
Risco e requisitos de desempenho		
Risco	Risco Alto A classificação errônea de um criadouro de mosquitos pode ser detrimental para a saúde dos envolvidos.	
Desempenho	O modelo de ML será otimizado para precisão porque precisamos de reduzir o risco de indicar a categoria errada ao usuário levando ele a uma compreensão errada.	
Medidas	Acurácia (total/por categoria)	No mínimo 0.95


4.2 Preparação de dados

Um conjunto de imagens de larvas de mosquitos foi criado em colaboração com o Laboratório de Transmissores de Hematozoários (LTH) da Universidade Federal de Santa Catarina e o Laboratório Central de Saúde Pública (LACEN) de Florianópolis. Os dados coletados foram utilizados em experimentos, nos quais foram comparados aos resultados anteriores para avaliar o desempenho do modelo criado. No futuro, o modelo desenvolvido seria implantado em um aplicativo móvel usando o App Inventor. Os dados incluíam diferentes espécies de larvas de mosquito e objetos não relacionados a larvas de mosquitos, sendo rotulados manualmente de acordo com suas categorias.

Tabela 12: Conjunto de dados coletados para o treinamento dos modelos

Conjunto de dados											
Fonte de dados	Imagens de celular Android capturadas por pesquisadores do GQS/INCoD/UFSC e Laboratório Central de Saúde Pública (LACEN) de Florianópolis e conjuntos de dados da iniciativa computação da escola/INCoD/INE/UFSC										
Quantidade de dados	<p>O conjunto de dados contém no total 2.297 imagens de quatro categorias:</p> <table border="1"> <thead> <tr> <th>Categoria</th> <th>Quantidade</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>698</td> </tr> <tr> <td><i>Aedes Albopitcus</i></td> <td>414</td> </tr> <tr> <td><i>Culex sp</i></td> <td>397</td> </tr> <tr> <td>Nonmosquito</td> <td>788</td> </tr> </tbody> </table>	Categoria	Quantidade	<i>Aedes Aegypti</i>	698	<i>Aedes Albopitcus</i>	414	<i>Culex sp</i>	397	Nonmosquito	788
Categoria	Quantidade										
<i>Aedes Aegypti</i>	698										
<i>Aedes Albopitcus</i>	414										
<i>Culex sp</i>	397										
Nonmosquito	788										
Rotulação de dados	As imagens foram rotuladas por um pesquisador do GQS treinado na classificação de imagens de larvas de mosquito e profissionais formados na área de biologia.										

Tabela 13: Exemplos de imagens coletadas no conjunto de dados separadas por categoria

Exemplo de imagem de <i>Aedes aegypti</i>	Exemplo de imagem de <i>Aedes albopictus</i>
	
Exemplo de imagem da categoria <i>Culex sp</i>	Exemplo de imagem da categoria não mosquito
	

Foram separadas 50 imagens de cada categoria para compor um conjunto de testes. Estas imagens não são utilizadas para nenhum treinamento.

A coleta das imagens de mosquito foi realizada de forma abrangente, incluindo diferentes fundos, níveis de claridade e ângulos de captura. Essa abordagem foi adotada para simular as condições reais de uso de um aplicativo móvel, onde os usuários podem encontrar uma ampla variedade de ambientes e ângulos ao fotografar as larvas de mosquito. Dessa forma, o conjunto de dados abrangeu uma diversidade de cenários, permitindo que o modelo desenvolvido fosse treinado em situações semelhantes às enfrentadas pelos usuários.

Durante a coleta das imagens, foram utilizados diversos modelos de smartphones, abrangendo tanto aparelhos Android quanto iOS. Entre os dispositivos utilizados estavam o Redmi Note 9 Pro, o Samsung Galaxy S10 e o iPhone 7. Essa escolha de diferentes modelos de celular buscou representar a realidade dos usuários, que possuem uma variedade de dispositivos móveis disponíveis. Dessa forma, o conjunto de dados foi enriquecido com imagens capturadas a partir de diferentes câmeras e configurações de hardware, garantindo a diversidade e representatividade das amostras.

É importante ressaltar que, durante o processo de coleta das imagens de mosquito, não foram aplicadas técnicas de *data augmentation*. Essas técnicas envolvem a geração de novas amostras de dados através de manipulações como rotação, espelhamento, zoom, entre outras. No entanto, no contexto deste projeto, optou-se por utilizar apenas as imagens capturadas originalmente, sem realizar alterações adicionais. Essa escolha pode influenciar a capacidade do modelo de generalizar para diferentes variações e variações de dados, mas permite uma avaliação mais precisa do desempenho do modelo com base nas imagens reais coletadas.

4.3 Treinamento

Foram realizados treinamentos de diferentes redes neurais com portabilidade a dispositivos móveis: MobileNetV3, ResNet18 e ResNet34, EfficientNet-B0 e EfficientNet-Lite.

A escolha das redes neurais foi baseada na noção de que devem ser altamente performáticas e ocupar pouco espaço de memória, já que serão disponibilizadas no futuro por meio de um aplicativo móvel.

Todos os modelos foram desenvolvidos e treinados utilizando o ambiente *Jupyter Notebook*, por meio da plataforma *Google Colab*.

4.3.1 Treinamento com MobileNetv3

Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0,001
Curva de loss	

Acurácia Total	93%										
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.95</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.91</td> </tr> <tr> <td><i>Culex</i></td> <td>0.90</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>0.99</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Aedes Aegypti</i>	0.95	<i>Aedes Albopictus</i>	0.91	<i>Culex</i>	0.90	<i>Não mosquito</i>	0.99
Classe	Acurácia										
<i>Aedes Aegypti</i>	0.95										
<i>Aedes Albopictus</i>	0.91										
<i>Culex</i>	0.90										
<i>Não mosquito</i>	0.99										

<p>Matriz de confusão</p>	<p style="text-align: center;">Confusion matrix</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td style="border: none;"></td> <td style="border: none;">AedesAegypti</td> <td style="border: none;">AedesAlbopictus</td> <td style="border: none;">Culex</td> <td style="border: none;">NonMosquito</td> </tr> <tr> <td style="border: none; vertical-align: middle;">Actual</td> <td style="text-align: center;">AedesAegypti</td> <td style="text-align: center;">AedesAlbopictus</td> <td style="text-align: center;">Culex</td> <td style="text-align: center;">NonMosquito</td> </tr> <tr> <td style="border: none;">AedesAegypti</td> <td style="text-align: center;">147</td> <td style="text-align: center;">1</td> <td style="text-align: center;">3</td> <td style="text-align: center;">1</td> </tr> <tr> <td style="border: none;">AedesAlbopictus</td> <td style="text-align: center;">6</td> <td style="text-align: center;">62</td> <td style="text-align: center;">4</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none;">Culex</td> <td style="text-align: center;">1</td> <td style="text-align: center;">4</td> <td style="text-align: center;">86</td> <td style="text-align: center;">1</td> </tr> <tr> <td style="border: none;">NonMosquito</td> <td style="text-align: center;">0</td> <td style="text-align: center;">1</td> <td style="text-align: center;">3</td> <td style="text-align: center;">139</td> </tr> <tr> <td style="border: none;"></td> <td style="border: none; text-align: center;">AedesAegypti</td> <td style="border: none; text-align: center;">AedesAlbopictus</td> <td style="border: none; text-align: center;">Culex</td> <td style="border: none; text-align: center;">NonMosquito</td> </tr> <tr> <td style="border: none;"></td> <td colspan="4" style="border: none; text-align: center;">Predicted</td> </tr> </table>		AedesAegypti	AedesAlbopictus	Culex	NonMosquito	Actual	AedesAegypti	AedesAlbopictus	Culex	NonMosquito	AedesAegypti	147	1	3	1	AedesAlbopictus	6	62	4	0	Culex	1	4	86	1	NonMosquito	0	1	3	139		AedesAegypti	AedesAlbopictus	Culex	NonMosquito		Predicted			
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																					
Actual	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																					
AedesAegypti	147	1	3	1																																					
AedesAlbopictus	6	62	4	0																																					
Culex	1	4	86	1																																					
NonMosquito	0	1	3	139																																					
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																					
	Predicted																																								
<p>Interpretação</p>	<p>Observa-se que nas iterações preliminares obtiveram-se bons resultados do treinamento com um valor de acurácia total de 0.95, ou seja, superior a maioria dos trabalhos encontrados na revisão do estado da arte. Considera-se também uma diferenciação maior das espécies se o resultado for comparado com o de trabalhos anteriores. Em termos de acurácia por categoria podemos observar que o modelo também conseguiu classificar larvas de mosquito do aedes aegypti com 0.93.</p>																																								
<p>Aceitação do modelo</p>	<p>Ainda há necessidade de melhorias na acurácia do modelo para que se possa ser atingida a acurácia de no mínimo 0.95.</p>																																								

4.3.2 Treinamento com ResNet18

Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0,001
Curva de loss	<p>The graph displays the training and validation loss curves over 1400 epochs. The x-axis represents the number of epochs from 0 to 1400, and the y-axis represents the loss from 0.0 to 1.4. The training loss (blue line) starts at approximately 1.4 and decreases steadily to near 0.0. The validation loss (orange line) starts at approximately 0.5, peaks at 1.5 around epoch 300, and then fluctuates between 0.2 and 0.4 for the remainder of the training process.</p>

Acurácia Total	96%										
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.98</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.92</td> </tr> <tr> <td><i>Culex</i></td> <td>0.98</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>1.00</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Aedes Aegypti</i>	0.98	<i>Aedes Albopictus</i>	0.92	<i>Culex</i>	0.98	<i>Não mosquito</i>	1.00
Classe	Acurácia										
<i>Aedes Aegypti</i>	0.98										
<i>Aedes Albopictus</i>	0.92										
<i>Culex</i>	0.98										
<i>Não mosquito</i>	1.00										

<p>Matriz de confusão</p>	<p style="text-align: center;">Confusion matrix</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td style="border: none;"></td> <td style="border: none;"></td> <td style="border: none; text-align: center;">AedesAegypti</td> <td style="border: none; text-align: center;">AedesAlbopictus</td> <td style="border: none; text-align: center;">Culex</td> <td style="border: none; text-align: center;">NonMosquito</td> </tr> <tr> <td style="border: none; text-align: center;">Actual</td> <td style="border: none; text-align: center;">AedesAegypti</td> <td style="text-align: center;">127</td> <td style="text-align: center;">4</td> <td style="text-align: center;">2</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; text-align: center;">AedesAlbopictus</td> <td style="text-align: center;">1</td> <td style="text-align: center;">90</td> <td style="text-align: center;">0</td> <td style="text-align: center;">0</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; text-align: center;">Culex</td> <td style="text-align: center;">1</td> <td style="text-align: center;">3</td> <td style="text-align: center;">88</td> <td style="text-align: center;">0</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; text-align: center;">NonMosquito</td> <td style="text-align: center;">0</td> <td style="text-align: center;">1</td> <td style="text-align: center;">0</td> <td style="text-align: center;">142</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none;"></td> <td style="border: none;"></td> <td style="border: none; text-align: center;">AedesAegypti</td> <td style="border: none; text-align: center;">AedesAlbopictus</td> <td style="border: none; text-align: center;">Culex</td> <td style="border: none; text-align: center;">NonMosquito</td> </tr> <tr> <td style="border: none;"></td> <td style="border: none;"></td> <td colspan="4" style="border: none; text-align: center;">Predicted</td> </tr> </table>			AedesAegypti	AedesAlbopictus	Culex	NonMosquito	Actual	AedesAegypti	127	4	2	0	AedesAlbopictus	1	90	0	0	0	Culex	1	3	88	0	0	NonMosquito	0	1	0	142	0			AedesAegypti	AedesAlbopictus	Culex	NonMosquito			Predicted			
		AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																						
Actual	AedesAegypti	127	4	2	0																																						
AedesAlbopictus	1	90	0	0	0																																						
Culex	1	3	88	0	0																																						
NonMosquito	0	1	0	142	0																																						
		AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																						
		Predicted																																									
<p>Interpretação</p>	<p>O modelo demonstrou um alto nível de acurácia na identificação dos diferentes tipos de mosquitos, com taxas de precisão variando de 92% a 98%, além de ter sido capaz de diferenciar efetivamente objetivos que não eram mosquitos.</p>																																										
<p>Aceitação do modelo</p>	<p>O modelo está dentro dos resultados esperados, apresentando alta acurácia para as categorias, com exceção da categoria do <i>Aedes Albopictus</i>, com a acurácia em 92%.</p>																																										

4.3.3 Treinamento com ResNet34

Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0.001
Curva de loss	

Acurácia Total	95%										
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.97</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.93</td> </tr> <tr> <td><i>Culex</i></td> <td>0.98</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>1.00</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Aedes Aegypti</i>	0.97	<i>Aedes Albopictus</i>	0.93	<i>Culex</i>	0.98	<i>Não mosquito</i>	1.00
Classe	Acurácia										
<i>Aedes Aegypti</i>	0.97										
<i>Aedes Albopictus</i>	0.93										
<i>Culex</i>	0.98										
<i>Não mosquito</i>	1.00										

<p>Matriz de confusão</p>	<p style="text-align: center;">Confusion matrix</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td></td> <td style="background-color: #003366; color: white;">127</td> <td style="background-color: #e6f2ff;">4</td> <td style="background-color: #e6f2ff;">2</td> <td style="background-color: #e6f2ff;">0</td> </tr> <tr> <td style="background-color: #e6f2ff;">AedesAegypti</td> <td style="background-color: #e6f2ff;">3</td> <td style="background-color: #0070c0; color: white;">88</td> <td style="background-color: #e6f2ff;">0</td> <td style="background-color: #e6f2ff;">0</td> </tr> <tr> <td style="background-color: #e6f2ff;">AedesAlbopictus</td> <td style="background-color: #e6f2ff;">1</td> <td style="background-color: #e6f2ff;">2</td> <td style="background-color: #0070c0; color: white;">89</td> <td style="background-color: #e6f2ff;">0</td> </tr> <tr> <td style="background-color: #e6f2ff;">Culex</td> <td style="background-color: #e6f2ff;">0</td> <td style="background-color: #e6f2ff;">1</td> <td style="background-color: #e6f2ff;">0</td> <td style="background-color: #003366; color: white;">142</td> </tr> <tr> <td style="background-color: #e6f2ff;">NonMosquito</td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td></td> <td style="background-color: #e6f2ff;">AedesAegypti</td> <td style="background-color: #e6f2ff;">AedesAlbopictus</td> <td style="background-color: #e6f2ff;">Culex</td> <td style="background-color: #e6f2ff;">NonMosquito</td> </tr> </table> <p style="text-align: center;">Actual</p> <p style="text-align: center;">Predicted</p>		127	4	2	0	AedesAegypti	3	88	0	0	AedesAlbopictus	1	2	89	0	Culex	0	1	0	142	NonMosquito						AedesAegypti	AedesAlbopictus	Culex	NonMosquito
	127	4	2	0																											
AedesAegypti	3	88	0	0																											
AedesAlbopictus	1	2	89	0																											
Culex	0	1	0	142																											
NonMosquito																															
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																											
<p>Interpretação</p>	<p>O resultado foi positivo e melhor do que as tecnologias apresentadas anteriormente, com porcentagem de acurácia variando de 93-98% por espécie de mosquito. O modelo também se mostrou capaz de definir objetos que não são mosquitos.</p>																														
<p>Aceitação do modelo</p>	<p>O modelo obteve ótimos resultados, mas novamente a categoria do Aedes Albopictus, por mais que tenha uma acurácia maior se comparada a tecnologia anterior, ainda não atinge os 95% necessários.</p>																														

4.3.4 Treinamento com EfficientNetLite

Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0.001
Curva de loss	<p>The graph displays the loss curves for training and validation over 800 epochs. The y-axis represents the loss value, ranging from 0.0 to 3.5. The x-axis represents the number of epochs, ranging from 0 to 800. The training loss (blue line) starts at approximately 3.8 and rapidly decreases, crossing the validation loss (orange line) around epoch 100, and continues to decrease towards 0.0. The validation loss starts at approximately 1.5 and decreases to about 0.25 by epoch 800, showing some minor fluctuations.</p>

Acurácia Total	95%										
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.96</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.90</td> </tr> <tr> <td><i>Culex</i></td> <td>0.93</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>1.00</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Aedes Aegypti</i>	0.96	<i>Aedes Albopictus</i>	0.90	<i>Culex</i>	0.93	<i>Não mosquito</i>	1.00
Classe	Acurácia										
<i>Aedes Aegypti</i>	0.96										
<i>Aedes Albopictus</i>	0.90										
<i>Culex</i>	0.93										
<i>Não mosquito</i>	1.00										

<p>Matriz de confusão</p>	<p style="text-align: center;">Confusion matrix</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td style="border: none;"></td> <td style="border: none;">AedesAegypti</td> <td style="border: none;">AedesAlbopictus</td> <td style="border: none;">Culex</td> <td style="border: none;">NonMosquito</td> </tr> <tr> <td style="border: none; vertical-align: middle;">Actual</td> <td style="text-align: center;">125</td> <td style="text-align: center;">5</td> <td style="text-align: center;">3</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; vertical-align: middle;">AedesAlbopictus</td> <td style="text-align: center;">2</td> <td style="text-align: center;">86</td> <td style="text-align: center;">3</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; vertical-align: middle;">Culex</td> <td style="text-align: center;">3</td> <td style="text-align: center;">4</td> <td style="text-align: center;">85</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; vertical-align: middle;">NonMosquito</td> <td style="text-align: center;">0</td> <td style="text-align: center;">1</td> <td style="text-align: center;">0</td> <td style="text-align: center;">142</td> </tr> <tr> <td style="border: none;"></td> <td style="border: none; text-align: center;">AedesAegypti</td> <td style="border: none; text-align: center;">AedesAlbopictus</td> <td style="border: none; text-align: center;">Culex</td> <td style="border: none; text-align: center;">NonMosquito</td> </tr> <tr> <td style="border: none;"></td> <td colspan="4" style="border: none; text-align: center;">Predicted</td> </tr> </table>		AedesAegypti	AedesAlbopictus	Culex	NonMosquito	Actual	125	5	3	0	AedesAlbopictus	2	86	3	0	Culex	3	4	85	0	NonMosquito	0	1	0	142		AedesAegypti	AedesAlbopictus	Culex	NonMosquito		Predicted			
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																
Actual	125	5	3	0																																
AedesAlbopictus	2	86	3	0																																
Culex	3	4	85	0																																
NonMosquito	0	1	0	142																																
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																
	Predicted																																			
<p>Interpretação</p>	<p>Observa-se que nas iterações anteriores obtiveram-se bons resultados do treinamento com um valor de acurácia total de 0.95, ou seja, superior a maioria dos trabalhos encontrados na revisão do estado da arte. Considera-se também uma diferenciação maior das espécies se o resultado for comparado com o de trabalhos anteriores.</p> <p>Em termos de acurácia por categoria podemos observar que o modelo também conseguiu classificar larvas de mosquito do aedes aegypti com 0.95.</p>																																			
<p>Aceitação do modelo</p>	<p>Ainda há necessidade de melhorias na acurácia do modelo para que se possa ser atingida a acurácia de no mínimo 0.95.</p>																																			

4.3.5 Treinamento com EfficientNetB0

Conjunto de dados coletado e rotulado	
Quantidade de dados	2297 imagens divididas em quatro grupos
Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0.001
Curva de loss	

Acurácia Total	95%										
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.93</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.90</td> </tr> <tr> <td><i>Culex</i></td> <td>0.94</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>1.00</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Aedes Aegypti</i>	0.93	<i>Aedes Albopictus</i>	0.90	<i>Culex</i>	0.94	<i>Não mosquito</i>	1.00
Classe	Acurácia										
<i>Aedes Aegypti</i>	0.93										
<i>Aedes Albopictus</i>	0.90										
<i>Culex</i>	0.94										
<i>Não mosquito</i>	1.00										

<p>Matriz de confusão</p>	<p style="text-align: center;">Confusion matrix</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td style="border: none;"></td> <td style="border: none;">AedesAegypti</td> <td style="border: none;">AedesAlbopictus</td> <td style="border: none;">Culex</td> <td style="border: none;">NonMosquito</td> </tr> <tr> <td style="border: none; vertical-align: middle;">Actual</td> <td style="text-align: center;">129</td> <td style="text-align: center;">2</td> <td style="text-align: center;">2</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; vertical-align: middle;">AedesAlbopictus</td> <td style="text-align: center;">7</td> <td style="text-align: center;">81</td> <td style="text-align: center;">3</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; vertical-align: middle;">Culex</td> <td style="text-align: center;">2</td> <td style="text-align: center;">5</td> <td style="text-align: center;">85</td> <td style="text-align: center;">0</td> </tr> <tr> <td style="border: none; vertical-align: middle;">NonMosquito</td> <td style="text-align: center;">0</td> <td style="text-align: center;">2</td> <td style="text-align: center;">0</td> <td style="text-align: center;">141</td> </tr> <tr> <td style="border: none;"></td> <td style="border: none; text-align: center;">AedesAegypti</td> <td style="border: none; text-align: center;">AedesAlbopictus</td> <td style="border: none; text-align: center;">Culex</td> <td style="border: none; text-align: center;">NonMosquito</td> </tr> <tr> <td style="border: none;"></td> <td colspan="4" style="border: none; text-align: center;">Predicted</td> </tr> </table>		AedesAegypti	AedesAlbopictus	Culex	NonMosquito	Actual	129	2	2	0	AedesAlbopictus	7	81	3	0	Culex	2	5	85	0	NonMosquito	0	2	0	141		AedesAegypti	AedesAlbopictus	Culex	NonMosquito		Predicted			
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																
Actual	129	2	2	0																																
AedesAlbopictus	7	81	3	0																																
Culex	2	5	85	0																																
NonMosquito	0	2	0	141																																
	AedesAegypti	AedesAlbopictus	Culex	NonMosquito																																
	Predicted																																			
<p>Interpretação</p>	<p>Observa-se que os resultados foram ainda melhores do que os modelos pré-treinados anteriormente. A acurácia da categoria do Aedes Albopictus ainda não chegou a 95%, mas tem melhorado se comparado às outras tentativas.</p>																																			
<p>Aceitação do modelo</p>	<p>Ainda há necessidade de melhorias na acurácia do modelo para que se possa ser atingida a acurácia de no mínimo 0.95 em todas as categorias.</p>																																			

4.4 Testes de desempenho

Seguindo a norma ISO/IEC 4213 (2022), foram realizados testes com os modelos treinados predizendo a classificação de imagens novas não utilizadas no treinamento/validação.

4.4.1 Preparação do teste

O conjunto de teste é composto por um total de 200 imagens, com as características de qualidade de dados conforme descrito na Tabela 22.

Tabela 22: Características do conjunto de dados de teste

Característica	Especificação
Número total de imagens no conjunto de testes	200 imagens

Distribuição do conjunto de testes	50 imagens de cada classe. A classe 'non-mosquito' inclui imagens de objetos/insetos visualmente semelhantes a larvas de mosquito para avaliar a especificidade.
Uso das imagens	Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas por pesquisadores da iniciativa Computação na Escola/INCoD/INE/UFSC em cooperação com biólogos do LTH/UFSC e CRLAB/LACEN/SC
Fonte	Essas imagens não foram usadas durante o treinamento do modelo. As imagens foram coletadas por pesquisadores da iniciativa Computação na Escola/INCoD/INE/UFSC em cooperação com biólogos do LTH/UFSC e CRLAB/LACEN/SC
Verdade fundamental	As imagens foram rotuladas por pesquisadores da iniciativa Computação na Escola/INCoD/INE/UFSC em cooperação com biólogos do LTH/UFSC e CRLAB/LACEN/SC.
Pré-processamento/ aumento de dados	Nenhum pré-processamento/aumento de dados foi aplicado ao conjunto de teste.
Precisão do conjunto de teste	A precisão dos rótulos das imagens é de 100%.
Completeness do conjunto de teste	As imagens no conjunto de dados cobrem todas as classes de interesse com uma variedade de exemplos.
Exclusividade do conjunto de teste	Não há duplicatas de imagens no conjunto de teste.
Consistência do conjunto de teste	Uniformidade das informações das imagens separando classes em pastas. As imagens são nomeadas por classe e número.
Autenticidade do conjunto de teste	As imagens foram coletadas localmente tirando fotos das espécies encontradas na região de interesse (Florianópolis/SC) As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso.
Robustez do conjunto de testes	As imagens foram coletadas variando o plano de fundo, ângulos, iluminação, etc., a fim de evitar efeitos de canalização.
Confidencialidade do conjunto de teste	Não aplicável

Métricas. Para avaliar o desempenho dos modelos, foram utilizadas as seguintes métricas:

- Acurácia, para avaliar o desempenho geral;
- Precisão e recall para apoiar a compreensão de como o modelo lida com falsos positivos e falsos negativos;
- Pontuação F1, a média harmônica dos resultados de precisão e recuperação; a especificidade foi medida para identificar corretamente exemplos negativos e minimizar falsos positivos.

Ambiente de execução. O teste foi executado usando *Jupyter Notebooks* no *Google Colab*.

4.4.2 Resultado dos testes com MobileNetV3

Testes																										
Acurácia total	80,5%																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.76</td> <td>50</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.80</td> <td>50</td> </tr> <tr> <td><i>Culex</i></td> <td>0.74</td> <td>50</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>0.94</td> <td>50</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Aedes Aegypti</i>	0.76	50	<i>Aedes Albopictus</i>	0.80	50	<i>Culex</i>	0.74	50	<i>Não mosquito</i>	0.94	50										
Classe	Acurácia	Amostras																								
<i>Aedes Aegypti</i>	0.76	50																								
<i>Aedes Albopictus</i>	0.80	50																								
<i>Culex</i>	0.74	50																								
<i>Não mosquito</i>	0.94	50																								
Matriz de confusão	<p style="text-align: center;">Confusion matrix</p> <table border="1"> <thead> <tr> <th></th> <th>Ae. aegypti</th> <th>Ae. albopictus</th> <th>Culex</th> <th>Nonmosquito</th> </tr> </thead> <tbody> <tr> <th>Ae. aegypti</th> <td>38</td> <td>6</td> <td>6</td> <td>0</td> </tr> <tr> <th>Ae. albopictus</th> <td>11</td> <td>28</td> <td>8</td> <td>3</td> </tr> <tr> <th>Culex</th> <td>1</td> <td>1</td> <td>48</td> <td>0</td> </tr> <tr> <th>Nonmosquito</th> <td>0</td> <td>0</td> <td>3</td> <td>47</td> </tr> </tbody> </table>		Ae. aegypti	Ae. albopictus	Culex	Nonmosquito	Ae. aegypti	38	6	6	0	Ae. albopictus	11	28	8	3	Culex	1	1	48	0	Nonmosquito	0	0	3	47
	Ae. aegypti	Ae. albopictus	Culex	Nonmosquito																						
Ae. aegypti	38	6	6	0																						
Ae. albopictus	11	28	8	3																						
Culex	1	1	48	0																						
Nonmosquito	0	0	3	47																						
Precisão	81%																									
Recall	81%																									
F1 score	81%																									

4.4.3 Resultado dos testes com Resnet18

Testes																										
Acurácia total	90,5%																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.90</td> <td>50</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.85</td> <td>50</td> </tr> <tr> <td><i>Culex</i></td> <td>0.89</td> <td>50</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>0.98</td> <td>50</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Aedes Aegypti</i>	0.90	50	<i>Aedes Albopictus</i>	0.85	50	<i>Culex</i>	0.89	50	<i>Não mosquito</i>	0.98	50										
Classe	Acurácia	Amostras																								
<i>Aedes Aegypti</i>	0.90	50																								
<i>Aedes Albopictus</i>	0.85	50																								
<i>Culex</i>	0.89	50																								
<i>Não mosquito</i>	0.98	50																								
Matriz de confusão	<p>Confusion matrix</p> <table border="1"> <thead> <tr> <th></th> <th>Ae. aegypti</th> <th>Ae. albopictus</th> <th>Culex</th> <th>Nonmosquito</th> </tr> </thead> <tbody> <tr> <th>Ae. aegypti</th> <td>43</td> <td>6</td> <td>1</td> <td>0</td> </tr> <tr> <th>Ae. albopictus</th> <td>5</td> <td>40</td> <td>5</td> <td>0</td> </tr> <tr> <th>Culex</th> <td>0</td> <td>1</td> <td>48</td> <td>1</td> </tr> <tr> <th>Nonmosquito</th> <td>0</td> <td>0</td> <td>0</td> <td>50</td> </tr> </tbody> </table>		Ae. aegypti	Ae. albopictus	Culex	Nonmosquito	Ae. aegypti	43	6	1	0	Ae. albopictus	5	40	5	0	Culex	0	1	48	1	Nonmosquito	0	0	0	50
	Ae. aegypti	Ae. albopictus	Culex	Nonmosquito																						
Ae. aegypti	43	6	1	0																						
Ae. albopictus	5	40	5	0																						
Culex	0	1	48	1																						
Nonmosquito	0	0	0	50																						
Precisão	90%																									
Recall	91%																									
F1 score	90%																									

4.4.4 Resultado dos testes Resnet34

Testes																										
Acurácia total	86,5%																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.91</td> <td>50</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.78</td> <td>50</td> </tr> <tr> <td><i>Culex</i></td> <td>0.80</td> <td>50</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>0.98</td> <td>50</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Aedes Aegypti</i>	0.91	50	<i>Aedes Albopictus</i>	0.78	50	<i>Culex</i>	0.80	50	<i>Não mosquito</i>	0.98	50										
Classe	Acurácia	Amostras																								
<i>Aedes Aegypti</i>	0.91	50																								
<i>Aedes Albopictus</i>	0.78	50																								
<i>Culex</i>	0.80	50																								
<i>Não mosquito</i>	0.98	50																								
Matriz de confusão	<p style="text-align: center;">Confusion matrix</p> <table border="1"> <thead> <tr> <th></th> <th>Ae. aegypti</th> <th>Ae. albopictus</th> <th>Culex</th> <th>Nonmosquito</th> </tr> </thead> <tbody> <tr> <th>Ae. aegypti</th> <td style="background-color: #004a80; color: white;">42</td> <td style="background-color: #4682b4;">8</td> <td style="background-color: #add8e6;">0</td> <td style="background-color: #add8e6;">0</td> </tr> <tr> <th>Ae. albopictus</th> <td style="background-color: #add8e6;">3</td> <td style="background-color: #0070c0; color: white;">35</td> <td style="background-color: #add8e6;">11</td> <td style="background-color: #add8e6;">1</td> </tr> <tr> <th>Culex</th> <td style="background-color: #add8e6;">1</td> <td style="background-color: #add8e6;">2</td> <td style="background-color: #004a80; color: white;">47</td> <td style="background-color: #add8e6;">0</td> </tr> <tr> <th>Nonmosquito</th> <td style="background-color: #add8e6;">0</td> <td style="background-color: #add8e6;">0</td> <td style="background-color: #add8e6;">1</td> <td style="background-color: #004a80; color: white;">49</td> </tr> </tbody> </table> <p style="text-align: center;">Predicted label</p>		Ae. aegypti	Ae. albopictus	Culex	Nonmosquito	Ae. aegypti	42	8	0	0	Ae. albopictus	3	35	11	1	Culex	1	2	47	0	Nonmosquito	0	0	1	49
	Ae. aegypti	Ae. albopictus	Culex	Nonmosquito																						
Ae. aegypti	42	8	0	0																						
Ae. albopictus	3	35	11	1																						
Culex	1	2	47	0																						
Nonmosquito	0	0	1	49																						
Precisão	87%																									
Recall	86%																									
F1 score	86%																									

4.4.5 Resultado dos testes EfficientNetLite

Testes																										
Acurácia total	84%																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.82</td> <td>50</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.79</td> <td>50</td> </tr> <tr> <td><i>Culex</i></td> <td>0.76</td> <td>50</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>1.00</td> <td>50</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Aedes Aegypti</i>	0.82	50	<i>Aedes Albopictus</i>	0.79	50	<i>Culex</i>	0.76	50	<i>Não mosquito</i>	1.00	50										
Classe	Acurácia	Amostras																								
<i>Aedes Aegypti</i>	0.82	50																								
<i>Aedes Albopictus</i>	0.79	50																								
<i>Culex</i>	0.76	50																								
<i>Não mosquito</i>	1.00	50																								
Matriz de confusão	<p>Confusion matrix</p> <table border="1"> <thead> <tr> <th></th> <th>Ae. aegypti</th> <th>Ae. albopictus</th> <th>Culex</th> <th>Nonmosquito</th> </tr> </thead> <tbody> <tr> <th>Ae. aegypti</th> <td>34</td> <td>8</td> <td>8</td> <td>0</td> </tr> <tr> <th>Ae. albopictus</th> <td>4</td> <td>35</td> <td>11</td> <td>0</td> </tr> <tr> <th>Culex</th> <td>0</td> <td>4</td> <td>46</td> <td>0</td> </tr> <tr> <th>Nonmosquito</th> <td>0</td> <td>0</td> <td>0</td> <td>50</td> </tr> </tbody> </table>		Ae. aegypti	Ae. albopictus	Culex	Nonmosquito	Ae. aegypti	34	8	8	0	Ae. albopictus	4	35	11	0	Culex	0	4	46	0	Nonmosquito	0	0	0	50
	Ae. aegypti	Ae. albopictus	Culex	Nonmosquito																						
Ae. aegypti	34	8	8	0																						
Ae. albopictus	4	35	11	0																						
Culex	0	4	46	0																						
Nonmosquito	0	0	0	50																						
Precisão	84%																									
Recall	84%																									
F1 score	84%																									

4.4.6 Resultado dos testes EfficientNetB0

Testes																										
Acurácia total	90%																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Aedes Aegypti</i></td> <td>0.92</td> <td>50</td> </tr> <tr> <td><i>Aedes Albopictus</i></td> <td>0.86</td> <td>50</td> </tr> <tr> <td><i>Culex</i></td> <td>0.83</td> <td>50</td> </tr> <tr> <td><i>Não mosquito</i></td> <td>0.98</td> <td>50</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Aedes Aegypti</i>	0.92	50	<i>Aedes Albopictus</i>	0.86	50	<i>Culex</i>	0.83	50	<i>Não mosquito</i>	0.98	50										
Classe	Acurácia	Amostras																								
<i>Aedes Aegypti</i>	0.92	50																								
<i>Aedes Albopictus</i>	0.86	50																								
<i>Culex</i>	0.83	50																								
<i>Não mosquito</i>	0.98	50																								
Matriz de confusão	<p style="text-align: center;">Confusion matrix</p> <table border="1"> <thead> <tr> <th></th> <th>Ae. aegypti</th> <th>Ae. albopictus</th> <th>Culex</th> <th>Nonmosquito</th> </tr> </thead> <tbody> <tr> <th>Ae. aegypti</th> <td>35</td> <td>7</td> <td>8</td> <td>0</td> </tr> <tr> <th>Ae. albopictus</th> <td>3</td> <td>44</td> <td>2</td> <td>1</td> </tr> <tr> <th>Culex</th> <td>0</td> <td>0</td> <td>50</td> <td>0</td> </tr> <tr> <th>Nonmosquito</th> <td>0</td> <td>0</td> <td>0</td> <td>50</td> </tr> </tbody> </table>		Ae. aegypti	Ae. albopictus	Culex	Nonmosquito	Ae. aegypti	35	7	8	0	Ae. albopictus	3	44	2	1	Culex	0	0	50	0	Nonmosquito	0	0	0	50
	Ae. aegypti	Ae. albopictus	Culex	Nonmosquito																						
Ae. aegypti	35	7	8	0																						
Ae. albopictus	3	44	2	1																						
Culex	0	0	50	0																						
Nonmosquito	0	0	0	50																						
Precisão	90%																									
Recall	90%																									
F1 score	89%																									

4.5 Discussão

Os resultados obtidos durante o treinamento dos modelos de machine learning estão documentados na tabela 14. Essa tabela fornece uma visão abrangente da performance dos modelos em relação a diferentes métricas de avaliação, incluindo acurácia, precisão, recall e F1-score. Através desses dados, é possível realizar uma análise detalhada do desempenho dos modelos em cada uma dessas métricas, permitindo uma compreensão mais completa de sua eficácia.

Tabela 14: Resultado dos treinamentos de diferentes modelos.

Resultados da validação do desempenho	Acurácia total	Precisão	Recall	F1-Score
MobileNetV3	94%	93%	94%	94%
Resnet18	97%	95%	97%	96%
Resnet34	97%	97%	97%	97%
EfficientNetLite	95%	94%	95%	95%
EfficientNetB0	94%	94%	94%	94%

Os modelos apresentados na tabela 14 demonstraram resultados promissores, com taxas de acurácia acima de 94%. Esses modelos foram projetados e otimizados para atender às demandas e restrições dos dispositivos móveis, levando em consideração suas limitações de recursos e capacidade de processamento.

A Tabela 15 exibe os resultados do teste desses modelos, utilizando um conjunto de 50 imagens de cada uma das 4 classes.

Tabela 15: Resultado do teste dos modelos.

Resultados da validação do desempenho	Acurácia total	Precisão	Recall	F1-Score
MobileNetV3	80,5%	81%	81%	81%
Resnet18	90,5%	90%	91%	90%
Resnet34	86,5%	87%	86%	86%
EfficientNetLite	82,5%	84%	82%	82%
EfficientNetB0	90%	90%	90%	89%

Os modelos Resnet18 e EfficientNetB0 demonstraram o melhor desempenho, atingindo uma acurácia superior a 90% nos testes de classificação de larvas de mosquitos. Além disso, outras métricas como precisão, *recall* e F1-score também apresentaram resultados notáveis, com valores de 90%, 91% e 90% para Resnet18, e 90%, 90% e 89% para EfficientNetB0, respectivamente.

Esses resultados são particularmente significativos considerando que os modelos foram desenvolvidos com foco em dispositivos móveis e foram capazes de fornecer uma classificação detalhada por espécie de mosquito (*Aedes Aegypti*, *Aedes Albopictus*, *Culex sp.*). Mesmo em comparação com trabalhos correlatos, que utilizam conjuntos de dados com imagens de microscópio, classificação binária entre *Aedes* e não-*Aedes* e redes neurais mais complexas, os resultados obtidos pelos modelos Resnet18 e EfficientNetB0 se mostraram semelhantes.

Embora tenham sido obtidos resultados muito promissores durante o treinamento, nos testes os modelos não atingiram o desempenho esperado conforme especificado nos requisitos (acurácia <95%) chegando a resultados de 90,5% com ResNet18 e 90% com EfficientNetB0. Portanto, é necessário ter cautela ao considerar o uso desses modelos em cenários reais, levando em consideração que a aplicação em questão apresenta um grau de risco elevado, mas a acurácia de 90% pode ser considerada aceitável dependendo do caso de uso em questão.

Ameaças à validade. Existem ameaças à validade que devem ser consideradas em relação aos resultados obtidos. No que se refere ao viés de seleção, foi buscada a criação de uma amostra diversificada e representativa de imagens, abrangendo diferentes cenários e condições. No entanto, é importante reconhecer que o conjunto de dados utilizado pode não ser completamente

abrangente, o que pode limitar a generalização dos resultados para todos os contextos possíveis. Além disso, embora um tamanho de amostra considerável tenha sido utilizado, é importante destacar que existem abordagens existentes na literatura que empregam conjuntos de dados maiores. Outra ameaça é o viés de pré-processamento dos dados, onde foram aplicadas técnicas padronizadas a todos os modelos comparados para evitar distorções. Além disso, foram adotados parâmetros de treinamento consistentes para garantir uma comparação justa entre os modelos. Por fim, é importante mencionar o viés das métricas de avaliação, onde várias métricas padrão foram utilizadas para avaliar diferentes aspectos do desempenho do modelo. No entanto, é necessário considerar as limitações inerentes a cada métrica e interpretar os resultados de forma crítica. Ao levar em conta essas ameaças à validade, pode-se obter uma compreensão mais abrangente e realista dos resultados alcançados.

5. Conclusão

Por meio de uma análise da fundamentação teórica sobre mosquitos, dengue e deep learning (O1) e um mapeamento do estado da arte na classificação de larvas de mosquito com *deep learning* (O2), foram estabelecidas bases para o desenvolvimento do estudo. Referente ao OE3 foram desenvolvidos modelos de classificação de larvas de mosquito utilizando *deep learning* com base em um conjunto de dados preparados especialmente para esta pesquisa. E embora os resultados de validação da maioria dos modelos atingiram o requisito, os resultados dos testes com as melhores acurácias foram de 90,5% dos modelos EfficientNetB0 e ResNet18, abaixo do requisito proposto de 95%. Este resultado indica a necessidade de aprimoramentos para melhorar a acurácia dos modelos. Apesar disso, os modelos ainda apresentam um desempenho promissor e podem ser aplicados com resultados significativos na classificação de larvas de mosquito ($\geq 90\%$), mesmo não tendo atingido o requisito de 95%.

Os resultados deste trabalho apresentam benefícios inéditos, uma vez que o modelo desenvolvido é capaz de classificar as larvas de mosquito de três espécies distintas: *Aedes aegypti*, *Aedes albopictus* e *Culex sp.* Ao contrário dos trabalhos correlatos que se limitaram à classificação de *Aedes* versus Não-*Aedes*, essa abordagem mais abrangente permite uma identificação mais precisa das espécies de mosquito, o que é crucial para a implementação de estratégias de controle mais direcionadas. Além disso, destaca-se que este trabalho empregou redes neurais mais leves, buscando a viabilidade de implementação em um aplicativo móvel e do uso das imagens feitas diretamente com

a câmera do celular, sem o uso de *zoom* físico ou digital. Essa abordagem tem o potencial de beneficiar significativamente a população, facilitando o acesso a um classificador eficiente e proporcionando uma ferramenta valiosa para profissionais de saúde pública e outros envolvidos no controle de doenças transmitidas por mosquitos.

Existem oportunidades promissoras para pesquisas futuras neste campo. A acurácia do modelo tem grandes chances de ser melhorada por meio do aumento da quantidade de dados de treinamento e do refinamento das técnicas de pré-processamento. Além disso, a aplicação dos modelos treinados em um aplicativo é um passo importante para a disseminação e utilização em larga escala. Isso permitirá que profissionais de saúde, autoridades locais e até mesmo a população em geral tenham acesso fácil e rápido a essa ferramenta de classificação de larvas de mosquito, auxiliando no monitoramento e controle eficaz de doenças como a dengue. Com essas melhorias e avanços contínuos, espera-se que o uso de deep learning na identificação de mosquitos e larvas continue a evoluir e contribuir para a saúde pública de forma significativa.

REFERÊNCIAS

AMERSHI, S. et al. Guidelines for Human-AI Interaction. In: CHI '19: Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems. New York: Association for Computing Machinery, 2019. p. 1-13.

BAR, Ananya; ANDREW, J. Morphology and Morphometry of Aedes aegypti Larvae. Annual Research & Review in Biology, v. 3, n. 1, p. 1-21, 2013. Disponível em: <https://journalarrb.com/index.php/ARRB/article/view/24602>. Acesso em: 08 nov. 2022.

BASIC APPLICATION IN PYTHON. In: Proceedings of the 10th International Conference on Digital Strategies for, [s.d.]. [informações indisponíveis].

BAŞTANLAR, Yalin; ÖZUYSAL, M. Introduction to Machine Learning. 2013.

BIOGENTS. O ciclo de vida dos mosquitos. Disponível em: <https://eu.biogents.com/o-ciclo-de-vida-dos-mosquitos/?lang=pt-br>. Acesso em: 08 nov. 2022.

CDC. About Malaria. Disponível em: <https://www.cdc.gov/malaria/about/biology/index.html#:~:text=Like%20all%20mosquitoes%20anopheles%20mosquitoes,Anopheles%20mosquito%20may%20carry%20malari>a.. Acesso em: 30 set. 2022.

CHOLLET, Francois. Building powerful image classification models using very little data. 2016. Disponível em: <https://blog.keras.io/building-powerful-image-classification-models-using-very-little-data.html>. Acesso em: 01 out. 2022.

CONSOLI, RAGB, OLIVEIRA, RL. Principais mosquitos de importância sanitária no Brasil. Rio de Janeiro: Editora FIOCRUZ, 1994. 228 p. ISBN 85-85676-03-5. Disponível em: <http://books.scielo.org>.

COVISA. (2020). Ciclo de vida do mosquito Culex [PDF]. Disponível em: https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/Pernilongo_2020.pdf. Acesso em: 01 out. 2022.

DEEPAI. What is Machine Learning? 2019. Disponível em: <https://deepai.org/machine-learning-glossary-and-terms/machine-learning>. Acesso em: 01 out. 2022.

DENGUEVIRUS.NET. Life Cycle of Aedes aegypti. Disponível em: <http://www.denguevirusnet.com/life-cycle-of-aedes-aegypti.html>. Acesso em: 30 set. 2022.

DIVE, Informe Epidemiológico nº16/2023. Disponível em: <https://dive.sc.gov.br/phocadownload/doencas-agrivos/Dengue/Informes/2023/Informe-DengueCZ16-2023.pdf> Acesso em 05 jun. 2023.

EGID, B. et al. Review of the ecology and behaviour of Aedes aegypti and Aedes albopictus in Western Africa and implications for vector control. Current Research in Parasitology & Vector-Borne Diseases, v. 2, 2022.

ESCOVEDO, T. Machine Learning: Conceitos e Modelos - Parte I: Aprendizado Supervisionado. 2020. Disponível em: <https://tatianaesc.medium.com/machine-learning-conceitos-e-modelos-f0373bf4f445>. Acesso em: 10 jun. 2023.

EUROPEAN CENTRE FOR DISEASE PREVENTION AND CONTROL. Dengue worldwide overview. Disponível em: <https://www.ecdc.europa.eu/en/dengue-monthly>. Acesso em: 29 ago. 2022.

FIOCRUZ. (2016). O *Aedes aegypti* só se alimenta de sangue? Disponível em: <https://portal.fiocruz.br/pergunta/o-aedes-aegypti-so-se-alimenta-de-sangue>. Acesso em: 10 jun. 2023.

FUNASA. Instruções para Pessoal de combate ao Vetor - Manual de Normas Técnicas, 2001. Disponível em: https://bvsmms.saude.gov.br/bvs/publicacoes/funasa/man_dengue.pdf. Acesso em: 02 dez. 2022.

GLOBE. A series of mosquito tutorials - Identifying species. 2022. Disponível em: <https://observer.globe.gov/documents/19589576/8c9e4a31-ac81-48ff-82aa-8d07a86babc2>. Acesso em: 02 dez. 2022.

GOOGLE. (2020). Higher Accuracy on Vision Models with EfficientNet-Lite.

<https://blog.tensorflow.org/2020/03/higher-accuracy-on-vision-models-with-efficientnet-lite.html> Acesso em: 10 jun. 2023.

GRESSE VON WANGENHEIM, C., VON WANGENHEIM, A. (2021). Visão geral de um processo interativo centrado no ser humano para ensinar aprendizado de máquina no ensino fundamental e médio. Disponível em <http://www.gqs.ufsc.br/files/2020/02/GQSTemplate-RelatorioTecnico-HumanCentricProcesses-v10.pdf>. Acesso em: 10 jun. 2023.

GUNATHILAKA, Nayana. Illustrated key to the adult female Anopheles (Diptera: Culicidae) mosquitoes of Sri Lanka. *Applied Entomology and Zoology*, v. 52, p. 69-77, 2017.

GUO, Y. et al. SpotTune: Transfer Learning Through Adaptive Fine-Tuning. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Long Beach, CA, USA, 2019.

HARBACH, R. E. The Phylogeny and Classification of Anopheles. In: *Anopheles mosquitoes - New insights into malaria vectors*. IntechOpen, 2013.

HOWARD, ANDREW G. et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv:1704.04861. 2017.

IBM. What are neural networks? 2020. Disponível em: <https://www.ibm.com/cloud/learn/neural-networks>. Acesso em: 08 nov. 2022.

JEONG, Yoon woo. ResNet: The Most Popular Network in the Computer-Vision Era. 2020. Disponível em: <https://towardsdatascience.com/resnet-the-most-popular-network-in-computer-vision-era-973df3e92809>. Acesso em: 27 nov. 2022.

KAIMING HE et al. Deep Residual Learning for Image Recognition. arXiv:1512.03385. 2015.

KAMRAN, M. Difference between major mosquito species (Anophele, Culex and Aedes sp.). 2017. Disponível em: <https://www.slideshare.net/ksial01/difference-between-major-mosquito-species-anophele-culex-and-aedes-sp>. Acesso em: 08 nov. 2022.

KULARATNE, S. Dengue fever. *BMJ*, v. 351, p. h4661, 2015.

KUMAR, A. Different Types of CNN Architectures Explained: Examples. 2022. Disponível em: <https://vitalflux.com/different-types-of-cnn-architectures-explained-examples/>. Acesso em: 08 nov. 2022.

KUMAR, V. MobileNet vs ResNet50 – Two CNN Transfer Learning Light Frameworks. 2020. Disponível em: <https://analyticsindiamag.com/mobilenet-vs-resnet>

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436-444, 2015.

MARINHO, R. A. et al. Effects of temperature on the life cycle, expansion, and dispersion of *Aedes aegypti* (Diptera: Culicidae) in three cities in Paraíba, Brazil. *Journal of Vector Ecology*, v. 41, n. 1, 2016.

MINISTÉRIO DA SAÚDE. Monitoramento dos casos de arboviroses até a semana epidemiológica 19 de 2022. *Boletim Epidemiológico*, v. 53, n. 19, Brasil, 2022.

NICHOLSON, C. A beginner's guide to neural networks and deep learning. 2019. Disponível em: <https://wiki.pathmind.com/neural-network>. Acesso em: 01 out. 2022.

OLIVEIRA, F. P. de. TMIC - Uma extensão do App Inventor para a implantação de modelos de ML voltados a classificação de imagens treinados no Teachable Machine. 2022. Trabalho de Conclusão de Curso. (Graduação em Sistemas de Informação) – Universidade Federal de Santa Catarina.

PACHECO, C. A. R. & PEREIRA, N. S. 2018. Deep Learning: Conceitos e Utilização nas Diversas Áreas do Conhecimento. Graduação em Computação. Trabalho de Conclusão de Curso (Engenharia de Computação). Universidade Evangélica de Goiás. <http://repositorio.aee.edu.br/jspui/handle/aee/1104>.

PAN AMERICAN HEALTH ORGANIZATION/WORLD HEALTH ORGANIZATION. Epidemiological Update: Arbovirus. Washington, DC, USA, 2020.

PUJARA, A. Image Classification With MobileNet. 2020. Disponível em: <https://medium.com/analytics-vidhya/image-classification-with-mobilenet-cc6fbb2cd470>. Acesso em: 08 nov. 2022.

RASCHKA, S. (2015) Python Machine Learning. Packt Publishing Ltd., Birmingham.

RUSSAKOVSKY, O. et al. ImageNet Large Scale Visual Recognition Challenge.

SCUDILIO, J. Qual a melhor métrica para avaliar os modelos de Machine Learning? 2020. Disponível em: <https://www.flai.com.br/juscudilio/qual-a-melhor-metrica-para-avaliar-os-modelos-de-machine-learning/>. Acesso em: 12 abr. 2022.

SECRETARIA DE ESTADO DA SAÚDE DE SANTA CATARINA. LACEN realizou mais de 100 mil exames de dengue em 2023. Disponível em: <https://www.saude.sc.gov.br/index.php/noticias-geral/14214-lacen-realizou-mais-de-100-mil-exames-de-dengue-em-2023>. Acesso em: 11 jul. 2023.

SIDDHARTH M. Building Resnet-34 model using Pytorch – A Guide for Beginners. 2021. Disponível em: <https://www.analyticsvidhya.com/blog/2021/09/building-resnet-34-model-using-pytorch-a-guide-for-beginners/>. Acesso em: 08 nov. 2022.

SODHI, P, A., NAMAN and SHARMA, V., Introduction to Machine Learning and Its Basic Application in Python (January 6, 2019). Proceedings of 10th International Conference on Digital Strategies for Organizational Success, Disponível em: <https://ssrn.com/abstract=3323796> or <http://dx.doi.org/10.2139/ssrn.3323796> Acesso em: 12 set. 2022.

TAN, M.; LE, Q. V. EfficientNet: Improving Accuracy and Efficiency through AutoML and Model Scaling. 2019. Disponível em: <https://ai.googleblog.com/2019/05/efficientnet-improving-accuracy-and.html>. Acesso em: 08 nov. 2022.

TAN, M.; LE, Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv:1905.11946. 2019.

TARGET MALARIA. *Anopheles gambiae* s.l.: morphology, life-cycle, ecology. EU, 2020.

WARDEN, P. How many images do you need to train a neural network? 2017. Disponível em: <https://petewarden.com/2017/12/14/how-many-images-do-you-need-to-train-a-neural-network/>. Acesso em: 01 out. 2022.

W. D. M. DE SILVA; S. JAYALAL. Dengue mosquito larvae identification using digital images. In: Proc. of the International Research Conference on Smart Computing and Systems Engineering, IEEE, 2020, p. 31-36.

WEBB, C. E., RUSSELL, R. C., & DOGGETT, S. L. Diferença na morfologia das espécies de mosquito. In A Guide to Mosquitoes of Australia.2016.CSIRO PUBLISHING.

ZHANG, H. et al. Predictive symptoms and signs of severe dengue disease for patients with dengue fever: a meta-analysis. BioMed Research International, 2014. PMID: 25097856

APÊNDICE A - ARTIGO NO FORMATO SBC

Desenvolvimento de um Modelo de Classificação de Imagens de Larvas de Mosquitos usando *Deep Learning*

Bruno Manarin Espíndola¹, Christiane Gresse Von Wangenheim¹

¹Departamento de Informática e Estatística, Universidade Federal de Santa Catarina, Florianópolis / SC, Brasil

bruno.manarin@grad.ufsc.br, c.wangeheim@ufsc.br

Abstract. *Dengue is an endemic disease with over two million cases in the Americas in 2022. Disease control is crucial, and preventing the formation of Aedes aegypti mosquito breeding sites is one of the most effective measures. A deep learning model was developed to identify mosquito species through photos of larvae. The goal was to distinguish between Aedes aegypti, Aedes albopictus, and Culex sp. The model was trained using larvae images taken with cellphone cameras and achieved an accuracy of 90.5% when using the EfficientNetB0 and ResNet18 models.*

Resumo. *A dengue é uma doença endêmica com mais de dois milhões de casos no continente americano em 2022. O controle da doença é crucial e prevenir a formação de criadouros do mosquito Aedes aegypti é uma das medidas mais eficazes. Um modelo de deep learning foi desenvolvido para identificar a espécie de mosquitos por meio de fotos das larvas. O objetivo foi distinguir entre Aedes aegypti, Aedes albopictus e Culex sp. O modelo foi treinado com imagens de larvas tiradas com câmeras de celular e obteve uma acurácia de 90,5% ao utilizar os modelos EfficientNetB0 e ResNet18.*

1. Introdução

A dengue é uma doença febril aguda, causada por vírus, que é transmitido principalmente pelo *Aedes aegypti*, mosquito que também transmite a febre chikungunya e o zika vírus [KULARATNE, 2015]. A transmissão se dá pela picada da fêmea deste mosquito infectado pelo vírus, que afeta as células musculares e os glóbulos brancos dos seres humanos, causando a doença [KULARATNE, 2015]. A dengue pode ser grave, apresentando sintomas como febre, dor nas articulações e manchas pelo corpo [KULARATNE, 2015].

É uma doença endêmica nas Américas, África, Ásia e Oceania. A Organização Mundial da Saúde estima que, anualmente, ocorram 50 a 100 milhões de casos, sendo que 500 mil a 1 milhão desenvolvem a forma grave, que pode ser fatal [PAHO, 2020]. No Brasil, a dengue é um problema de saúde pública. De acordo com o Ministério da Saúde, aproximadamente 544 mil casos foram registrados em 2021 e uma alta de 165,7% dos casos confirmados até maio de 2022 [MS, 2022].

Em Santa Catarina, segundo o informe epidemiológico do governo do Estado, no período de 02 de janeiro a 01 de dezembro de 2022, foram identificados mais de 141.392 casos de dengue, com mais de 130 municípios considerados infestados até novembro [DIVE, 2023]. Florianópolis é uma das situações graves, sendo dengue considerada uma epidemia na cidade [DIVE, 2023].

Estes dados indicam a importância da prevenção da doença para o bem-estar da população. Uma das formas de prevenção é a eliminação dos focos de larvas. Focos de larvas podem ser encontrados em depósitos naturais e recipientes com água parada, onde possibilitam a reprodução do mosquito. Vasos de flores, pneus, recipientes expostos à chuva são alguns dos exemplos de potenciais focos de dengue. Sendo assim, um dos atores importantes no controle à doença é a

própria população, que evita que focos sejam formados nas residências e identificam acúmulos existentes.

Um dos fatores que agravam a proliferação das larvas é a falta de conhecimento da população em relação aos mosquitos [FUNASA, 2001]. Nem sempre as larvas encontradas pela população são de *Aedes aegypti*. As regiões urbanas em Santa Catarina também encontram criadouros de *Aedes albopictus* ou mosquitos do gênero *Culex*, por exemplo. Por isso, a classificação taxonômica dos mosquitos pode ajudar na prevenção e controle desses focos.

O *Aedes* é um gênero de inseto holometábolo, ou seja, os mosquitos transmissores da doença passam pelo processo completo da metamorfose: ovos, larva, pupa, e fase adulta. A fase mais propícia para a determinação da espécie destes mosquitos pode ser a larval, já que tem diferenças morfológicas distintivas e visíveis, é de fácil coleta quando comparado a fase adulta e pode ser uma das fases mais duradouras da vida do inseto dependendo as condições climáticas onde se encontra [MARINHO et al., 2016].

Características anatômicas da larva, cor, cílios, comprimento do tubo de respiração, posicionamento na água são fatores levados em consideração para a caracterização do inseto, como é o caso da diferenciação de mosquitos dos gêneros *Culex* e *Aedes*. Normalmente é necessário a consulta a um especialista para se determinar se o foco encontrado é realmente de mosquitos da dengue com base numa análise no microscópio [GLOBE, 2022].

Uma solução pode ser a criação de um aplicativo móvel baseado em aprendizado de máquina que possibilita a classificação de modo eficaz por meio de uma fotografia de uma larva de mosquito encontrada pelo usuário. Isso faria com que o diagnóstico fosse rápido e acessível, além de não requerer conhecimento prévio sobre morfologia dos mosquitos por parte do cidadão que utilizará a ferramenta.

Já existem propostas para a criação de modelos de Machine Learning (ML) que são capazes de realizar esse tipo de reconhecimento e classificação morfológica das larvas, como, por exemplo, apresentado por de Silva, Jaylal [2020]. Porém, nenhum desses modelos foram desenvolvidos no Brasil, além do mais, os modelos existentes não contam com a funcionalidade de um app inteligente que permite o manuseio por um cidadão não instruído.

Assim o objetivo do presente estudo é identificar se é possível o desenvolvimento de um aplicativo móvel inteligente que consegue de forma fácil classificar larvas dos mosquitos *Aedes aegypti*, *Aedes albopictus* e *Culex* por meio de fotos com um grau de precisão de no mínimo 95%.

2. Trabalhos Correlatos

Nos últimos cinco anos, houve pesquisas sobre a classificação de larvas de mosquitos *Aedes aegypti*, porém, a maioria delas não se concentrou especificamente nessa espécie, mas em *Aedes* e *Non-aedes*. Isso é problemático para o controle da dengue, já que a espécie que transmite a doença no Brasil é somente *Aedes aegypti*. Além disso, a maioria dos modelos existentes não abordam a classificação de outros gêneros e espécies de mosquitos, como o *Culex*. As que abordam mais espécies apresentaram desempenho insatisfatório, com baixa acurácia (64%), representando risco para os usuários e vidas humanas.

Observa-se a falta de pesquisas sobre classificação de larvas no Brasil, o que impacta a coleta de dados devido à variação de espécies de mosquitos entre os países. A maioria dos estudos usou conjuntos de dados pequenos, com poucas imagens. Apenas um estudo coletou mais de 10.000 imagens online. A classificação de larvas é complexa e exigiu imagens de microscópio ou zoom (60x), o que não é viável para um aplicativo móvel de uso generalizado. Além disso, as redes convolucionais mais usadas, como a ResNet-50 e VGG-16/VGG-19, têm muitas camadas,

dificultando sua implementação em dispositivos móveis. A EfficientNet, com melhor desempenho, não foi utilizada nos estudos. Em termos de desempenho, a maioria dos modelos não alcançou acurácia maior que o objetivo (63-94%), o que é preocupante devido ao risco envolvido na classificação de larvas de mosquito. Alguns estudos apresentaram acurácia acima de 95%, mas não relataram métricas como Recall ou F1-Score.

Com base nesse levantamento, há a necessidade de um modelo de classificação de larvas de mosquito para a região urbana de Santa Catarina, portátil a um aplicativo móvel, com acurácia e métricas de desempenho relevantes.

Foram abordadas ameaças à validade dos resultados, como viés de publicação, omissão de estudos relevantes e seleção/extração de dados. Estratégias foram adotadas para minimizar essas ameaças, garantindo a confiabilidade e robustez dos resultados.

3. Solução

3.1 Requisitos

O objetivo é desenvolver um modelo de classificação de larvas de mosquito que seja portátil a um aplicativo móvel para auxiliar os usuários na identificação de criadouros de mosquitos da dengue em suas residências. O modelo utilizará *deep learning* e aprenderá com base em um conjunto de imagens rotuladas de larvas de mosquito dos gêneros *Aedes aegypti*, *Aedes albopictus*, *Culex*, além de objetos não relacionados a mosquitos. A medida de desempenho desejada é uma acurácia superior a 95%. O risco de classificação incorreta é alto, pois isso pode ter consequências negativas para a saúde das pessoas. Portanto, o modelo será otimizado para precisão, garantindo que a categoria correta seja indicada aos usuários do aplicativo.

3.2 Preparação de dados


Foi criado um conjunto de dados de imagens de larvas de mosquito em colaboração com o Grupo de qualidade de software (GQS), Laboratório de Transmissores de Hematozoários (LTH) da Universidade Federal de Santa Catarina e o Laboratório Central de Saúde Pública (LACEN) de Florianópolis. O conjunto de dados contém 2.297 imagens de larvas de mosquito e objetos não relacionados a mosquitos, divididos em quatro categorias. As imagens foram coletadas por pesquisadores usando câmeras de celular Android, representando uma variedade de cenários e ângulos encontrados na captura de imagens no aplicativo móvel. Diferentes modelos de smartphones foram utilizados para garantir a diversidade e representatividade das amostras. As imagens foram rotuladas manualmente por especialistas treinados. Não foram aplicadas técnicas de data augmentation durante a coleta das imagens. Esse conjunto de dados é utilizado para treinar e avaliar o desempenho do modelo de classificação de larvas de mosquito.

Tabela 1: Exemplos de imagens coletadas no conjunto de dados separadas por categoria

Exemplo de imagem de *Aedes aegypti*



Exemplo de imagem de *Aedes albopictus*



Exemplo de imagem da categoria *Culex sp*



Exemplo de imagem da categoria não mosquito



Foram selecionadas 50 imagens de cada categoria para compor um conjunto de testes, que não são utilizadas no treinamento do modelo. A coleta das imagens de mosquito foi abrangente, incluindo diferentes cenários, fundos, níveis de iluminação e ângulos de captura para simular as condições reais de uso do aplicativo móvel. Diversos modelos de smartphones foram usados durante a coleta, representando a variedade de dispositivos móveis utilizados pelos usuários. Não foram aplicadas técnicas de data augmentation durante a coleta das imagens, optando-se por utilizar as imagens capturadas originalmente. Essa escolha pode afetar a capacidade do modelo de generalização, mas permite uma avaliação mais precisa do desempenho com base nas imagens reais coletadas.

3.3 Treinamento

Foram realizados treinamentos de diferentes redes neurais com portabilidade para dispositivos móveis, incluindo MobileNetV3, ResNet18, ResNet34, EfficientNet-B0 e EfficientNet-Lite. Os modelos foram treinados usando o ambiente Jupyter Notebook na plataforma Google Colab.

Os resultados dos treinamentos são os seguintes:

MobileNetV3:

- Acurácia total: 93%
- Acurácia por categoria: Aedes Aegypti (95%), Aedes Albopictus (91%), Culex (90%), Não mosquito (99%)

ResNet18:

- Acurácia total: 96%
- Acurácia por categoria: Aedes Aegypti (98%), Aedes Albopictus (92%), Culex (98%), Não mosquito (100%)

ResNet34:

- Acurácia total: 95%
- Acurácia por categoria: Aedes Aegypti (97%), Aedes Albopictus (93%), Culex (98%), Não mosquito (100%)

EfficientNetLite:

- Acurácia total: 95%
- Acurácia por categoria: Aedes Aegypti (96%), Aedes Albopictus (90%), Culex (93%), Não mosquito (100%)

EfficientNet-B0:

- Acurácia total: 95%
- Acurácia por categoria: Aedes Aegypti (93%), Aedes Albopictus (90%), Culex (94%), Não mosquito (100%)

Observa-se que todos os modelos apresentaram resultados promissores, com acurácias totais variando de 93% a 96%. As acurácias por categoria também foram satisfatórias.

No entanto, ainda há necessidade de melhorias na acurácia do modelo, especialmente para a categoria *Aedes Albopictus*, que ainda não atingiu os 95% desejados. O objetivo é alcançar uma acurácia mínima de 95% em todas as categorias.

Em geral, os modelos treinados demonstraram uma capacidade satisfatória de distinguir larvas de mosquito de diferentes espécies, além de identificar objetos que não são mosquitos. Esses resultados são promissores para o desenvolvimento de um modelo de classificação de larvas de mosquito eficiente e preciso para prevenção da dengue.

3.4 Testes de desempenho

O conjunto de testes é composto por 200 imagens, distribuídas igualmente entre as classes. A classe "non-mosquito" inclui imagens de objetos/insetos visualmente semelhantes a larvas de mosquito. Essas imagens não foram usadas durante os treinamentos dos modelos. Foram coletadas por pesquisadores da iniciativa Computação na Escola/INCoD/INE/UFSC em cooperação com biólogos do LTH/UFSC e CRLAB/LACEN/SC. As imagens foram rotuladas pelos pesquisadores e não sofreram pré-processamento ou *data augmentation*. A acurácia dos rótulos é de 100%. O conjunto de dados contém todas as classes de interesse com exemplos variados e não possui duplicatas. As imagens foram coletadas na região de Florianópolis/SC. Foram coletadas variando o plano de fundo, ângulos, iluminação, etc. A confidencialidade não se aplica ao conjunto de teste. As métricas utilizadas para avaliar o desempenho dos modelos incluem acurácia, precisão, *recall* e *F1 Score*. O teste foi realizado usando *Jupyter Notebooks* no *Google Colab*.

3.5 Resultados dos testes

Os resultados dos testes com diferentes modelos de rede neural foram avaliados em termos de acurácia total e acurácia por categoria:

MobileNetV3:

- Acurácia total: 80,5%
- Acurácia por categoria: *Aedes Aegypti* (76%), *Aedes Albopictus* (80%), *Culex* (74%), Não mosquito (94%)

Resnet18:

- Acurácia total: 90,5%
- Acurácia por categoria: *Aedes Aegypti* (90%), *Aedes Albopictus* (85%), *Culex* (89%), Não mosquito (98%)

Resnet34:

- Acurácia total: 86,5%
- Acurácia por categoria: *Aedes Aegypti* (91%), *Aedes Albopictus* (76%), *Culex* (80%), Não mosquito (98%)

EfficientNetLite:

- Acurácia total: 84%
- Acurácia por categoria: *Aedes Aegypti* (82%), *Aedes Albopictus* (79%), *Culex* (76%), Não mosquito (100%)

EfficientNetB0:

- Acurácia total: 90%
- Acurácia por categoria: Aedes Aegypti (92%), Aedes Albopictus (86%), Culex (83%), Não mosquito (98%)

3.6 Discussão

Os resultados do treinamento dos modelos de machine learning indicam que, embora tenham sido obtidos resultados promissores, nenhum dos modelos alcançou a meta de acurácia de 95% ou mais nos testes. Os modelos Resnet18 e EfficientNetB0 se destacaram, atingindo uma acurácia total de 90,5% e 90%, respectivamente, e apresentando métricas de desempenho consistentes. No entanto, é importante considerar as limitações e ameaças à validade dos resultados, bem como a natureza de alto risco da aplicação em questão. Apesar dos resultados promissores, uma acurácia de 90% pode ser considerada aceitável, dependendo do contexto e do caso de uso específico.

4. Conclusão

Neste estudo, foram desenvolvidos modelos de classificação de larvas de mosquito utilizando *deep learning*, com base em uma pesquisa teórica e um mapeamento do estado da arte. Embora os resultados dos testes tenham ficado abaixo da meta de 95% de acurácia, os modelos EfficientNetB0 e ResNet18 apresentaram acurácias de 90,5% e 90%, o que demonstra um desempenho considerável. Os modelos têm a capacidade de identificar espécies específicas de mosquito (*Aedes aegypti*, *Aedes albopictus* e *Culex sp*), permitindo estratégias de controle mais direcionadas. Além disso, a abordagem leve desses modelos permite sua implementação em aplicativos móveis e uso de imagens capturadas diretamente pela câmera do celular. Isso oferece benefícios significativos para profissionais de saúde e outros envolvidos no controle da dengue. Pesquisas futuras podem explorar oportunidades de melhorias, como aumentar a quantidade de dados de treinamento e aprimorar as técnicas de pré-processamento, além de implementar os modelos em um aplicativo para uso generalizado. Espera-se que o uso contínuo de *deep learning* na identificação de mosquitos contribua para a saúde pública de maneira significativa.

5. Referências

W. D. M. DE SILVA; S. JAYALAL. Dengue mosquito larvae identification using digital images. In: Proc. of the International Research Conference on Smart Computing and Systems Engineering, IEEE, 2020, p. 31-36.

DIVE, Informe Epidemiológico nº16/2023. Disponível em: <https://dive.sc.gov.br/phocadownload/doencas-agrivos/Dengue/Informes/2023/Informe-DengueCZ16-2023.pdf> Acesso em 05 jun. 2023.

FUNASA. Instruções para Pessoal de combate ao Vetor - Manual de Normas Técnicas, 2001. Disponível em: https://bvsmms.saude.gov.br/bvs/publicacoes/funasa/man_dengue.pdf. Acesso em: 02 dez. 2022.

GLOBE. A series of mosquito tutorials - Identifying species. 2022. Disponível em: <https://observer.globe.gov/documents/19589576/8c9e4a31-ac81-48ff-82aa-8d07a86babc2>. Acesso em: 02 dez. 2022.

KULARATNE, S. Dengue fever. *BMJ*, v. 351, p. h4661, 2015.

MARINHO, R. A. et al. Effects of temperature on the life cycle, expansion, and dispersion of *Aedes aegypti* (Diptera: Culicidae) in three cities in Paraíba, Brazil. *Journal of Vector Ecology*, v. 41, n. 1, 2016.

MINISTÉRIO DA SAÚDE. Monitoramento dos casos de arboviroses até a semana epidemiológica 19 de 2022. *Boletim Epidemiológico*, v. 53, n. 19, Brasil, 2022.

PAN AMERICAN HEALTH ORGANIZATION/WORLD HEALTH ORGANIZATION. *Epidemiological Update: Arbovirus*. Washington, DC, USA, 2020.