

UNIVERSIDADE FEDERAL DE SANTA CATARINA



CENTRO TECNOLÓGICO

DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA

CURSO DE CIÊNCIAS DA COMPUTAÇÃO

**Desenvolvimento de um modelo de classificação de imagens de
lagartas peçonhentas usando *deep learning***

Matheus Felipe Bertonceli Bueno

Florianópolis

2023

Desenvolvimento de um modelo de classificação de imagens de lagartas 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 Ciências da Computação.

Autor: Matheus Felipe Bertonceli Bueno

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

Florianópolis

2023

Bueno, Matheus Felipe Bertonceli

Desenvolvimento de um modelo de classificação de imagens de lagartas usando deep learning / Matheus Felipe Bertonceli Bueno ; orientadora, Christiane Anneliese Gresse Von Wangenheim, 2024.

88 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Ciências da Computação, Florianópolis, 2024.

Inclui referências.

1. Ciências da Computação. 2. Deep Learning. 3. Animais Peçonhentos. 4. App Inventor. I. Wangenheim, Christiane Anneliese Gresse Von. II. Universidade Federal de Santa Catarina. Graduação em Ciências da Computação. III. Título.

Matheus Felipe Bertonceli Bueno

Desenvolvimento de um modelo de classificação de imagens de lagartas usando deep learning

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de Bacharel em Ciências da Computação e aprovado em sua forma final pelo Curso de graduação em Ciências da Computação.

Florianópolis, 10 de junho de 2024.

Coordenação do Curso

Banca examinadora

Profa. Christiane Anneliese Gresse Von Wangenheim , Dra.

Orientadora

Universidade Federal de Santa Catarina

Profa. Taciana Mara da Silva Seemann , Me.

Avaliadora

Universidade Federal de Santa Catarina

Prof. Jônata Tyska Carvalho , Dr.

Avaliador

Universidade Federal de Santa Catarina

Florianópolis, 2024.

RESUMO

Acontecem muitos acidentes com animais peçonhentos em Santa Catarina. Entre estes uma parcela considerável é causada por lagartas. Conseqüentemente, em casos de acidentes com lagartas ou mesmo antes no encontro com estes, é de fundamental importância identificar a espécie com a qual a vítima entrou em contato, em virtude do perigo associado especificamente com as lagartas do gênero *Lonomia*. No entanto, para a população em geral, pode ser difícil diferenciar as lagartas do gênero *Lonomia* das demais espécies e assim correr riscos de danos de saúde grave, inclusive morte. Tendo em vista a importância dessa classificação de lagartas peçonhentas em Santa Catarina no contexto da saúde pública, uma possível e importante contribuição seria a criação de um aplicativo móvel inteligente que permite a classificação automatizada. Atualmente já existem alguns aplicativos para classificação de animais e plantas em geral, porém, não foi encontrado nenhum aplicativo atualmente voltado ao escopo de classificação de lagartas peçonhentas em SC. Assim, o objetivo geral deste trabalho é desenvolver e comparar modelos de classificação de imagens dedicados à identificação de lagartas peçonhentas de Santa Catarina. São adotadas técnicas de *Deep Learning* para automatizar a classificação a partir de fotos de lagartas criadas com a câmera do celular. O modelo desenvolvido foi implantado em um protótipo de aplicativo móvel usando *App Inventor*. Com isso espera-se contribuir para a prevenção de acidentes com lagartas peçonhentas por meio do uso do aplicativo e auxílio da população.

SUMÁRIO

1. Introdução.....	8
1.1 Contextualização.....	8
1.2. Objetivos.....	11
1.3. Metodologia de pesquisa.....	12
1.4 Estrutura do Documento.....	14
2. Fundamentação Teórica.....	14
2.1 Lagartas de Santa Catarina.....	14
Família Saturniidae.....	15
2.2 Classificação de Imagens com Deep Learning.....	23
3. Análise de Estado da Arte.....	34
3.1 Definição do protocolo de revisão.....	34
3.2 Execução da busca.....	36
3.3 Resultados da revisão.....	37
3.3.1 Quais pesquisas existem em termos de classificação e quais espécies são classificadas?.....	37
3.3.2 Como é formado o conjunto de imagens e quantas imagens possui?...	38
3.3.3 Como os modelos foram treinados?.....	38
3.3.4 Quais foram os desempenhos relatados?.....	39
3.3.5 O modelo de DL foi implantado?.....	40
3.4 Discussão.....	41
4. Solução.....	42
4.1 Análise do requisitos.....	42
Realização de survey.....	42
4.2 Desenvolvimento do modelo de DL.....	45
4.2.1 Desenvolvimento do conjunto de imagens.....	45
4.2.2 Treinamento dos modelos.....	48
Treinamento com Resnet18.....	49
Treinamento com Resnet34.....	51
Treinamento com EfficientNetLite.....	53
Treinamento com EfficientNetB0.....	55
Treinamento com MobileNetV3.....	57
Treinamento com MobileNetV3 - Google Teachable Machine.....	59
4.2.3 Testes de desempenho.....	60
Preparação do teste.....	61
Métricas.....	62
Ambiente de execução.....	63
Resultado dos testes com Resnet18.....	63

Resultado dos testes com Resnet34.....	64
Resultado dos testes com EfficientNetLite.....	65
Resultado dos testes com EfficientNetB0.....	67
Resultado dos testes com MobileNetV3.....	68
Resultado dos testes com MobileNetV3 - Google Teachable Machine.....	69
4.3 Discussão.....	71
Ameaças à validade.....	73
4.4 Implementação de aplicativo móvel.....	74
5. Conclusão.....	81
Referências.....	83

1. Introdução

1.1 Contextualização

Acontecem muitos acidentes com animais peçonhentos em Santa Catarina. Entre estes uma parcela considerável é causada por lagartas. Estas lagartas são consideradas peçonhentas pois produzem e inoculam toxinas por meio de estruturas dedicadas. Diferentemente de animais venenosos, que secretam as toxinas produzidas (Azevedo & Almeida, 2017). Acidentes causados por contato com lagartas são comuns, constituindo 38% dos acidentes com animais peçonhentos ou venenosos na população entre 0 e 14 anos, e 16,62% dos acidentes com animais peçonhentos ou venenosos na população de 15 ou mais anos de idade em Santa Catarina em 2021 (CIATOX/SC, 2022)(DIVE,2021). Estes acidentes acontecem especialmente em regiões rurais, onde são consideradas um risco ocupacional. Mas também ocorrem em áreas urbanas, onde comumente os insetos podem ser encontrados em árvores frutíferas próximas às residências (Gamborgi *et al.*, 2012).

Lagartas são insetos em fase larval de espécies de insetos da ordem *Lepidoptera*, que engloba borboletas e mariposas. A identificação das formas imaturas de Lepidópteros tem relevada importância na área da entomologia médica, visto que algumas destas espécies possuem peçonha em sua fase larval, e possuem cerdas urticantes que inoculam toxinas e funcionam como mecanismo de defesa contra predadores, podendo causar acidentes com humanos (Gamborgi *et al.*, 2012).

Tabela 1. Acidentes por lagartas segundo a região de saúde, Santa Catarina, 2011-2021 (DIVE, 2022).

Região de Saúde	Anos											Total
	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	
Extremo Oeste	62	24	46	86	97	72	157	224	119	34	33	954
Oeste	51	20	47	67	48	45	67	89	93	26	25	578
Xanxerê	86	35	37	57	57	51	77	88	64	19	22	593
Alto Vale do Itajaí	36	40	23	31	34	40	99	79	54	14	26	476
Foz do Rio Itajaí	18	12	7	4	5	3	6	7	5	3	5	75
Médio Vale do Itajaí	19	27	15	19	12	14	26	24	28	14	16	214
Grande Florianópolis	52	53	43	43	44	42	49	27	41	18	38	450
Meio Oeste	21	28	24	17	23	36	54	53	34	11	7	308
Alto Vale do Rio do Peixe	34	21	9	15	11	18	16	23	26	12	18	203
Alto Uruguai Catarinense	88	57	33	67	93	78	108	95	54	16	33	722
Nordeste	7	17	17	19	14	9	14	14	26	10	13	160
Planalto Norte	13	15	12	11	17	8	27	27	29	15	12	186
Serra Catarinense	3	9	5	6	3	4	7	13	7	5	2	64
Extremo Sul Catarinense	6	7	5	9	12	4	11	12	8	2	8	84
Carbonífera	19	7	6	15	7	9	13	23	28	6	20	153
Laguna	17	13	9	15	13	5	8	15	12	4	15	126
Vale do Itapocu	12	22	18	30	17	11	14	18	21	13	23	199
Total	544	407	356	511	507	449	753	831	649	222	316	5545





Fonte: Sistema de Informação de Agravos de Notificação – SINAN. Dados coletados em 24/05/2022.

Em casos de contato com lagartas urticantes, o tratamento é sintomático, focado em aliviar os sintomas causados pela peçonha (Gamborgi *et al.*, 2012). Acidentes com lagartas do gênero *Lonomia* apresentam casos mais graves, pois a peçonha destas lagartas pode causar alterações na coagulação sanguínea e síndrome hemorrágica importante, potencialmente grave com risco de óbito, se não tratado. Por este motivo, o tratamento para acidentes com lagartas do gênero *Lonomia* necessitam da aplicação do soro antilonômico, produzido no Brasil pelo Instituto Butantan (Gamborgi *et al.*, 2012).

Conseqüentemente, em casos de acidentes com lagartas, é de fundamental importância identificar a espécie com a qual a vítima entrou em contato, em virtude do perigo associado especificamente com as lagartas do gênero *Lonomia*. Para a identificação podem ser utilizadas as principais características morfológicas das lagartas incluindo a coloração, formato e densidade das cerdas. Por exemplo, as lagartas do gênero *Lonomia* possuem cerdas esverdeadas e em forma de pinheiros (Gamborgi *et al.*, 2012)(CIATOX/SC, 2023). A Tabela 2 apresenta alguns exemplos

de lagartas peçonhentas que habitam a região de Santa Catarina, destacando algumas características morfológicas que as diferenciam (CIATOX/SC, 2023).

Tabela 2. Exemplos espécies de lagartas peçonhentas de Santa Catarina (CIATOX/SC, 2023)

			
<i>Lonomia obliqua</i>	<i>Hylesia sp</i>	<i>Podalia sp</i>	<i>Automeris sp</i>

No entanto, para a população em geral, pode ser difícil diferenciar as lagartas do gênero *Lonomia* das demais espécies e assim até correr riscos de danos de saúde grave, inclusive morte, caso não procurar e/ou não receber atendimento médico adequado imediatamente por não saber dos perigos associados ao contato.

Tendo em vista a importância dessa classificação de lagartas peçonhentas em Santa Catarina no contexto da saúde pública, uma possível solução seria a criação de um aplicativo móvel inteligente que permite a classificação automatizada. Essa solução pode ser criada utilizando *Deep Learning (DL)* Implantando o modelo de DL treinado em um aplicativo móvel que possibilita a classificação de espécies de lagartas por meio de uma fotografia da lagarta feita com a câmera do celular do próprio cidadão. Como resultado pode ser apresentada a espécie da lagarta, levantando um alerta caso haja risco de complicação de saúde grave caso o usuário faça contato com o inseto. Desta forma a identificação se tornaria fácil e acessível, sem necessidade de conhecimento prévio da morfologia das lagartas por parte do cidadão, e mesmo que este não conheça os riscos envolvidos em caso de acidente pode ser alertado e se encaminhar para um centro de atendimento de forma apropriada prevenindo maiores riscos a sua saúde.

Atualmente já existem alguns aplicativos para classificação de animais e plantas em geral, como o Seek da iNaturalist (INATURALIST, 2023), que utiliza uma base de dados com contribuições da comunidade de usuários para identificar espécies de animais, plantas e fungos. Existe também pesquisa voltada à criação de modelos de classificação de mariposas adultas (Zhu *et al.*, 2017). Porém, não foi encontrado nenhum aplicativo atualmente voltado ao escopo de classificação de lagartas peçonhentas em SC.

Assim o objetivo do presente estudo é identificar se é possível o desenvolvimento de um aplicativo móvel inteligente que consegue de forma fácil classificar lagartas peçonhentas de SC por meio de fotos com um grau de precisão de no mínimo 95%.

1.2. Objetivos

Observação

Para fins de clarificação, no contexto deste trabalho, “classificação” se refere apenas à identificação da espécie de lagartas, seguindo a nomenclatura comum de classificação em modelos de Inteligência artificial. O objetivo deste trabalho não é a classificação taxonômica das espécies de lagartas peçonhentas.

Objetivo geral

O objetivo geral deste trabalho é desenvolver um modelo de classificação de imagens de lagartas para classificar lagartas peçonhentas de SC. São adotadas técnicas de *Deep Learning* para automatizar a classificação a partir de fotos de lagartas criadas com a câmera do celular. O modelo desenvolvido é implantado em um aplicativo móvel usando App Inventor.

Objetivos Específicos

O1. Analisar a fundamentação teórica sobre espécies de lagartas e *Deep Learning*.

O2. Analisar o estado da arte em relação a classificação de lagartas com *Deep Learning*.

O3. Desenvolver, testar e comparar modelos de *Deep Learning* para a classificação de lagartas.

O4. Implantar o modelo treinado em um aplicativo móvel.

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 é limitado à classificação de lagartas peçonhentas de SC. Larvas de outras espécies de insetos ou outros animais peçonhentos não são 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 lagartas de SC/Brasil

A1.2 – Análise teórica sobre *Deep Learning* para classificação de imagens

Etapa 2 – Estado da arte

Nesta etapa é realizado um mapeamento sistemático da literatura seguindo o processo proposto por Petersen *et al.* (2015) 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 lagartas, seguindo um processo de desenvolvimento de redes neurais/Deep Learning (Kierski, 2017; Shuai, 2017, Polyzotis *et al.*, 2017). Esta etapa é dividida nas seguintes atividades:

A3.1 – Análise de requisitos

A3.2 – Preparação de conjunto de dados

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

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

Etapa 4 – Implantação em app

Nesta etapa é implantado o modelo treinado em um aplicativo móvel usando *App Inventor* e a extensão TMIC seguindo um processo de engenharia de software proposto por Pressman (2016). Esta etapa é dividida nas seguintes atividades:

A4.1 – Análise de requisitos

A4.2 – Design de interface

A4.3 – Implementação e teste do aplicativo

1.4 Estrutura do Documento

No capítulo 2 é apresentada uma fundamentação teórica de conceitos relevantes, como a classificação de imagens usando *Deep Learning* e as espécies de lagartas presentes em Santa Catarina. No capítulo 3 é realizada uma revisão sistemática da literatura, a fim de averiguar o estado da arte na classificação de lagartas por meio de *Deep Learning*. No capítulo 4 é detalhado o processo de criação da solução utilizando o *Deep Learning*. O capítulo 5 conclui o trabalho com considerações finais.

2. Fundamentação Teórica

2.1 Lagartas de Santa Catarina

Lagartas são as larvas de borboletas e mariposas da ordem Lepidoptera. Possuem três pares de pernas no tórax e de um a cinco pares de falsas pernas no abdômen, também conhecidas por pseudópodes. Em geral se alimentam de tecido

vegetal, e algumas espécies liberam substâncias químicas irritantes ou possuem cerdas urticantes que podem causar complicações de saúde (Orlandin *et al.*, 2016).

No total há 37 famílias de Lepidópteros em Santa Catarina (Orlandin *et al.*, 2016), porém das quais nem todas possuem toxinas. Tipicamente lagartas de borboletas não são consideradas peçonhentas por não possuírem cerdas que inoculam toxinas. Das espécies presentes em Santa Catarina, algumas são destacadas pelo Centro de Informação e Assistência Toxicológica de Santa Catarina (CIATox/SC) como de importância médica. Estas pertencem a quatro famílias: *Saturniidae*, *Limacodidae*, *Megalopygidae* e *Arctiidae*.

Acidentes ocorrem quando as cerdas de lagartas urticantes entram em contato com a pele humana, fazendo que as cerdas se fragmentem e liberem o conteúdo de peçonha contido dentro das cerdas (Gamborgi *et al.*, 2012). O contato com a maioria das larvas peçonhentas tipicamente causa irritação na pele de humanos ao entrar em contato com suas cerdas (Cardoso & Haddad, 2005). Sintomas causados pela peçonha, incluem dor intensa imediata, eritema, edema, vesículas, bolhas, erosões, petéquias, necrose superficial cutânea, ulcerações e linfangite.

Porém, lagartas do gênero *Lonomia* podem provocar, além dos sintomas descritos acima, distúrbios nos fatores de coagulação após contato, provocando equimoses e hematomas na pele e nas mucosas, podendo levar a uma síndrome hemorrágica grave, podendo levar a óbito caso não seja tratada adequadamente. O tratamento é feito com o soro anti-lonômico, que é sintetizado pelo Instituto Butantan (Gamborgi *et al.*, 2012). Por consequência do medicamento especializado necessário para acidentes envolvendo lagartas *Lonomia*, a identificação destas espécies é de fundamental importância para o tratamento.

A morfologia das lagartas varia em termos de tamanho, cor, presença e número de cerdas. Nas próximas seções é descrita a morfologia das principais espécies das famílias de importância médica de Santa Catarina.

Família Saturniidae

Esta família compreende 165 espécies registradas em Santa Catarina (Orlandin *et al.*, 2016). A maioria dos gêneros desta família é noturna. Durante a fase larval possuem coloração verde para se camuflarem no ambiente onde vivem. Também podem ser diferenciadas por suas cerdas (também chamadas de espículas, escolos ou *scoli*) em formato arbóreo, semelhante a pequenos pinheiros.

Algumas lagartas durante o dia permanecem na parte ventral das folhas, provavelmente para não serem tão facilmente encontradas por predadores e evitar desidratação devido ao contato com raios solares. Durante os períodos iniciais do desenvolvimento as larvas ficam reunidas em grupos; conforme se desenvolvem o tamanho desses grupos torna-se menor (Orlandin *et al.*, 2016).

Lonomia obliqua

O gênero *Lonomia* contém as espécies de lagartas com maior importância médica, uma vez que contato com a peçonha de lagartas como *Lonomia obliqua* e *Lonomia achelous* podem causar síndromes hemorrágicas graves, choque e insuficiência renal aguda, variando conforme a intensidade do contato. Da mesma forma, o tempo para apresentar um quadro hemorrágico varia em função do grau de contato, com os sintomas podendo aparecer uma hora após o contato ou até mesmo 72 horas depois (Garcia, 2013).

Lagartas da espécie *Lonomia obliqua* possuem coloração castanho-claro esverdeado, que escurece à medida que entram em fase de pupa. Possuem também uma linha longitudinal contínua marrom-escura, marginada de preto em toda a extensão do corpo, assim como outras duas faixas longitudinais descontínuas, com manchas claras, levemente amareladas e dispostas externamente às cerdas dorsais. O comprimento das lagartas varia de 5,19 mm a 53,49 mm conforme crescem durante o estágio larval de desenvolvimento.



Figura 1. Exemplo de lagarta da espécie *Lonomia obliqua*.(CIATox/SC, 2023)

Neste gênero também pode ser observado comportamento gregário, no qual as lagartas se encontram em grupos. Quando não estão se movendo, formam um agrupamento denso, apontando a cabeça para fora do grupo, e quando se deslocam formam fileiras (Garcia, 2013). Este comportamento favorece o contato com múltiplas lagartas em casos de acidentes, aumentando significativamente a gravidade do quadro hemorrágico.



Figura 2. Grupo de lagartas de *Lonomia obliqua* (CIATox/SC, 2023).

***Hylesia* sp.**

O gênero *Hylesia* contém as únicas espécies de mariposas com importância médica tanto na fase larval quanto na fase adulta. A forma adulta das fêmeas desta espécie possuem cerdas no abdome que podem se desprender e causar dermatites. Porém, o presente estudo é focado na identificação de larvas da espécie, uma vez

que apresentam cerdas urticantes. Sintomas de contato com as cerdas das larvas incluem: dor intensa; vermelhidão; inchaço e coceira.

Em termos de morfologia, lagartas de *Hylesia* apresentam coloração amarelada nos estágios iniciais de crescimento, ganhando coloração verde-escura quando próximas do estágio de pupa. Quando as lagartas estão totalmente desenvolvidas, apresentam cabeça de coloração negra brilhante, corpo preto ornamentado com pontos brancos e uma faixa castanha bordeada com branco ao longo do abdome. Possuem espículos pretos pelo corpo, com um par mais desenvolvido na região anterior.

Assim como o gênero *Lonomia*, o gênero *Hylesia* apresenta comportamento gregário como forma de proteção contra predadores.



Hylesia sp. (CIT/SC - 2006)

Figura 3. Exemplo de *Hylesia* sp.



Figura 4. Exemplo de grupo de *Hylesia sp.* (CIATox/SC, 2023).

Automeris sp.

Lagartas do gênero *Automeris* apresentam variação de coloração dependendo da espécie e estágio de desenvolvimento larval, podendo possuir torso castanho-claro, verde-claro com listras brancas, branco ou preto. Como outras espécies da família Saturniidae, apresentam espículas arbóreas com coloração verde ou amarelada.



Figura 5. Exemplo de lagarta de *Automeris sp.*(CIATox/SC, 2023).

Família *Limacodidae*

Lagartas dessa família possuem projeções espinhosas venenosas e se deslocam de forma semelhante a lesmas, com a base do torso agarrada firmemente nas folhas que se alimentam. Muitas espécies possuem coloração verde e vermelha, e podem causar acidentes com suas projeções peçonhentas. Também apresentam comportamento gregário nos estágios iniciais de desenvolvimento larval, dispersando-se quando próximas da fase de pupa.

Phobetron sp.

Lagartas do gênero *Phobetron* podem ser distinguidas pelas projeções laterais presentes ao longo do corpo, que mimetizam pernas de aranha. Possuem corpo achatado e coberto por cerdas finas.



Figura 6. Exemplo de lagarta de *Phobetron sp.*

Acharia sp. (Anteriormente Sibine sp.)

Lagartas do gênero *Acharia* possuem corpo verde claro, com cerdas apenas nas regiões anterior e posterior do corpo, em forma de pequenos tufo, através dos quais injetam o veneno.



Figura 7. Exemplo de Lagarta de *Acharia sp.*

Família *Megalopygidae*

Lagartas dessa família possuem cerdas longas não urticantes em densidades variantes entre espécies, que escondem espinhos curtos que contém veneno. As larvas de *Megalopygidae* também se diferenciam pois se alimentam de múltiplas espécies de plantas e vivem solitariamente. Eles podem causar lesões cutâneas e irritação da pele característicos de acidentes com lagartas peçonhentas.

Megalopyge lanata

Lagarta de comportamento solitário, e apresentam coloração predominantemente branca, com anéis escuros e estreitos que seguem a segmentação do corpo. Possuem cerdas longas com pontas dilatadas, concentradas em tufo cercados com coloração laranja ou vermelha.



Figura 8. Lagarta de *Megalopyge lanata*(CIATox/SC, 2023).

***Podalia* sp.**

Lagartas do gênero *Podalia* possuem cerdas não urticantes longas e sedosas, densamente distribuídas pelo abdome do inseto, com coloração que varia bastante por espécie e inclui coloração cinza, amarelada, escura e branca.

Contato com as espículas dessa espécie demonstrou causar queimação intensa, com dor irradiando do local do contato e aumento de pressão arterial.



Figura 9. Exemplar de lagarta de *Podalia* (CIATox/SC, 2023).

Família Arctiidae

Lagartas dessa família chegam a até 4 cm de comprimento, e são semelhantes às lagartas de Megalopygidae, com cerdas maiores que encobrem outras cerdas urticantes menores (CIAToxSC, 2023).



Figura 10. Exemplar de lagarta de Arctiidae (CIATox/SC, 2023).

Lagartas não peçonhentas

Lagartas não peçonhentas podem ser identificadas pela ausência de espículas ou cerdas no corpo do animal. Algumas espécies contêm defesas químicas contra predadores (Orlandin et al., 2016), mas não produzem toxinas urticantes e não causam lesões em caso de contato (CIATox-SC, 2023).



Figura 11. Exemplos de lagartas não peçonhentas. Observa-se a ausência de cerdas (CIATox/SC, 2023).

2.2 Classificação de Imagens com *Deep Learning*

2.2.1 Visão Geral

Machine Learning (ML) (Aprendizado de máquina) é um subconjunto de Inteligência Artificial que exibe aprendizado associado à inteligência humana por meio de algoritmos de aprendizado. Usando entradas e saídas de dados suficientemente grandes, estes algoritmos têm a capacidade de aprender efetivamente por um processo iterativo e eventualmente conseguem prever uma saída esperada para uma dada entrada (Helm *et al.*, 2020).

O ML utiliza de diversas técnicas, entre elas Redes Neurais Artificiais. Redes Neurais Artificiais são modelos computacionais baseados no funcionamento do sistema neural humano, onde neurônios se comunicam entre si. Redes neurais são estruturadas em camadas de nodos (ou neurônios artificiais), contendo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (IBM, 2020).

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 (IBM, 2020) (Helm *et al.*, 2020). 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.

O algoritmo de aprendizado 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.

Técnicas de aprendizado são geralmente classificadas em aprendizado supervisionado e aprendizado não supervisionado. No aprendizado supervisionado é necessário que *a priori* seja conhecido o valor de saída de cada exemplo de treinamento. Por outro lado, no aprendizado não supervisionado apenas valores de entrada são dados e cabe ao algoritmo de aprendizado extrair padrões dos dados de entrada (Baştanlar; Özuysal, 2014).

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

A classificação de imagens é uma das aplicações mais conhecidas que utiliza DL, e consiste da extração de informação de imagens com base em categorias predefinidas. Classificação de imagens pode ser feita tanto com aprendizado supervisionado quanto com aprendizado não supervisionado (Affonso *et al.*, 2017)(Elngar *et al.*, 2021).




Figura 12: Estrutura de camadas de uma rede neural profunda. Fonte IBM, 2020.

2.2.2 Processo de Desenvolvimento de Modelos de *Deep Learning*

O desenvolvimento de modelos de *Deep Learning* deve seguir um processo sistemático como o apresentado na Figura 13 com base em Amershi (2019) e Gresse von Wangenheim e von Wangenheim (2021).

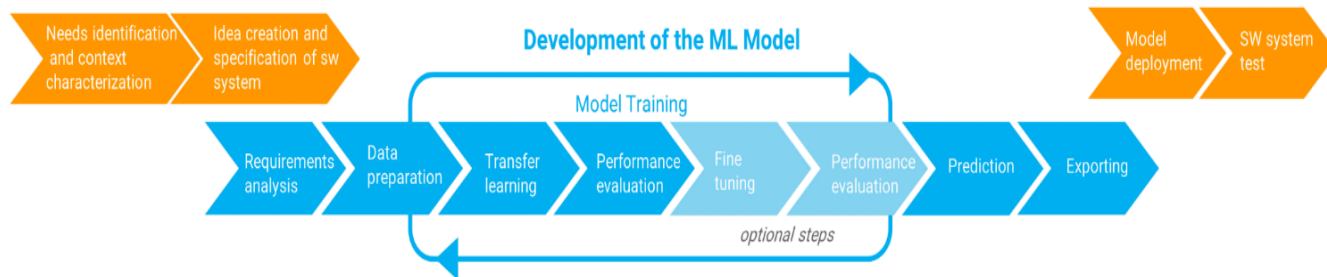


Figura 13: Visão geral do processo iterativo de ML centrado em humanos

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 e a identificação dos riscos.

Preparação de dados - Nesta etapa os dados que serão consumidos pelo algoritmo são coletados, limpos e preparados. A coleta de dados pode ser auxiliada com uso de conjuntos de dados existentes ou pode ser feita por conta própria. No entanto, é sempre necessário realizar a limpeza dos dados e remover dados incorretos e/ou repetidos. O tipo de dado pode variar dependendo do problema. Em aprendizado supervisionado, 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 - Nesta etapa o modelo de *ML* pode ser construído ou escolhido a partir de modelos bem conhecidos que foram provados efetivos em seus domínios respectivos (Gresse von Wangenheim, von Wangenheim, 2021). Em casos em que o conjunto de dados de um dado domínio é limitado, o *Transfer Learning* pode ser usado para amplificar e acelerar o desenvolvimento (Weiss *et al.*, 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 *et al.*, 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 por meio 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 - Esta etapa é realizada após o treinamento do modelo, e consiste em avaliar seu desempenho para verificar sua capacidade de generalização em dados não conhecidos. 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 (Baştanlar; Özuysal, 2014).

Predição - Nesta etapa o modelo é testado com dados novos não inclusos no treinamento, a fim de obter uma aproximação do desempenho no mundo real.

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 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 14).




Figura 14: Camadas de Rede neural convolucional (Kumar, 2022).

Na camada convolucional, a operação matemática de convolução é realizada entre a imagem de entrada e um filtro. O objetivo dessa operação é gerar um mapa de características da imagem, a partir desse mapa o modelo pode identificar certas características em cada classe a ser identificada. Essas características são

representadas por “*Kernels*” que são distribuídos pela entrada (O’Shea & Nash, 2015). O resultado dessa operação pode ser visualizado como na Figura 15.




Figura 15: Ativações de uma camada convolucional após treinamento(O’Shea & Nash, 2015).

Na camada de *pooling* procura-se reduzir gradativamente as dimensões da representação da entrada, reduzindo o número de parâmetros e a complexidade computacional do modelo. 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 *pooling* são normalmente usadas após as camadas convolucionais para reduzir o tamanho da entrada antes que ela seja alimentada para uma camada totalmente conectada (O’Shea & Nash, 2015).

A camada totalmente conectada realiza o mesmo papel encontrado em redes neurais artificiais tradicionais. Cada neurônio é conectado a todos os neurônios das duas camadas anteriores. Camadas totalmente conectadas são normalmente usadas no final de uma CNN, quando o objetivo é utilizar os dados transformados pela convolução e pelo pooling para gerar valores de saída (O’Shea & Nash, 2015).

ResNets

Um dos modelos CNN mais utilizados é o ResNet, que adotou o aprendizado residual para camadas empilhadas (He *et al.*, 2015). As CNNs profundas enfrentam

o problema do gradiente de fuga, no qual ocorre retorno diminutivo da precisão conforme aumenta-se a profundidade da rede. A ResNet adiciona conexões de salto para permitir que os gradientes fluam das camadas finais para os filtros iniciais, resultando em melhor precisão (Shafiq & Gu, 2022). 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 várias 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. 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.

MobileNet

MobileNet (Howard *et al.*, 2017) é um modelo pequeno, de baixa latência e baixo consumo energético parametrizado para atender diversos casos de uso. O modelo tem foco em dispositivos embarcados e móveis que possuem capacidade de processamento limitada. O *MobileNet* 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.

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 *et al.*, 2017).

Embora a arquitetura do *MobileNet* seja pequena e computacionalmente pouco intensiva, possui dois hiperparâmetros globais opcionais para reduzir ainda mais o custo computacional.

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	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
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 16: Arquitetura do *MobileNet* (Howard *et al.*, 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.

EfficientNet

A *EfficientNet* (Tan & Le, 2019) é uma arquitetura de rede neural convolucional e 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, a *EfficientNet* dimensiona uniformemente a largura, a profundidade e a resolução da rede com um conjunto de coeficientes de dimensionamento fixos.

A *EfficientNet* é baseada 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 17.

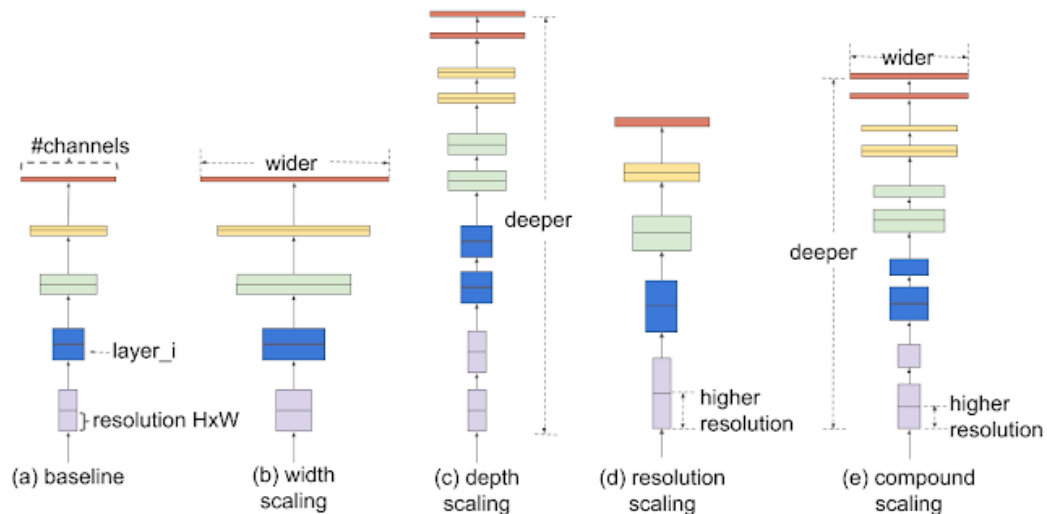


Figura 17: Diferentes métodos de dimensionamento versus dimensionamento composto (Tan & Le, 2019)

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 da 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).

Comparação do desempenho padrão de modelos

A Figura 18 apresenta uma comparação das principais CNNs mencionadas 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 & Le, 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 pela 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 para uma implanatacao de dispositivos com desempenho limitado, como aparelhos móveis devido a seu tamanho e dificuldade de adaptá-lo a um aplicativo.

Levando em consideração uma 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.

3. Análise de Estado da Arte

Para levantar o estado da arte sobre pesquisas do uso de *Deep Learning* para classificação de lagartas, foi realizada uma revisão sistemática de acordo com os procedimentos descritos por Petersen *et al.*, (2008)

3.1 Definição do protocolo de revisão

O objetivo da revisão é responder à questão: quais pesquisas existem para a classificação automática de lagartas utilizando *Deep Learning*? Esta pergunta de pesquisa é refinada nas seguintes questões de análise:

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

AQ2. Como é formado o dataset e quantas imagens possui?

AQ3. Como os modelos foram treinados?

AQ4. Quais foram os desempenhos relatados?

AQ5. O modelo de DL foi implantado?

Critérios de inclusão/exclusão

Foram consideradas apenas pesquisas voltadas à classificação de lagartas a partir de imagens. Pesquisas voltadas para classificação de insetos de forma mais geral que também incluem lagartas no seu escopo foram incluídas. Pesquisas não focadas em imagens de lagartas e que não incluem lagartas em seu escopo, como identificação de mariposas/borboletas adultas, assim como pesquisas sobre classificação de habitat foram excluídas. Também não foram consideradas pesquisas focadas em tarefas que não sejam classificação de imagens (detecção de objetos, uso de vídeos). Foram considerados trabalhos publicados nos últimos 10 anos.

Critérios de qualidade

Foram considerados apenas artigos ou materiais com informações suficientes

(resumos não foram considerados).

Fontes dos dados

Foram revisados artigos e materiais disponíveis no ACM Digital Library, IEEE, Scopus disponíveis gratuitamente por meio do portal CAPES, em inglês e português. Para complementar a busca, foi realizada uma busca no Google Scholar, uma vez que consegue indexar um amplo conjunto de dados de várias fontes (Haddaway *et al.*, 2015).

Definição da *string* de busca

A *string* de busca foi composta de conceitos relacionados à questão de pesquisa, incluindo sinônimos.

Termo	Sinônimo
<i>Larvae</i>	
<i>Caterpillar</i>	<i>Lonomia, Moth, Butterfly</i>
"Deep Learning"	"machine learning", "artificial intelligence", "image classification", "image recognition", "neural network"

Tabela 3. Termos de busca utilizados no protocolo de revisão

A partir disto, foi gerada a *string* genérica de busca:

Larvae AND (Caterpillar OR Lonomia OR Moth OR Butterfly) AND ("Deep Learning" OR "Machine Learning" OR "Image Classification" OR "Image recognition" OR "Neural Network")

E a partir da *string* genérica foram criadas strings específicas para cada fonte de pesquisa.

Fonte	String de busca
IEEE	(Larvae AND (Caterpillar OR Lonomia OR Moth) AND ("Deep Learning" OR "Machine Learning" OR "Image Classification" OR "Neural Network"))
Scopus	TITLE-ABS-KEY(Larvae AND (Caterpillar OR Lonomia OR Moth OR Butterfly) AND ("Deep Learning" OR "Machine Learning" OR "Image Classification" OR "Image recognition" OR "Neural Network"))
ACM	Abstract:(Larvae AND (Caterpillar OR Lonomia OR Moth OR Butterfly) AND ("Deep Learning" OR "Machine Learning" OR "Image Classification" OR "Image recognition"

	OR "Neural Network"))
Google Scholar	"Larvae" AND "Lonomia" OR "Moth" OR "Butterfly" AND "Deep Learning" OR "image classification" -segmentation -population -sound -habitat -acoustic after:2013

Tabela 4. *Strings* de busca das respectivas fontes de pesquisa.

3.2 Execução da busca

A busca foi realizada em outubro de 2023 pelo autor e revisada pela orientadora. As pesquisas retornaram poucos resultados, e vários não se encaixaram nos critérios de inclusão.

Fonte	Resultados encontrados	Resultados analisados	Resultados potencialmente relevantes	Resultados relevantes
IEEE	1	1	1	0
Scopus	18	18	5	1
ACM	0	0	0	0
Google Scholar	87	87	6	0
Total				1

Tabela 5. Resultados da busca

Após a realização da busca, foi feita uma análise do título e resumo dos artigos encontrados a fim de apurar os artigos potencialmente relevantes. Estes, por sua vez, foram lidos por completo para assegurar a aderência aos critérios de inclusão e exclusão, assim como critérios de qualidade.

Como a presente pesquisa é focada na classificação de espécies mariposas em seu estágio larval, muitos dos resultados que realizam classificação destes insetos em sua forma adulta foram considerados não relevantes. Por consequência, apenas um artigo foi considerado relevante para esta revisão.

Na Tabela 6 são apresentados alguns dos resultados mais relevantes que foram excluídos pelos critérios de revisão.

Tabela 6. Resultados excluídos da revisão.

Referência	Título	Motivo de exclusão
Suárez <i>et al.</i> , 2021	Pest detection and classification to reduce pesticide use in fruit crops based on deep neural networks and image processing	Classifica apenas mariposas adultas.
Chen <i>et al.</i> , 2019	Agricultural Pests Damage Detection Using Deep Learning	Detecta danos causados por lagartas em folhas, não as lagartas em si.
Sagar <i>et al.</i> 2020	Identification of Indian butterflies and moths with deep convolutional neural networks	Classifica apenas mariposas adultas.
Khan <i>et al.</i> , 2021	Harmful insect detection using Deep Learning	Classifica apenas mariposas adultas.
Xin <i>et al.</i> , 2020	Fine-Grained Butterfly Classification in Ecological Images Using Squeeze-And-Excitation and Spatial Attention Modules	Classifica apenas mariposas adultas.

3.3 Resultados da revisão

Como resultado da busca foi encontrado somente um artigo relevante: *Real-Time Soybean Crop Insect Classification Using Customized Deep Learning Models* (Tiwari *et al.*, 2021).

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

O trabalho de Tiwari *et al.* foca em espécies de insetos comumente encontrados em plantações de soja na Índia, que representam um risco para produção destas plantações. Foram incluídas 3 espécies de lagartas, que abrangem dois gêneros: *Spodoptera* e *Amsacta*. Também foi incluída uma espécie de inseto do gênero *Eocanthecona*. No artigo é descrito que existem outras espécies de insetos que afetam plantações de soja, mas estas espécies foram selecionadas por demonstrarem risco maior.

3.3.2 Como é formado o conjunto de imagens e quantas imagens possui?

O conjunto de imagens é composto de um total de 3.824 imagens. As imagens também possuem arquivos CSV anexados que descrevem *bounding boxes* que identificam onde o inseto se encontra na imagem. Estes dados CSV são usados pelo modelo de ML descrito para distinguir o conteúdo dentro das *bounding boxes* como um objeto diferente, separando-o do ruído presente nas imagens. O conjunto de imagens também foi aumentado com imagens cortadas para simular diferenças de distâncias entre diferentes imagens.

3.3.3 Como os modelos foram treinados?

Foram treinados dois modelos de *CNN*: um utilizando a arquitetura VGG16 (Simonyan, & Zisserman, 2014) e o outro utilizando GoogLeNet (Szegedy *et al*, 2015). Ambos os modelos foram treinados com 30 épocas. A divisão de imagens de treino, validação e teste foi feita com amostragem aleatória. Para validação, foi utilizada a técnica *K-Fold Cross-Validation*, que divide o conjunto de imagens em diferentes subconjuntos, que são circulados entre treino e teste. Segundo Tiwari *et al*, o conjunto de imagens de validação foi separado antes de começar o treinamento e portanto não foi incluído na rotação treino-teste que foi aplicada ao resto do conjunto de imagens.

Os modelos foram treinados usando *Keras* utilizando a biblioteca *TensorFlow* em *Python*. Apesar de usar *frameworks* prontos, os autores iniciaram os pesos com valores aleatórios, então não houve uso de *transfer learning*.

Ambos os modelos utilizaram acurácia como métrica de avaliação, e método do gradiente estocástico (*SGD*) como otimizador. O *SGD* teve taxa de aprendizado, *decay* e *momentum* como e-6, e-6 e 0.9, respectivamente (Tiwari et al., 2021).

Para o treinamento, os conjuntos de treinamento, validação e teste foram divididos com uma proporção 8:1:1, resultando em 3.049 imagens de treinamento , 380 de validação e 380 de teste.

3.3.4 Quais foram os desempenhos relatados?

Segundo os resultados de Tiwari *et al.*, ambos os modelos apresentam bom nível de precisão de teste e validação, atingindo valores acima de 95% em ambas as arquiteturas.

Model	Testing accuracy (%)	Testing loss
VGG16	96.30	0.1713
GoogLeNet	98.96	69.4832

Tabela 7. Resultados comparativos de treinamento dos modelos (Fonte: Tiwari *et al.*, 2021).

Epoch	Training accuracy	Training loss	Validation accuracy	Validation loss
5	47.82	1.1873	73.92	1.0763
10	77.49	0.6406	89.96	0.3909
15	91.19	0.2728	94.78	0.1531
20	94.39	0.1618	97.13	0.0939
25	96.73	0.1088	97.78	0.0749
30	97.39	0.0846	97.78	0.0852

Tabela 8. Acurácia e perda por época de treinamento do modelo VGG16 (Fonte: Tiwari *et al.*, 2021).

Epoch	Training accuracy	Training loss	Validation accuracy	Validation loss
5	37.41	83.1946	52.59	82.1079
10	63.52	81.8336	75.70	81.5952
15	89.36	79.3587	93.41	79.0230
20	95.99	76.7385	96.44	76.4295
25	97.99	73.5986	97.52	73.2625
30	98.66	69.9045	99.03	69.5098

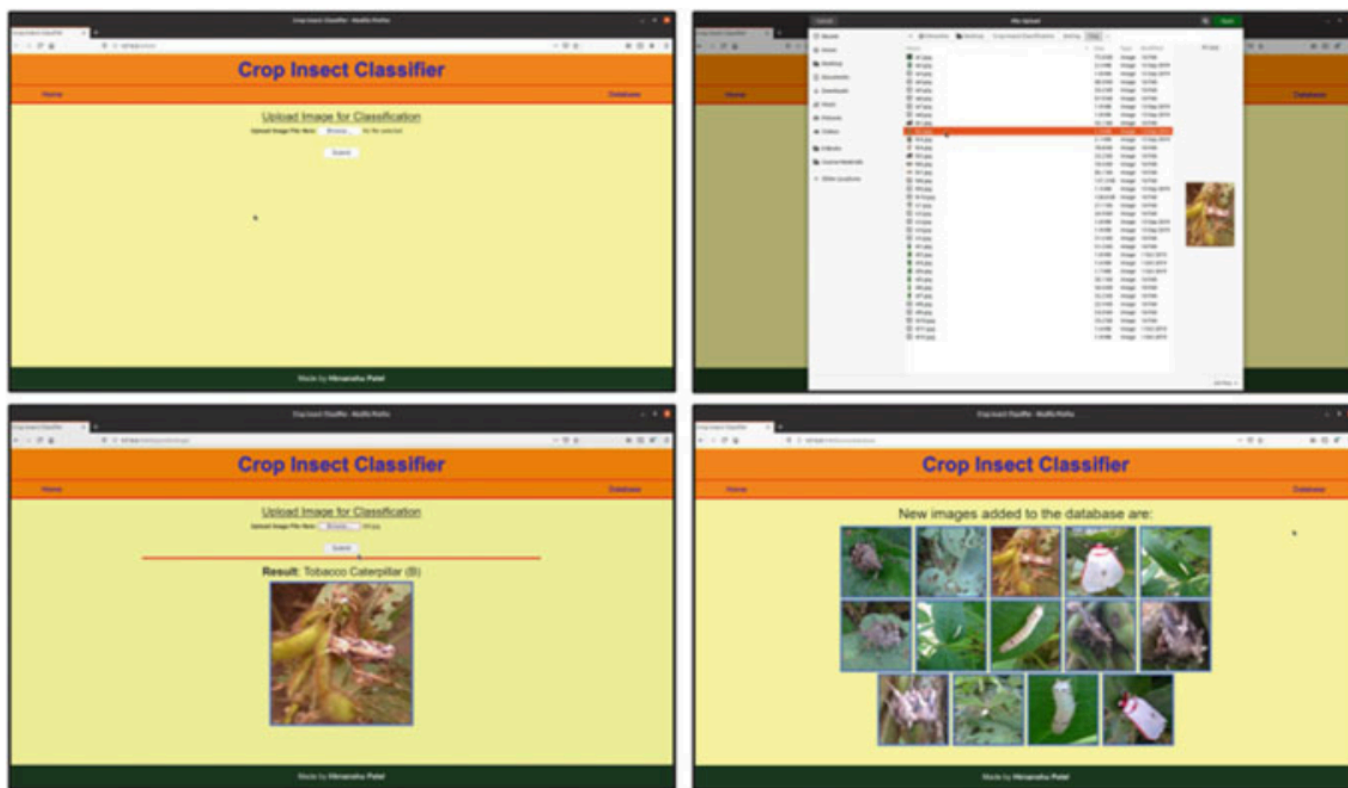
Tabela 9 Acurácia e perda por época de treinamento do modelo GoogLeNet (Fonte: Tiwari *et al.*, 2021).

Vale comentar que não foram relatadas outras medidas de desempenho, como matriz de confusão ou *F1-Score*. No artigo foi decidido uso do modelo GoogLeNet para implementação no aplicativo por apresentar melhor performance e

tamanho de arquivo menor.

3.3.5 O modelo de *DL* foi implantado?

Além do desenvolvimento do modelo, Tiwari *et al.* também implantaram o modelo GoogLeNet em um *App* para plataforma Android, implementado com uso de *Java* e *Android Studio*. Assim como em uma aplicação *Web* desenvolvida utilizando o *framework Django* para *Python*. A aplicação *Web* possui a funcionalidade de ler uma imagem salva em disco e realizar a classificação do inseto presente na foto.



O *App* desenvolvido possui a funcionalidade de permitir o uso do modelo exportado com a câmera de celular, com as telas disponibilizadas apresentadas na Figura 19.

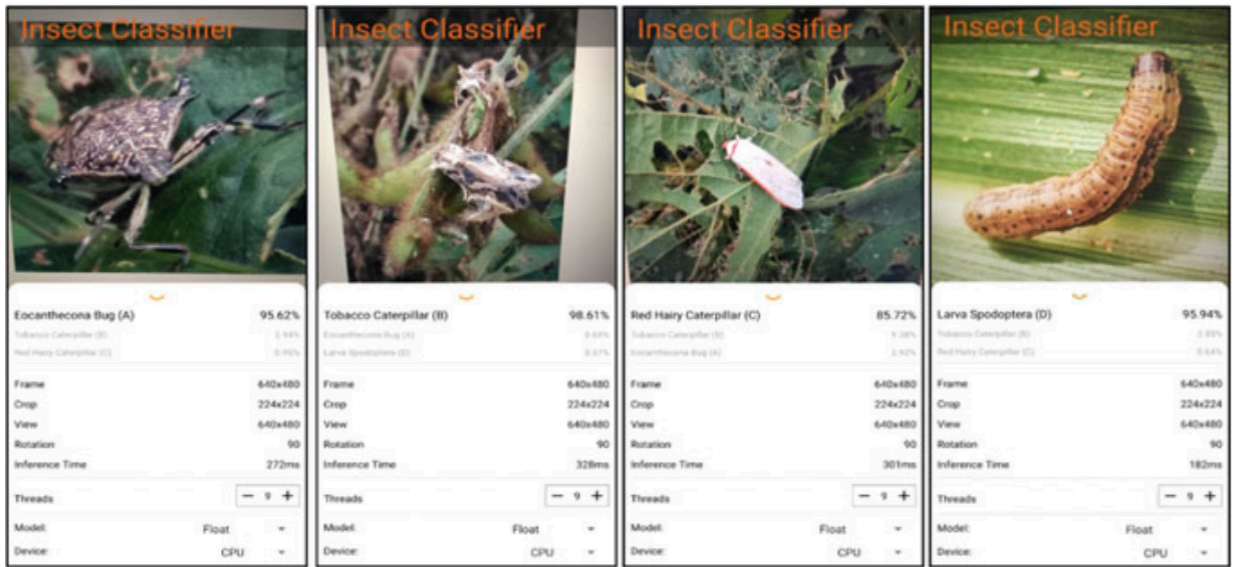


Figura 19. Telas do Aplicativo móvel (Tiwari *et al.*, 2021)

3.4 Discussão

Apesar de existirem múltiplas pesquisas voltadas à identificação de Lepidópteros na fase adulta, foi encontrado apenas um único trabalho envolvendo classificação de lagartas especificamente, apesar de existirem vários trabalhos focados na detecção da presença de lagartas em áreas de plantação. A demanda por soluções inteligentes para sistemas de defesa agrícola incentivou a aplicação de *Deep Learning* nestes sistemas, levando justamente à exploração da capacidade destes modelos identificarem corretamente espécies de lagartas, como no caso de *Tiwari et al.*

A partir da análise do estado da arte, percebe-se que ainda é muito raro a aplicação de DL para classificação de lagartas de forma geral e ainda não existe nenhum modelo para classificação de espécies peçonhentas de Santa Catarina, ou sequer de outras regiões da América do Sul que também são afetadas por acidentes com lagartas peçonhentas.

Ameaças à validade: É importante ressaltar que existem ameaças à validade dos resultados neste mapeamento sistemático. A fim de mitigar o impacto causado

por essas ameaças, algumas foram destacadas e medidas atenuantes foram tomadas:

Viés de Publicação: Resultados positivos tendem a ser publicados em detrimento de resultados negativos, podendo gerar viés no mapeamento. Porém, dado que este estudo se concentra no estado da arte e não é afetado gravemente por esta tendência, o viés de publicação não apresenta uma ameaça séria neste caso.

Identificação de estudos: Há um risco de estudos relevantes serem omitidos, particularmente por conta da classificação de lagartas ser uma área relativamente inexplorada e sobreposta por outros métodos de detecção e classificação. Este risco foi mitigado pela construção da *string* de busca, que inclui sinônimos relevantes, e pela busca em diversas bases de dados.

Seleção e extração de dados dos estudos: A definição de critérios explícitos de inclusão e exclusão, bem como critérios de qualidade, contribuiu para mitigar a ameaça de informações incorretas serem extraídas, a fim de garantir a confiabilidade dos dados extraídos.

4. Solução

4.1 Análise do requisitos

Para poder realizar a análise de requisitos, inicialmente foi feita uma análise do contexto de potenciais usuários por meio de um questionário aplicado com 38 voluntários anônimos representantes do público alvo. A partir deste estudo foram descritos os requisitos funcionais e de usabilidade do aplicativo móvel, assim como os requisitos funcionais do modelo de *DL*.

Realização de *survey*

O questionário foi aplicado via *Google Forms* e respondido por 38 pessoas. As perguntas feitas foram:

- Com que frequência encontra lagartas no dia a dia?
- Como avaliaria seu conhecimento sobre lagartas peçonhentas?
- Em qual faixa etária você se encontra?
- Qual a sua escolaridade?
- Já teve acidente com uma lagarta peçonhenta?
- Em caso de acidente, saberia quem procurar? Se sim, quem procuraria?
- Realiza trilhas com que frequência?
- Trabalha com jardinagem, paisagismo ou trabalho semelhante?
- Frequenta parques, jardins ou áreas com cobertura de árvores?
- Quais são os 3 apps que você mais usa no dia a dia?
- Se existisse um App para identificação de lagartas, você usaria?
- Se respondeu sim à última pergunta, quanto tempo você acha que deveria levar, da abertura do app até receber uma resposta sobre espécie de lagarta e nível de perigo?

A partir das respostas foram extraídas informações chave sobre o contexto dos potenciais usuários:

- Tempo máximo de uso, de abertura do *App* até a classificação: **1 minuto**.
- 13 dos 38 participantes (34,21%) **não** saberiam para onde procurar ajuda em caso de acidentes com lagartas peçonhentas. Os demais afirmaram que iriam procurar postos de saúde, emergência de hospital próximo ou bombeiros.
- 7 dos 38 participantes (18,4%) **já tiveram** acidentes com lagartas peçonhentas.
- 25 dos 38 participantes (65,8%) afirmaram que **usariam o aplicativo**, se este existisse.

A partir das conclusões tiradas sobre o questionário, foi identificada a necessidade da solução proposta de utilizar *Deep Learning* em um aplicativo móvel.

Tabela 10. Identificação de necessidade da solução.

Qual é o problema/ necessidade identificado?	Com o crescente número de acidentes envolvendo lagartas peçonhentas, é importante que o cidadão saiba o perigo envolvido com contato com estes insetos, o que fazer em caso de acidentes e principalmente identificar as espécies mais perigosas.
Ponto de Vista (POV)	COMO Cidadão EU QUERO descobrir qual espécie é uma lagarta PARA procurar ajuda adequada.
Como podemos (HMW)	COMO PODEMOS ajudar o cidadão a saber qual lagarta encontrou?

Baseado na necessidade identificada, foram identificados os requisitos funcionais e requisitos de usabilidade do aplicativo:

Tabela 11. Requisitos funcionais do aplicativo proposto.

Requisito funcional	COMO Cidadão EU QUERO descobrir qual espécie é uma lagarta PARA procurar ajuda adequada.
Funcionalidade(s)	Classificar a espécie de uma lagarta a partir de uma foto dela.
	Fornecer informações sobre espécies de lagartas peçonhentas de SC

Tabela 12. Requisitos de usabilidade do aplicativo proposto.

História de usuário	COMO Cidadão EU QUERO descobrir qual espécie é uma lagarta PARA procurar ajuda adequada.
Eficácia	90% do público alvo conseguem completar a tarefa
Eficiência	Em no max. 1 minutos
Satisfação	Com no mínimo 80 pontos (SUS)

Com base no estudo sobre as espécies de lagartas de SC, realizado no capítulo 2, foram definidos os requisitos funcionais e riscos do modelo *DL* necessário para o funcionamento do *App*.

Tabela 13. Requisitos funcionais do modelo *DL* proposto.

Tarefa	Classificar lagartas de espécies existentes em Santa Catarina por meio de imagens capturadas por um celular Android.	
Tipo de tarefa	Classificação de imagens (<i>Single-Label</i>).	
Categorias	10 categorias	<i>Lonomia obliqua</i> ; <i>Hylesia sp.</i> ; <i>Automeris sp.</i> ;

		<i>Phobetron sp.</i> ; <i>Acharia sp.</i> ; <i>Podalia sp.</i> ; <i>Megalopyge lanata</i> ; <i>Arctiidae sp.</i> ; Lagarta não peçonhenta; Não-lagarta;
Contexto de uso	O modelo é utilizado por um cidadão como orientação sobre prevenção de acidentes com lagartas peçonhentas	
Risco e requisitos de desempenho		
Risco	Risco muito alto Risco de classificar erroneamente a espécie da lagarta. A classificação errada pode prejudicar as ações de resposta em caso de acidentes com lagartas, potencialmente fazendo o cidadão não procurar ajuda profissional em caso possivelmente mortal.	
Desempenho	O modelo de <i>Machine Learning</i> será otimizado para precisão pois deve reduzir o risco de indicar a categoria errada ao usuário, potencialmente colocando-o em perigo.	
Medidas	Acurácia (total/por categoria)	No mínimo 0.95

4.2 Desenvolvimento do modelo de DL

4.2.1 Desenvolvimento do conjunto de imagens

Com base no escopo definido na análise de requisitos, o conjunto de imagens de treino foi criado a partir do conjunto de imagens *iNaturalist Research-grade Observations* (INaturalist e contribuidores, 2024). Este conjunto de imagens agrega observações de usuários da plataforma INaturalist, e contém um largo conjunto de espécies de seres vivos. Cada observação possui pelo menos uma foto, uma data e a localização da observação. O conjunto é rotulado com base no consenso dos usuários da plataforma quanto às espécies observadas. A partir do conjunto de imagens do INaturalist, foram filtradas observações correspondentes às espécies que ocorrem no estado de Santa Catarina.

Também foram adicionadas imagens disponibilizadas e rotuladas pelo CIATOX/SC, assim como fotos tiradas por voluntários. Para a classe Não Lagarta, foram utilizadas fotos disponibilizadas pela iniciativa Computação na Escola/INCoD/INE/UFSC. Em total, o dataset totalizou 6001 imagens, divididas entre as seguintes classes:

Tabela 17. Conjunto de imagens coletadas.

Classe	Quantidade de imagens
Não Lagarta	640
Lagarta não peçonhenta	820
Lonomia sp.	124
Hylesia sp.	556
Acharia sp.	645
Automeris sp.	736
Megalopyge sp.	691
Podalia sp.	817
Phobetron sp.	355
Arctiidae sp.	617


Antes do treinamento, foi realizado um pré-processamento das imagens do conjunto de dados. Foram aplicadas transformações nas imagens para aumentar o tamanho do dataset. A partir das imagens originais, foram feitas novas imagens usando rotações, espelhamentos verticais, espelhamentos horizontais e distorções de perspectiva para gerar um novo dataset. As transformações de imagens foram aplicadas de forma aleatória, com valores fixos definindo a probabilidade de uma transformação ser aplicada seguindo a Tabela 18.


Tabela 18. Transformações aplicadas ao conjunto original.

Rotação aleatória de 90 até 270 graus	70%
---------------------------------------	-----

Espelhamento vertical	70%
Espelhamento horizontal	40%
Distorção de perspectiva	80%

Tabela 19. Transformações aplicadas a uma única imagem.





As características do novo conjunto de imagens resultantes são apresentadas na Tabela 20.

Tabela 20. Conjunto de imagens ampliado.

Classe	Quantidade de imagens
Não Lagarta	1.500
Lagarta não peçonhenta	1.500
Lonomia sp.	1.500
Hylesia sp.	1.500
Acharia sp.	1.500
Automeris sp.	1.500
Megalopyge sp.	1.500
Podalia sp.	1.500
Phobetron sp.	1.500
Arctiidae sp.	1.500
Total de imagens	15.000

4.2.2 Treinamento dos modelos

Para o treinamento, foram selecionadas redes neurais com portabilidade para dispositivos móveis. Além disso, foram priorizadas redes neurais com baixo consumo de memória e com alto desempenho, pois o objetivo final é implantá-las em um aplicativo móvel. Dado estes critérios, foram selecionadas as seguintes redes: *Resnet18*; *Resnet34*; *EfficientNetLite*; *EfficientNetB0*; *MobileNetV3* e *Google Teachable Machine*. Todos os treinamentos foram realizados em um ambiente *Jupyter Notebook*, com exceção do *Teachable Machine*, que foi treinado no ambiente *web* próprio da ferramenta.

Treinamento com *Resnet18*

Treinamento	
Quantidade de épocas	50
Taxa de aprendizagem	0,001
Tamanho de lote	16
Curva de <i>loss</i>	

Acurácia total	94%
-----------------------	------------

Acurácia por classe	<table border="1"> <thead> <tr> <th data-bbox="576 315 1043 394">Classe</th> <th data-bbox="1043 315 1519 394">Acurácia</th> </tr> </thead> <tbody> <tr> <td data-bbox="576 394 1043 468"><i>Acharia sp.</i></td> <td data-bbox="1043 394 1519 468">94%</td> </tr> <tr> <td data-bbox="576 468 1043 542"><i>Arctiidae sp.</i></td> <td data-bbox="1043 468 1519 542">95%</td> </tr> <tr> <td data-bbox="576 542 1043 616"><i>Automeris sp.</i></td> <td data-bbox="1043 542 1519 616">96%</td> </tr> <tr> <td data-bbox="576 616 1043 689"><i>Hylesia sp.</i></td> <td data-bbox="1043 616 1519 689">95%</td> </tr> <tr> <td data-bbox="576 689 1043 763"><i>Lonomia obliqua</i></td> <td data-bbox="1043 689 1519 763">97%</td> </tr> <tr> <td data-bbox="576 763 1043 837"><i>Megalopyge sp.</i></td> <td data-bbox="1043 763 1519 837">94%</td> </tr> <tr> <td data-bbox="576 837 1043 911">Não lagarta</td> <td data-bbox="1043 837 1519 911">96%</td> </tr> <tr> <td data-bbox="576 911 1043 985">Lagarta não peçonhenta</td> <td data-bbox="1043 911 1519 985">91%</td> </tr> <tr> <td data-bbox="576 985 1043 1059"><i>Phobetron sp.</i></td> <td data-bbox="1043 985 1519 1059">97%</td> </tr> <tr> <td data-bbox="576 1059 1043 1133"><i>Podalia sp.</i></td> <td data-bbox="1043 1059 1519 1133">89%</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Acharia sp.</i>	94%	<i>Arctiidae sp.</i>	95%	<i>Automeris sp.</i>	96%	<i>Hylesia sp.</i>	95%	<i>Lonomia obliqua</i>	97%	<i>Megalopyge sp.</i>	94%	Não lagarta	96%	Lagarta não peçonhenta	91%	<i>Phobetron sp.</i>	97%	<i>Podalia sp.</i>	89%																																																																																																			
Classe	Acurácia																																																																																																																									
<i>Acharia sp.</i>	94%																																																																																																																									
<i>Arctiidae sp.</i>	95%																																																																																																																									
<i>Automeris sp.</i>	96%																																																																																																																									
<i>Hylesia sp.</i>	95%																																																																																																																									
<i>Lonomia obliqua</i>	97%																																																																																																																									
<i>Megalopyge sp.</i>	94%																																																																																																																									
Não lagarta	96%																																																																																																																									
Lagarta não peçonhenta	91%																																																																																																																									
<i>Phobetron sp.</i>	97%																																																																																																																									
<i>Podalia sp.</i>	89%																																																																																																																									
Matriz de confusão	<table border="1"> <tbody> <tr> <td>acharia</td> <td>144</td> <td>0</td> <td>3</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> </tr> <tr> <td>arctiidae</td> <td>0</td> <td>159</td> <td>0</td> <td>4</td> <td>2</td> <td>0</td> <td>1</td> <td>2</td> <td>1</td> <td>1</td> </tr> <tr> <td>automeris</td> <td>1</td> <td>0</td> <td>132</td> <td>1</td> <td>1</td> <td>0</td> <td>1</td> <td>2</td> <td>0</td> <td>2</td> </tr> <tr> <td>hylesia</td> <td>2</td> <td>5</td> <td>2</td> <td>162</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>3</td> </tr> <tr> <td>lonomia</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>149</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <td>megalopyge</td> <td>1</td> <td>0</td> <td>1</td> <td>1</td> <td>0</td> <td>110</td> <td>1</td> <td>4</td> <td>2</td> <td>14</td> </tr> <tr> <td>nao-lagarta</td> <td>1</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>131</td> <td>0</td> <td>1</td> <td>0</td> </tr> <tr> <td>nao-peconhenta</td> <td>3</td> <td>2</td> <td>0</td> <td>1</td> <td>0</td> <td>2</td> <td>1</td> <td>115</td> <td>0</td> <td>1</td> </tr> <tr> <td>phobetron</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>1</td> <td>0</td> <td>2</td> <td>147</td> <td>0</td> </tr> <tr> <td>podalia</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>4</td> <td>1</td> <td>1</td> <td>0</td> <td>165</td> </tr> <tr> <td></td> <td>acharia</td> <td>arctiidae</td> <td>automeris</td> <td>hylesia</td> <td>lonomia</td> <td>megalopyge</td> <td>nao-lagarta</td> <td>nao-peconhenta</td> <td>phobetron</td> <td>podalia</td> </tr> </tbody> </table>	acharia	144	0	3	0	0	0	0	1	0	0	arctiidae	0	159	0	4	2	0	1	2	1	1	automeris	1	0	132	1	1	0	1	2	0	2	hylesia	2	5	2	162	2	0	0	0	0	3	lonomia	0	0	0	0	149	0	0	0	0	0	megalopyge	1	0	1	1	0	110	1	4	2	14	nao-lagarta	1	1	0	0	0	0	131	0	1	0	nao-peconhenta	3	2	0	1	0	2	1	115	0	1	phobetron	1	0	0	1	0	1	0	2	147	0	podalia	0	1	0	0	0	4	1	1	0	165		acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia
acharia	144	0	3	0	0	0	0	1	0	0																																																																																																																
arctiidae	0	159	0	4	2	0	1	2	1	1																																																																																																																
automeris	1	0	132	1	1	0	1	2	0	2																																																																																																																
hylesia	2	5	2	162	2	0	0	0	0	3																																																																																																																
lonomia	0	0	0	0	149	0	0	0	0	0																																																																																																																
megalopyge	1	0	1	1	0	110	1	4	2	14																																																																																																																
nao-lagarta	1	1	0	0	0	0	131	0	1	0																																																																																																																
nao-peconhenta	3	2	0	1	0	2	1	115	0	1																																																																																																																
phobetron	1	0	0	1	0	1	0	2	147	0																																																																																																																
podalia	0	1	0	0	0	4	1	1	0	165																																																																																																																
	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
Interpretação	O modelo apresentou acurácia alta para boa parte das classes, em especial																																																																																																																									

	tendo acurácia de 97% com <i>Lonomia obliqua</i> . Observando a matriz de confusão também se observa que em poucos casos o modelo confunde lagartas peçonhentas por lagartas não peçonhentas ou objetos que não são lagartas.
Aceitação do modelo	O modelo está próximo do resultado esperado, mas ainda não atingiu a acurácia de 95%.

Treinamento com *Resnet34*

Treinamento	
Quantidade de épocas	50
Taxa de aprendizagem	0,001
Tamanho de lote	16
Curva de <i>loss</i>	

Acurácia total	95%	
Acurácia por classe		
	Classe	Acurácia

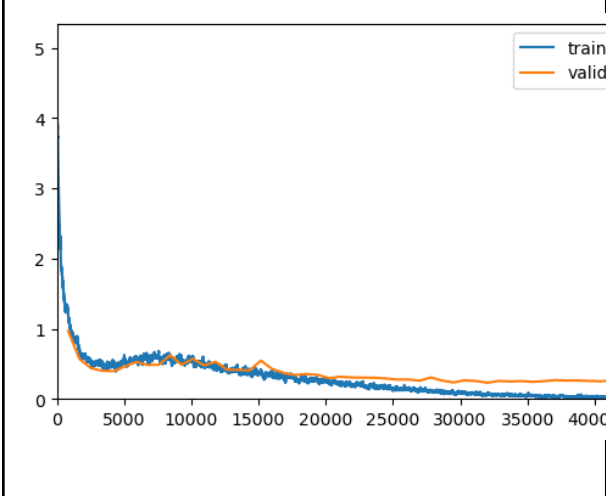
<i>Acharia sp.</i>	94%
<i>Arctiidae sp.</i>	96%
<i>Automeris sp.</i>	97%
<i>Hylesia sp.</i>	95%
<i>Lonomia obliqua</i>	98%
<i>Megalopyge sp.</i>	93%
Não lagarta	97%
Lagarta não peçonhenta	91%
<i>Phobetron sp.</i>	99%
<i>Podalia sp.</i>	91%

Matriz de confusão	Actual	acharia	146	0	0	0	1	0	0	0	0	1
		arctiidae	1	157	2	2	1	1	0	4	0	2
		automeris	3	0	129	3	0	0	1	3	0	1
		hylesia	2	5	0	165	1	0	1	1	0	1
		lonomia	0	0	0	0	149	0	0	0	0	0
		megalopyge	0	1	1	0	0	119	1	1	0	11
		nao-lagarta	1	0	0	0	0	1	130	1	1	0
		nao-peconhenta	2	1	1	2	0	1	0	116	1	1
		phobetron	0	0	0	0	0	1	0	1	150	0
		podalia	0	0	0	2	0	5	1	1	0	163
				acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron
		Predicted										

Interpretação O modelo Resnet34 apresentou acurácia de pelo menos 90% para todas as

	classes. Ainda aparenta ter confusões semelhantes aos modelos anteriores, especialmente com a espécie <i>Podalia sp.</i>
Aceitação do modelo	O modelo atinge acurácia de 95%, porém ainda possui possibilidade de melhoria.

Treinamento com *EfficientNetLite*

Treinamento	
Quantidade de épocas	50
Taxa de aprendizagem	0,001
Tamanho de lote	16
Curva de <i>loss</i>	

Acurácia total	95%					
Acurácia por classe	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>97%</td> </tr> </tbody> </table>		Classe	Acurácia	<i>Acharia sp.</i>	97%
Classe	Acurácia					
<i>Acharia sp.</i>	97%					

<i>Arctiidae sp.</i>	94%
<i>Automeris sp.</i>	96%
<i>Hylesia sp.</i>	97%
<i>Lonomia obliqua</i>	99%
<i>Megalopyge sp.</i>	93%
Não lagarta	97%
Lagarta não peçonhenta	92%
<i>Phobetron sp.</i>	97%
<i>Podalia sp.</i>	90%

Matriz de confusão	Confusion matrix										
	acharia	144	0	2	0	0	0	0	1	0	1
	arctiidae	0	161	1	3	0	1	0	1	1	2
	automeris	1	0	132	2	0	0	1	2	1	1
	hylesia	1	3	0	167	1	0	1	3	0	0
	lonomia	0	0	0	0	149	0	0	0	0	0
	megalopyge	0	3	0	0	0	114	1	1	2	13
	nao-lagarta	0	0	1	0	0	0	132	1	0	0
	nao-peconhenta	2	2	0	1	0	0	1	118	0	1
	phobetron	1	0	0	0	0	0	0	0	151	0
	podalia	0	3	1	0	0	8	0	1	0	159
		acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia
		Predicted									

Interpretação O modelo apresentou acurácia semelhante aos anteriores, com um aumento de acurácia nas classes que já atingiram 95% de acurácia. No

	entanto, as classes que ainda não atingiram a acurácia alvo não tiveram aumento significativo.
Aceitação do modelo	O modelo atinge acurácia de 95%, porém ainda possui possibilidade de melhoria.

Treinamento com *EfficientNetB0*

Treinamento	
Quantidade de épocas	50
Taxa de aprendizagem	0,001
Tamanho de lote	16
Curva de <i>loss</i>	

Acurácia total	96%	
Acurácia por classe	Classe	Acurácia
	<i>Acharia sp.</i>	99%
	<i>Arctiidae sp.</i>	96%

<i>Automeris sp.</i>	96%
<i>Hylesia sp.</i>	98%
<i>Lonomia obliqua</i>	99%
<i>Megalopyge sp.</i>	89%
Não lagarta	95%
Lagarta não peçonhenta	92%
<i>Phobetron sp.</i>	97%
<i>Podalia sp.</i>	94%

Matriz de confusão	Confusion matrix										
	acharia	143	0	1	0	1	0	0	2	1	0
	arctiidae	0	163	0	2	0	2	0	1	1	1
	automeris	0	1	132	1	1	0	2	2	1	0
	hylesia	0	4	0	169	0	1	1	1	0	0
	lonomia	0	0	0	0	149	0	0	0	0	0
	megalopyge	0	1	2	0	0	119	2	1	0	9
	nao-lagarta	0	0	1	0	0	0	133	0	0	0
	nao-peconhenta	2	0	1	1	0	2	2	116	1	0
	phobetron	0	0	0	0	0	2	0	0	150	0
podalia	0	0	1	0	0	7	0	3	0	161	
		acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia
		Predicted									

Interpretação O modelo apresentou mudanças significativas em algumas classes que aparentavam estagnar nos modelos anteriores. A acurácia da espécie *Megalopyge sp.* diminuiu significativamente neste modelo, quando

	comparado aos anteriores.
Aceitação do modelo	O modelo atinge e supera acurácia de 96%, portanto pode ser aceito. No entanto, com melhoria da acurácia com lagartas <i>Megalopyge</i> , ainda possui espaço para melhoria.

Treinamento com *MobileNetV3*

Treinamento	
Quantidade de épocas	50
Taxa de aprendizagem	0,001
Tamanho de lote	16
Curva de <i>loss</i>	

Acurácia total	95%					
Acurácia por classe	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>99%</td> </tr> </tbody> </table>		Classe	Acurácia	<i>Acharia sp.</i>	99%
Classe	Acurácia					
<i>Acharia sp.</i>	99%					

<i>Arctiidae sp.</i>	96%
<i>Automeris sp.</i>	96%
<i>Hylesia sp.</i>	97%
<i>Lonomia obliqua</i>	100%
<i>Megalopyge sp.</i>	93%
Não lagarta	95%
Lagarta não peçonhenta	91%
<i>Phobetron sp.</i>	99%
<i>Podalia sp.</i>	90%

Matriz de confusão	Confusion matrix										
	acharia	144	0	2	0	0	0	0	2	0	0
	arctiidae	0	163	1	2	0	0	2	1	0	1
	automeris	0	1	135	0	0	0	1	3	0	0
	hylesia	0	3	0	165	0	1	1	3	1	2
	lonomia	0	0	0	0	149	0	0	0	0	0
	megalopyge	0	0	0	1	0	116	2	3	0	12
	nao-lagarta	0	2	2	0	0	1	129	0	0	0
	nao-peconhenta	0	1	1	2	0	0	0	119	0	2
	phobetron	1	0	0	0	0	0	0	0	149	2
	podalia	1	0	0	0	0	7	1	0	1	162
		acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia
		Predicted									

Interpretação	O modelo demonstra acurácia comparável com o modelo EfficientNetLite, com variações pequenas de acurácia
----------------------	--

Aceitação do modelo	O modelo atinge a acurácia de 95%, portanto pode ser aceito. No entanto, ainda possui espaço para melhoria.
----------------------------	---

Treinamento com *MobileNetV3* - *Google Teachable Machine*

Treinamento	
Quantidade de épocas	50
Taxa de aprendizagem	0,001
Tamanho de lote	16
Curva de <i>loss</i>	

Acurácia total	80%									
Acurácia por classe	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>82%</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>71%</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>80%</td> </tr> </tbody> </table>		Classe	Acurácia	<i>Acharia sp.</i>	82%	<i>Arctiidae sp.</i>	71%	<i>Automeris sp.</i>	80%
Classe	Acurácia									
<i>Acharia sp.</i>	82%									
<i>Arctiidae sp.</i>	71%									
<i>Automeris sp.</i>	80%									

	<table border="1"> <tbody> <tr> <td><i>Hylesia sp.</i></td> <td>74%</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>97%</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>68%</td> </tr> <tr> <td>Não lagarta</td> <td>92%</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>79%</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>80%</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>77%</td> </tr> </tbody> </table>	<i>Hylesia sp.</i>	74%	<i>Lonomia obliqua</i>	97%	<i>Megalopyge sp.</i>	68%	Não lagarta	92%	Lagarta não peçonhenta	79%	<i>Phobetron sp.</i>	80%	<i>Podalia sp.</i>	77%																																																																																																											
<i>Hylesia sp.</i>	74%																																																																																																																									
<i>Lonomia obliqua</i>	97%																																																																																																																									
<i>Megalopyge sp.</i>	68%																																																																																																																									
Não lagarta	92%																																																																																																																									
Lagarta não peçonhenta	79%																																																																																																																									
<i>Phobetron sp.</i>	80%																																																																																																																									
<i>Podalia sp.</i>	77%																																																																																																																									
Matriz de confusão	<table border="1"> <thead> <tr> <th>Class</th> <th>acharia</th> <th>arctiidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao lagarta</th> <th>nao peçonhen...</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>184</td> <td>3</td> <td>10</td> <td>4</td> <td>0</td> <td>2</td> <td>1</td> <td>15</td> <td>1</td> <td>5</td> </tr> <tr> <th>arctiidae</th> <td>8</td> <td>159</td> <td>5</td> <td>13</td> <td>3</td> <td>11</td> <td>1</td> <td>16</td> <td>1</td> <td>8</td> </tr> <tr> <th>automeris</th> <td>6</td> <td>10</td> <td>179</td> <td>10</td> <td>2</td> <td>4</td> <td>1</td> <td>9</td> <td>4</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>9</td> <td>11</td> <td>11</td> <td>167</td> <td>5</td> <td>2</td> <td>1</td> <td>15</td> <td>4</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>0</td> <td>1</td> <td>3</td> <td>2</td> <td>218</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>14</td> <td>3</td> <td>5</td> <td>6</td> <td>3</td> <td>152</td> <td>1</td> <td>10</td> <td>9</td> <td>22</td> </tr> <tr> <th>nao lagarta</th> <td>1</td> <td>0</td> <td>4</td> <td>0</td> <td>0</td> <td>6</td> <td>207</td> <td>1</td> <td>5</td> <td>1</td> </tr> <tr> <th>nao peçonhen...</th> <td>12</td> <td>3</td> <td>10</td> <td>6</td> <td>0</td> <td>8</td> <td>3</td> <td>177</td> <td>2</td> <td>4</td> </tr> <tr> <th>phobetron</th> <td>10</td> <td>1</td> <td>1</td> <td>2</td> <td>2</td> <td>8</td> <td>3</td> <td>10</td> <td>180</td> <td>8</td> </tr> <tr> <th>podalia</th> <td>9</td> <td>6</td> <td>1</td> <td>1</td> <td>2</td> <td>20</td> <td>2</td> <td>8</td> <td>2</td> <td>174</td> </tr> </tbody> </table>	Class	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao lagarta	nao peçonhen...	phobetron	podalia	acharia	184	3	10	4	0	2	1	15	1	5	arctiidae	8	159	5	13	3	11	1	16	1	8	automeris	6	10	179	10	2	4	1	9	4	0	hylesia	9	11	11	167	5	2	1	15	4	0	lonomia	0	1	3	2	218	0	0	0	1	0	megalopyge	14	3	5	6	3	152	1	10	9	22	nao lagarta	1	0	4	0	0	6	207	1	5	1	nao peçonhen...	12	3	10	6	0	8	3	177	2	4	phobetron	10	1	1	2	2	8	3	10	180	8	podalia	9	6	1	1	2	20	2	8	2	174
Class	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao lagarta	nao peçonhen...	phobetron	podalia																																																																																																																
acharia	184	3	10	4	0	2	1	15	1	5																																																																																																																
arctiidae	8	159	5	13	3	11	1	16	1	8																																																																																																																
automeris	6	10	179	10	2	4	1	9	4	0																																																																																																																
hylesia	9	11	11	167	5	2	1	15	4	0																																																																																																																
lonomia	0	1	3	2	218	0	0	0	1	0																																																																																																																
megalopyge	14	3	5	6	3	152	1	10	9	22																																																																																																																
nao lagarta	1	0	4	0	0	6	207	1	5	1																																																																																																																
nao peçonhen...	12	3	10	6	0	8	3	177	2	4																																																																																																																
phobetron	10	1	1	2	2	8	3	10	180	8																																																																																																																
podalia	9	6	1	1	2	20	2	8	2	174																																																																																																																
Interpretação	O modelo apresenta acurácia boa para identificação de <i>Lonomia obliqua</i> e não-lagartas. No entanto, a acurácia das outras classes não atinge 90%.																																																																																																																									
Aceitação do modelo	O modelo não atinge a acurácia alvo.																																																																																																																									

4.2.3 Testes de desempenho

Os testes dos modelos treinados foram realizados por predição de imagens novas não utilizadas para o treinamento ou validação, em concordância com a norma ISO/IEC 4213 (2022).

Preparação do teste

O conjunto de teste contém 300 imagens no total, com as características qualitativas dos dados descrita na Tabela 21.

Tabela 21. Características do conjunto de dados de teste

Característica	Especificação																						
Número total de imagens no conjunto de testes	300 imagens																						
Distribuição do conjunto de imagens	<table border="1"> <thead> <tr> <th>Classe</th> <th>Número de imagens</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>30</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>30</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>30</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>30</td> </tr> </tbody> </table>	Classe	Número de imagens	<i>Acharia sp.</i>	30	<i>Arctiidae sp.</i>	30	<i>Automeris sp.</i>	30	<i>Hylesia sp.</i>	30	<i>Lonomia obliqua</i>	30	<i>Megalopyge sp.</i>	30	Não lagarta	30	Lagarta não peçonhenta	30	<i>Phobetron sp.</i>	30	<i>Podalia sp.</i>	30
Classe	Número de imagens																						
<i>Acharia sp.</i>	30																						
<i>Arctiidae sp.</i>	30																						
<i>Automeris sp.</i>	30																						
<i>Hylesia sp.</i>	30																						
<i>Lonomia obliqua</i>	30																						
<i>Megalopyge sp.</i>	30																						
Não lagarta	30																						
Lagarta não peçonhenta	30																						
<i>Phobetron sp.</i>	30																						
<i>Podalia sp.</i>	30																						

Uso das imagens	Essas imagens não foram usadas para treinamento ou validação dos modelos.
Fonte	As imagens foram separadas do conjunto de dados de nível de pesquisa do iNaturalist.
Verdade Fundamental	As imagens foram rotuladas por pesquisadores usuários da plataforma iNaturalist e as rotulações foram confirmadas por pesquisadores da iniciativa Computação na Escola/INCoD/INE/UFSC em colaboração com biólogos do CIATox/SC e LBMM/UFSC
Pré-processamento	Nenhum pré-processamento foi aplicado ao conjunto de teste
Precisão do conjunto de teste	A precisão dos rótulos das imagens é de 100%
Completude 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 no conjunto de teste
Consistência do conjunto de teste	As imagens são separadas em pastas de acordo com a classe. As imagens são nomeadas por classe e número
Autenticidade do conjunto de teste	As imagens foram coletadas em campo por contribuidores do iNaturalist tirando fotos de espécies encontradas na região de interesse (Santa Catarina/Brasil)
	As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso
Robustez do conjunto de teste	As imagens foram coletadas variando o plano de fundo, ângulos, iluminação, distância, etc., a fim de evitar efeitos de canalização ou viés.
Confidencialidade do conjunto de teste	Não aplicável

Métricas

Para avaliar os modelos, as seguintes métricas foram utilizadas:

- Acurácia para avaliação de desempenho geral
- Precisão e *recall* para compreensão de como o modelo lida com falsos positivos e falsos negativos
- *F1-Score*, média harmônica de precisão e *recall* para avaliar a diferença entre as pontuações das medidas prévias.

Ambiente de execução

Os testes foram realizados usando Jupyter Notebooks no ambiente Google Colab. Os testes com Teachable Machine foram realizados utilizando a plataforma de prévia do mesmo para execução das predições das imagens de teste, e o cálculo das métricas foi realizado no mesmo ambiente de teste dos outros modelos.

Resultado dos testes com Resnet18

Testes																	
Acurácia total	88,67%																
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>94%</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>76%</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>90%</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>85%</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>91%</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>77%</td> </tr> <tr> <td>Não lagarta</td> <td>100%</td> </tr> </tbody> </table>	Classe	Acurácia	<i>Acharia sp.</i>	94%	<i>Arctiidae sp.</i>	76%	<i>Automeris sp.</i>	90%	<i>Hylesia sp.</i>	85%	<i>Lonomia obliqua</i>	91%	<i>Megalopyge sp.</i>	77%	Não lagarta	100%
Classe	Acurácia																
<i>Acharia sp.</i>	94%																
<i>Arctiidae sp.</i>	76%																
<i>Automeris sp.</i>	90%																
<i>Hylesia sp.</i>	85%																
<i>Lonomia obliqua</i>	91%																
<i>Megalopyge sp.</i>	77%																
Não lagarta	100%																

	<table border="1"> <tr> <td>Lagarta não peçonhenta</td> <td>100%</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>88%</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>90%</td> </tr> </table>	Lagarta não peçonhenta	100%	<i>Phobetron sp.</i>	88%	<i>Podalia sp.</i>	90%																																																																																																																			
Lagarta não peçonhenta	100%																																																																																																																									
<i>Phobetron sp.</i>	88%																																																																																																																									
<i>Podalia sp.</i>	90%																																																																																																																									
Matriz de Confusão	<p>Matriz de Confusão</p> <table border="1"> <thead> <tr> <th>Verdadeiro \ Predição</th> <th>acharia</th> <th>arctidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao-lagarta</th> <th>nao-peconhenta</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>29</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>arctidae</th> <td>0</td> <td>26</td> <td>0</td> <td>1</td> <td>1</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <th>automeris</th> <td>0</td> <td>0</td> <td>28</td> <td>1</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>0</td> <td>1</td> <td>0</td> <td>28</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>1</td> <td>3</td> <td>2</td> <td>2</td> <td>21</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>0</td> <td>1</td> <td>0</td> <td>1</td> <td>0</td> <td>24</td> <td>0</td> <td>0</td> <td>2</td> <td>2</td> </tr> <tr> <th>nao-lagarta</th> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>29</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>nao-peconhenta</th> <td>1</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>25</td> <td>2</td> <td>0</td> </tr> <tr> <th>phobetron</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>28</td> <td>0</td> </tr> <tr> <th>podalia</th> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>28</td> </tr> </tbody> </table>	Verdadeiro \ Predição	acharia	arctidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia	acharia	29	0	0	0	0	1	0	0	0	0	arctidae	0	26	0	1	1	1	0	0	0	1	automeris	0	0	28	1	0	1	0	0	0	0	hylesia	0	1	0	28	1	0	0	0	0	0	lonomia	1	3	2	2	21	1	0	0	0	0	megalopyge	0	1	0	1	0	24	0	0	2	2	nao-lagarta	0	0	1	0	0	0	29	0	0	0	nao-peconhenta	1	2	0	0	0	0	0	25	2	0	phobetron	0	1	0	0	0	1	0	0	28	0	podalia	0	0	0	0	0	2	0	0	0	28
Verdadeiro \ Predição	acharia	arctidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
acharia	29	0	0	0	0	1	0	0	0	0																																																																																																																
arctidae	0	26	0	1	1	1	0	0	0	1																																																																																																																
automeris	0	0	28	1	0	1	0	0	0	0																																																																																																																
hylesia	0	1	0	28	1	0	0	0	0	0																																																																																																																
lonomia	1	3	2	2	21	1	0	0	0	0																																																																																																																
megalopyge	0	1	0	1	0	24	0	0	2	2																																																																																																																
nao-lagarta	0	0	1	0	0	0	29	0	0	0																																																																																																																
nao-peconhenta	1	2	0	0	0	0	0	25	2	0																																																																																																																
phobetron	0	1	0	0	0	1	0	0	28	0																																																																																																																
podalia	0	0	0	0	0	2	0	0	0	28																																																																																																																
Precisão	89%																																																																																																																									
Recall	89%																																																																																																																									
F1-Score	89%																																																																																																																									

Resultado dos testes com Resnet34

Testes								
Acurácia total	87,33%							
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>100%</td> <td>30</td> </tr> </tbody> </table>		Classe	Acurácia	Amostras	<i>Acharia sp.</i>	100%	30
Classe	Acurácia	Amostras						
<i>Acharia sp.</i>	100%	30						

	<table border="1"> <tbody> <tr> <td><i>Arctiidae sp.</i></td> <td>76%</td> <td>30</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>85%</td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>84%</td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>88%</td> <td>30</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>72%</td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>93%</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>100%</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>96%</td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>87%</td> <td>30</td> </tr> </tbody> </table>	<i>Arctiidae sp.</i>	76%	30	<i>Automeris sp.</i>	85%	30	<i>Hylesia sp.</i>	84%	30	<i>Lonomia obliqua</i>	88%	30	<i>Megalopyge sp.</i>	72%	30	Não lagarta	93%	30	Lagarta não peçonhenta	100%	30	<i>Phobetron sp.</i>	96%	30	<i>Podalia sp.</i>	87%	30																																																																																														
<i>Arctiidae sp.</i>	76%	30																																																																																																																								
<i>Automeris sp.</i>	85%	30																																																																																																																								
<i>Hylesia sp.</i>	84%	30																																																																																																																								
<i>Lonomia obliqua</i>	88%	30																																																																																																																								
<i>Megalopyge sp.</i>	72%	30																																																																																																																								
Não lagarta	93%	30																																																																																																																								
Lagarta não peçonhenta	100%	30																																																																																																																								
<i>Phobetron sp.</i>	96%	30																																																																																																																								
<i>Podalia sp.</i>	87%	30																																																																																																																								
Matriz de Confusão	<p>Matriz de Confusão</p> <table border="1"> <thead> <tr> <th>Verdadeiro \ Predição</th> <th>acharia</th> <th>arctiidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao-lagarta</th> <th>nao-peconhenta</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>30</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>arctiidae</th> <td>0</td> <td>25</td> <td>0</td> <td>2</td> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <th>automeris</th> <td>0</td> <td>0</td> <td>29</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>0</td> <td>1</td> <td>0</td> <td>26</td> <td>3</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>0</td> <td>2</td> <td>3</td> <td>3</td> <td>21</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>26</td> <td>0</td> <td>0</td> <td>0</td> <td>3</td> </tr> <tr> <th>nao-lagarta</th> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> <td>28</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>nao-peconhenta</th> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>2</td> <td>25</td> <td>1</td> <td>0</td> </tr> <tr> <th>phobetron</th> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>26</td> <td>0</td> </tr> <tr> <th>podalia</th> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>3</td> <td>0</td> <td>0</td> <td>0</td> <td>26</td> </tr> </tbody> </table>	Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia	acharia	30	0	0	0	0	0	0	0	0	0	arctiidae	0	25	0	2	0	2	0	0	0	1	automeris	0	0	29	0	0	1	0	0	0	0	hylesia	0	1	0	26	3	0	0	0	0	0	lonomia	0	2	3	3	21	1	0	0	0	0	megalopyge	0	1	0	0	0	26	0	0	0	3	nao-lagarta	0	0	1	0	0	1	28	0	0	0	nao-peconhenta	0	2	0	0	0	0	2	25	1	0	phobetron	0	2	0	0	0	2	0	0	26	0	podalia	0	0	1	0	0	3	0	0	0	26
Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
acharia	30	0	0	0	0	0	0	0	0	0																																																																																																																
arctiidae	0	25	0	2	0	2	0	0	0	1																																																																																																																
automeris	0	0	29	0	0	1	0	0	0	0																																																																																																																
hylesia	0	1	0	26	3	0	0	0	0	0																																																																																																																
lonomia	0	2	3	3	21	1	0	0	0	0																																																																																																																
megalopyge	0	1	0	0	0	26	0	0	0	3																																																																																																																
nao-lagarta	0	0	1	0	0	1	28	0	0	0																																																																																																																
nao-peconhenta	0	2	0	0	0	0	2	25	1	0																																																																																																																
phobetron	0	2	0	0	0	2	0	0	26	0																																																																																																																
podalia	0	0	1	0	0	3	0	0	0	26																																																																																																																
Precisão	88%																																																																																																																									
Recall	87%																																																																																																																									
F1-Score	87%																																																																																																																									

Resultado dos testes com EfficientNetLite

Testes																																																																																																																										
Acurácia total	88%																																																																																																																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>97%</td> <td>30</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>82%</td> <td>30</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>88%</td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>83%</td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>81%</td> <td>30</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>70%</td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>97%</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>96%</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>100%</td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>92%</td> <td>30</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Acharia sp.</i>	97%	30	<i>Arctiidae sp.</i>	82%	30	<i>Automeris sp.</i>	88%	30	<i>Hylesia sp.</i>	83%	30	<i>Lonomia obliqua</i>	81%	30	<i>Megalopyge sp.</i>	70%	30	Não lagarta	97%	30	Lagarta não peçonhenta	96%	30	<i>Phobetron sp.</i>	100%	30	<i>Podalia sp.</i>	92%	30																																																																																								
Classe	Acurácia	Amostras																																																																																																																								
<i>Acharia sp.</i>	97%	30																																																																																																																								
<i>Arctiidae sp.</i>	82%	30																																																																																																																								
<i>Automeris sp.</i>	88%	30																																																																																																																								
<i>Hylesia sp.</i>	83%	30																																																																																																																								
<i>Lonomia obliqua</i>	81%	30																																																																																																																								
<i>Megalopyge sp.</i>	70%	30																																																																																																																								
Não lagarta	97%	30																																																																																																																								
Lagarta não peçonhenta	96%	30																																																																																																																								
<i>Phobetron sp.</i>	100%	30																																																																																																																								
<i>Podalia sp.</i>	92%	30																																																																																																																								
Matriz de Confusão	<p>Matriz de Confusão</p> <table border="1"> <thead> <tr> <th>Verdadeiro \ Predição</th> <th>acharia</th> <th>arctiidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao-lagarta</th> <th>nao-peconhenta</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>30</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>arctiidae</th> <td>0</td> <td>27</td> <td>0</td> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> </tr> <tr> <th>automeris</th> <td>0</td> <td>0</td> <td>28</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>0</td> <td>1</td> <td>0</td> <td>25</td> <td>2</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>1</td> <td>1</td> <td>4</td> <td>3</td> <td>21</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> <td>26</td> <td>0</td> <td>0</td> <td>0</td> <td>2</td> </tr> <tr> <th>nao-lagarta</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>29</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>nao-peconhenta</th> <td>0</td> <td>1</td> <td>0</td> <td>1</td> <td>0</td> <td>3</td> <td>0</td> <td>25</td> <td>0</td> <td>0</td> </tr> <tr> <th>phobetron</th> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>29</td> <td>0</td> </tr> <tr> <th>podalia</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>5</td> <td>0</td> <td>0</td> <td>0</td> <td>24</td> </tr> </tbody> </table>	Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia	acharia	30	0	0	0	0	0	0	0	0	0	arctiidae	0	27	0	0	2	0	0	1	0	0	automeris	0	0	28	1	0	0	1	0	0	0	hylesia	0	1	0	25	2	2	0	0	0	0	lonomia	1	1	4	3	21	0	0	0	0	0	megalopyge	0	1	0	0	1	26	0	0	0	2	nao-lagarta	0	1	0	0	0	0	29	0	0	0	nao-peconhenta	0	1	0	1	0	3	0	25	0	0	phobetron	0	0	0	0	0	1	0	0	29	0	podalia	0	1	0	0	0	5	0	0	0	24
Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
acharia	30	0	0	0	0	0	0	0	0	0																																																																																																																
arctiidae	0	27	0	0	2	0	0	1	0	0																																																																																																																
automeris	0	0	28	1	0	0	1	0	0	0																																																																																																																
hylesia	0	1	0	25	2	2	0	0	0	0																																																																																																																
lonomia	1	1	4	3	21	0	0	0	0	0																																																																																																																
megalopyge	0	1	0	0	1	26	0	0	0	2																																																																																																																
nao-lagarta	0	1	0	0	0	0	29	0	0	0																																																																																																																
nao-peconhenta	0	1	0	1	0	3	0	25	0	0																																																																																																																
phobetron	0	0	0	0	0	1	0	0	29	0																																																																																																																
podalia	0	1	0	0	0	5	0	0	0	24																																																																																																																

Precisão	89%
Recall	88%
F1-Score	88%

Resultado dos testes com EfficientNetB0

Testes																																		
Acurácia total	87,33%																																	
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>94%</td> <td>30</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>79%</td> <td>30</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>85%</td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>84%</td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>91%</td> <td>30</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>74%</td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>94%</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>92%</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>96%</td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>89%</td> <td>30</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Acharia sp.</i>	94%	30	<i>Arctiidae sp.</i>	79%	30	<i>Automeris sp.</i>	85%	30	<i>Hylesia sp.</i>	84%	30	<i>Lonomia obliqua</i>	91%	30	<i>Megalopyge sp.</i>	74%	30	Não lagarta	94%	30	Lagarta não peçonhenta	92%	30	<i>Phobetron sp.</i>	96%	30	<i>Podalia sp.</i>	89%	30
Classe	Acurácia	Amostras																																
<i>Acharia sp.</i>	94%	30																																
<i>Arctiidae sp.</i>	79%	30																																
<i>Automeris sp.</i>	85%	30																																
<i>Hylesia sp.</i>	84%	30																																
<i>Lonomia obliqua</i>	91%	30																																
<i>Megalopyge sp.</i>	74%	30																																
Não lagarta	94%	30																																
Lagarta não peçonhenta	92%	30																																
<i>Phobetron sp.</i>	96%	30																																
<i>Podalia sp.</i>	89%	30																																

Matriz de Confusão																																																																																																																										
	<p>Matriz de Confusão</p> <table border="1"> <thead> <tr> <th>Verdadeiro \ Predição</th> <th>acharia</th> <th>arctiidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao-lagarta</th> <th>nao-peconhenta</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>30</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>arctiidae</th> <td>0</td> <td>27</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>2</td> <td>0</td> <td>0</td> </tr> <tr> <th>automeris</th> <td>0</td> <td>0</td> <td>29</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>0</td> <td>1</td> <td>0</td> <td>26</td> <td>2</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>0</td> <td>2</td> <td>4</td> <td>3</td> <td>20</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>26</td> <td>0</td> <td>0</td> <td>1</td> <td>2</td> </tr> <tr> <th>nao-lagarta</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>29</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>nao-peconhenta</th> <td>1</td> <td>2</td> <td>0</td> <td>1</td> <td>0</td> <td>2</td> <td>0</td> <td>23</td> <td>0</td> <td>1</td> </tr> <tr> <th>phobetron</th> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>1</td> <td>0</td> <td>27</td> <td>0</td> </tr> <tr> <th>podalia</th> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>4</td> <td>0</td> <td>0</td> <td>0</td> <td>25</td> </tr> </tbody> </table>	Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia	acharia	30	0	0	0	0	0	0	0	0	0	arctiidae	0	27	0	0	0	1	0	2	0	0	automeris	0	0	29	1	0	0	0	0	0	0	hylesia	0	1	0	26	2	0	1	0	0	0	lonomia	0	2	4	3	20	1	0	0	0	0	megalopyge	0	1	0	0	0	26	0	0	1	2	nao-lagarta	0	1	0	0	0	0	29	0	0	0	nao-peconhenta	1	2	0	1	0	2	0	23	0	1	phobetron	1	0	0	0	0	1	1	0	27	0	podalia	0	0	1	0	0	4	0	0	0	25
Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
acharia	30	0	0	0	0	0	0	0	0	0																																																																																																																
arctiidae	0	27	0	0	0	1	0	2	0	0																																																																																																																
automeris	0	0	29	1	0	0	0	0	0	0																																																																																																																
hylesia	0	1	0	26	2	0	1	0	0	0																																																																																																																
lonomia	0	2	4	3	20	1	0	0	0	0																																																																																																																
megalopyge	0	1	0	0	0	26	0	0	1	2																																																																																																																
nao-lagarta	0	1	0	0	0	0	29	0	0	0																																																																																																																
nao-peconhenta	1	2	0	1	0	2	0	23	0	1																																																																																																																
phobetron	1	0	0	0	0	1	1	0	27	0																																																																																																																
podalia	0	0	1	0	0	4	0	0	0	25																																																																																																																
Precisão	88%																																																																																																																									
Recall	87%																																																																																																																									
F1-Score	87%																																																																																																																									

Resultado dos testes com MobileNetV3

Testes																			
Acurácia total	84,33%																		
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>88%</td> <td>30</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>66%</td> <td>30</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>81%</td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>84%</td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>83%</td> <td>30</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Acharia sp.</i>	88%	30	<i>Arctiidae sp.</i>	66%	30	<i>Automeris sp.</i>	81%	30	<i>Hylesia sp.</i>	84%	30	<i>Lonomia obliqua</i>	83%	30
Classe	Acurácia	Amostras																	
<i>Acharia sp.</i>	88%	30																	
<i>Arctiidae sp.</i>	66%	30																	
<i>Automeris sp.</i>	81%	30																	
<i>Hylesia sp.</i>	84%	30																	
<i>Lonomia obliqua</i>	83%	30																	

	<table border="1"> <tr> <td><i>Megalopyge sp.</i></td> <td>65%</td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>100%</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>96%</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>100%</td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>93%</td> <td>30</td> </tr> </table>	<i>Megalopyge sp.</i>	65%	30	Não lagarta	100%	30	Lagarta não peçonhenta	96%	30	<i>Phobetron sp.</i>	100%	30	<i>Podalia sp.</i>	93%	30																																																																																																										
<i>Megalopyge sp.</i>	65%	30																																																																																																																								
Não lagarta	100%	30																																																																																																																								
Lagarta não peçonhenta	96%	30																																																																																																																								
<i>Phobetron sp.</i>	100%	30																																																																																																																								
<i>Podalia sp.</i>	93%	30																																																																																																																								
Matriz de Confusão	<p>Matriz de Confusão</p> <table border="1"> <thead> <tr> <th>Verdadeiro \ Predição</th> <th>acharia</th> <th>arctiidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao-lagarta</th> <th>nao-peconhenta</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>29</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>arctiidae</th> <td>1</td> <td>21</td> <td>1</td> <td>2</td> <td>2</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <th>automeris</th> <td>0</td> <td>0</td> <td>29</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>0</td> <td>2</td> <td>0</td> <td>26</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>1</td> <td>2</td> <td>5</td> <td>2</td> <td>20</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>1</td> <td>2</td> <td>0</td> <td>1</td> <td>0</td> <td>24</td> <td>0</td> <td>1</td> <td>0</td> <td>1</td> </tr> <tr> <th>nao-lagarta</th> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>29</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>nao-peconhenta</th> <td>0</td> <td>4</td> <td>1</td> <td>0</td> <td>0</td> <td>2</td> <td>0</td> <td>23</td> <td>0</td> <td>0</td> </tr> <tr> <th>phobetron</th> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>3</td> <td>0</td> <td>0</td> <td>26</td> <td>0</td> </tr> <tr> <th>podalia</th> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>4</td> <td>0</td> <td>0</td> <td>0</td> <td>26</td> </tr> </tbody> </table>	Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia	acharia	29	0	0	0	0	1	0	0	0	0	arctiidae	1	21	1	2	2	2	0	0	0	1	automeris	0	0	29	0	0	1	0	0	0	0	hylesia	0	2	0	26	2	0	0	0	0	0	lonomia	1	2	5	2	20	0	0	0	0	0	megalopyge	1	2	0	1	0	24	0	1	0	1	nao-lagarta	0	1	0	0	0	0	29	0	0	0	nao-peconhenta	0	4	1	0	0	2	0	23	0	0	phobetron	1	0	0	0	0	3	0	0	26	0	podalia	0	0	0	0	0	4	0	0	0	26
Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
acharia	29	0	0	0	0	1	0	0	0	0																																																																																																																
arctiidae	1	21	1	2	2	2	0	0	0	1																																																																																																																
automeris	0	0	29	0	0	1	0	0	0	0																																																																																																																
hylesia	0	2	0	26	2	0	0	0	0	0																																																																																																																
lonomia	1	2	5	2	20	0	0	0	0	0																																																																																																																
megalopyge	1	2	0	1	0	24	0	1	0	1																																																																																																																
nao-lagarta	0	1	0	0	0	0	29	0	0	0																																																																																																																
nao-peconhenta	0	4	1	0	0	2	0	23	0	0																																																																																																																
phobetron	1	0	0	0	0	3	0	0	26	0																																																																																																																
podalia	0	0	0	0	0	4	0	0	0	26																																																																																																																
Precisão	85%																																																																																																																									
Recall	84%																																																																																																																									
F1-Score	84%																																																																																																																									

Resultado dos testes com MobileNetV3 - Google Teachable Machine

Testes

Acurácia total	77,6%																																																																																																																									
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> <th>Amostras</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>90%</td> <td>30</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>73%</td> <td>30</td> </tr> <tr> <td><i>Automeris sp.</i></td> <td>83%</td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>80%</td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>76%</td> <td>30</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>60%</td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>93%</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>67%</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>80%</td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>73%</td> <td>30</td> </tr> </tbody> </table>	Classe	Acurácia	Amostras	<i>Acharia sp.</i>	90%	30	<i>Arctiidae sp.</i>	73%	30	<i>Automeris sp.</i>	83%	30	<i>Hylesia sp.</i>	80%	30	<i>Lonomia obliqua</i>	76%	30	<i>Megalopyge sp.</i>	60%	30	Não lagarta	93%	30	Lagarta não peçonhenta	67%	30	<i>Phobetron sp.</i>	80%	30	<i>Podalia sp.</i>	73%	30																																																																																								
Classe	Acurácia	Amostras																																																																																																																								
<i>Acharia sp.</i>	90%	30																																																																																																																								
<i>Arctiidae sp.</i>	73%	30																																																																																																																								
<i>Automeris sp.</i>	83%	30																																																																																																																								
<i>Hylesia sp.</i>	80%	30																																																																																																																								
<i>Lonomia obliqua</i>	76%	30																																																																																																																								
<i>Megalopyge sp.</i>	60%	30																																																																																																																								
Não lagarta	93%	30																																																																																																																								
Lagarta não peçonhenta	67%	30																																																																																																																								
<i>Phobetron sp.</i>	80%	30																																																																																																																								
<i>Podalia sp.</i>	73%	30																																																																																																																								
Matriz de Confusão	<p style="text-align: center;">Matriz de Confusão</p> <table border="1"> <thead> <tr> <th>Verdadeiro \ Predição</th> <th>acharia</th> <th>arctiidae</th> <th>automeris</th> <th>hylesia</th> <th>lonomia</th> <th>megalopyge</th> <th>nao-lagarta</th> <th>nao-peconhenta</th> <th>phobetron</th> <th>podalia</th> </tr> </thead> <tbody> <tr> <th>acharia</th> <td>27</td> <td>0</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <th>arctiidae</th> <td>0</td> <td>22</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>3</td> <td>0</td> <td>4</td> </tr> <tr> <th>automeris</th> <td>1</td> <td>0</td> <td>25</td> <td>1</td> <td>0</td> <td>0</td> <td>3</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>hylesia</th> <td>1</td> <td>2</td> <td>1</td> <td>24</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>lonomia</th> <td>0</td> <td>1</td> <td>4</td> <td>1</td> <td>23</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> </tr> <tr> <th>megalopyge</th> <td>3</td> <td>2</td> <td>0</td> <td>0</td> <td>0</td> <td>18</td> <td>0</td> <td>1</td> <td>1</td> <td>5</td> </tr> <tr> <th>nao-lagarta</th> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>28</td> <td>1</td> <td>0</td> <td>0</td> </tr> <tr> <th>nao-peconhenta</th> <td>3</td> <td>4</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>20</td> <td>1</td> <td>0</td> </tr> <tr> <th>phobetron</th> <td>3</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>1</td> <td>24</td> <td>0</td> </tr> <tr> <th>podalia</th> <td>1</td> <td>1</td> <td>0</td> <td>1</td> <td>0</td> <td>5</td> <td>0</td> <td>0</td> <td>0</td> <td>22</td> </tr> </tbody> </table>	Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia	acharia	27	0	2	0	0	0	0	0	0	1	arctiidae	0	22	0	0	0	1	0	3	0	4	automeris	1	0	25	1	0	0	3	0	0	0	hylesia	1	2	1	24	2	0	0	0	0	0	lonomia	0	1	4	1	23	0	0	0	1	0	megalopyge	3	2	0	0	0	18	0	1	1	5	nao-lagarta	1	0	0	0	0	0	28	1	0	0	nao-peconhenta	3	4	1	0	0	0	1	20	1	0	phobetron	3	1	0	0	0	1	0	1	24	0	podalia	1	1	0	1	0	5	0	0	0	22
Verdadeiro \ Predição	acharia	arctiidae	automeris	hylesia	lonomia	megalopyge	nao-lagarta	nao-peconhenta	phobetron	podalia																																																																																																																
acharia	27	0	2	0	0	0	0	0	0	1																																																																																																																
arctiidae	0	22	0	0	0	1	0	3	0	4																																																																																																																
automeris	1	0	25	1	0	0	3	0	0	0																																																																																																																
hylesia	1	2	1	24	2	0	0	0	0	0																																																																																																																
lonomia	0	1	4	1	23	0	0	0	1	0																																																																																																																
megalopyge	3	2	0	0	0	18	0	1	1	5																																																																																																																
nao-lagarta	1	0	0	0	0	0	28	1	0	0																																																																																																																
nao-peconhenta	3	4	1	0	0	0	1	20	1	0																																																																																																																
phobetron	3	1	0	0	0	1	0	1	24	0																																																																																																																
podalia	1	1	0	1	0	5	0	0	0	22																																																																																																																

Precisão	78%
Recall	78%
F1-Score	78%

4.3 Discussão

Os resultados da validação dos modelos durante o treinamento estão agregados na Tabela 22. Esta tabela permite visualizar como cada modelo aprendeu a identificar o conjunto de imagens durante o treinamento. Na tabela foram incluídas as métricas: Acurácia; Precisão; *Recall*; *F1-Score*. Por meio destas medidas é possível realizar uma análise aprofundada do desempenho dos modelos. Para esta validação, 10% do conjunto de treinamento foi separado aleatoriamente e usado para validação.

Tabela 22. Resultado dos treinamentos dos modelos.

Resultados da validação de desempenho	Acurácia total	Precisão	Recall	F1-Score
Resnet18	94%	94%	94%	94%
Resnet34	95%	95%	95%	95%
EfficientNetLite	95%	95%	95%	95%
EfficientNetB0	96%	96%	96%	96%
MobileNetV3	95%	95%	95%	95%
MobileNetV3 - Google	80%	80%	80%	80%

Teachable Machine				
--------------------------	--	--	--	--

Os modelos na Tabela 22, na sua maioria, atingem acurácia de 95%. Além disso, observando os valores de *recall* e *F1-Score*, conclui-se que os modelos em geral conseguem evitar falsos negativos. Em termos práticos, estas métricas indicam que os modelos conseguem distinguir diferentes espécies de lagartas, com poucos casos de confusão para o conjunto de imagens de validação.

Na Tabela 23 estão detalhadas as mesmas métricas, desta vez aplicadas para o conjunto de testes. O conjunto de imagens de teste consiste de 30 imagens por classe, totalizando 300 imagens.

Tabela 23. Resultado dos testes de desempenho dos modelos.

Resultados da validação de desempenho	Acurácia total	Precisão	Recall	F1-Score
Resnet18	89%	89%	89%	89%
Resnet34	87%	88%	87%	87%
EfficientNetLite	88%	89%	88%	88%
EfficientNetB0	87%	88%	87%	87%
MobileNetV3	84%	85%	84%	84%
MobileNetV3-Google Teachable Machine	78%	78%	78%	78%

Observa-se que no conjunto de testes os modelos ainda mantêm uma proporção de aproximadamente 1:1 de precisão e *recall* (Tabela 23). No entanto, os modelos não atingem a acurácia de 95% no conjunto de teste, e as outras medidas também são reduzidas em uma proporção semelhante. Os modelos com melhor desempenho nos testes foram Resnet18 e EfficientNetLite.

Estes resultados são significativos pois os modelos utilizados priorizam desempenho em dispositivos móveis, e lidam com um conjunto de dados variado que pode ser de difícil identificação até para um especialista na área. Comparando com outros trabalhos que identificam lagartas a acurácia não atinge o mesmo nível atingido por *Tiwari et al.* (2021). No entanto, o escopo daquele estudo abrange 4 classes de diferentes espécies de insetos, enquanto neste estudo há 9 classes de espécies de lagartas, com uma classe para abstrair fotos que não apresentam uma lagarta.

Outro aspecto a ser considerado ao avaliar os resultados obtidos é o tratamento de *overfitting*. Durante o treinamento não foram usadas técnicas de mitigação de para tal, como validação cruzada. Também não foram usados ajustes de hiperparâmetro. Comparando os resultados de acurácia do treinamento e do teste, percebe-se que houve uma queda grande de acurácia, indicando ocorrência de *overfitting*.

Os modelos apresentaram resultados promissores durante o treinamento, mas os testes de desempenho demonstraram que ainda é necessária cautela se estes forem aplicados em cenários reais, pois uma classificação incorreta pode oferecer alto risco para os usuários. Em especial, observando as matrizes de confusão dos testes para a identificação de *Lonomia obliqua*, houveram múltiplos casos onde um espécime desta lagarta foi identificado como uma lagarta de outra espécie, algo que ocorreu com pouquíssima frequência durante o treinamento. Este erro de classificação em particular coloca um potencial usuário em risco direto, pois não comunica corretamente a severidade do risco em caso de contato com esta lagarta.

Ameaças à validade

Existem ameaças à validade em relação aos resultados obtidos que devem ser consideradas. A não utilização de técnicas para mitigação de *overfitting* é a principal ameaça à validade. Se tivessem sido aplicadas técnicas como validação cruzada e ajuste de hiperparâmetro, resultados melhores poderiam ser obtidos.

Com relação ao viés de seleção, procurou-se criar uma amostra representativa de diferentes casos reais, com diferentes distâncias, condições de iluminação e variedade de espécimes. No entanto, existe a possibilidade do conjunto de dados pode não ser completamente abrangente, impedindo a generalização para todos os casos possíveis. Além disso, o tamanho da amostra pode ser insuficiente, uma vez que a quantidade de imagens encontradas para algumas espécies foi pequena para este tipo de tarefa de classificação. Ainda em relação ao tamanho da amostra, outra ameaça que se apresenta é o viés criado pelo pós-processamento de dados, que quando utilizado em um conjunto de dados muito pequeno gera um modelo capaz apenas de identificar variações de um conjunto pequeno de imagens. Este viés foi mitigado separando imagens de teste antes da aplicação do pós-processamento, impedindo que variações de uma mesma imagem estejam presentes nos conjuntos de treino e teste ao mesmo tempo. Finalmente, é necessário considerar o viés gerado pelas métricas de avaliação, mitigado pelo uso de diversas métricas para avaliar diferentes características do desempenho do modelo. Contudo, as métricas em si possuem limitações que devem ser consideradas para avaliar criticamente os resultados obtidos.


4.4 Implementação de aplicativo móvel

A implementação em aplicativo móvel foi feita usando o *MIT App Inventor* (2023), para fazer uso de sua integração com *Teachable Machine* e velocidade para criação de um protótipo funcional. O modelo *Teachable Machine* foi escolhido pois não foram identificadas ferramentas para integração dos outros modelos com o *MIT App Inventor*

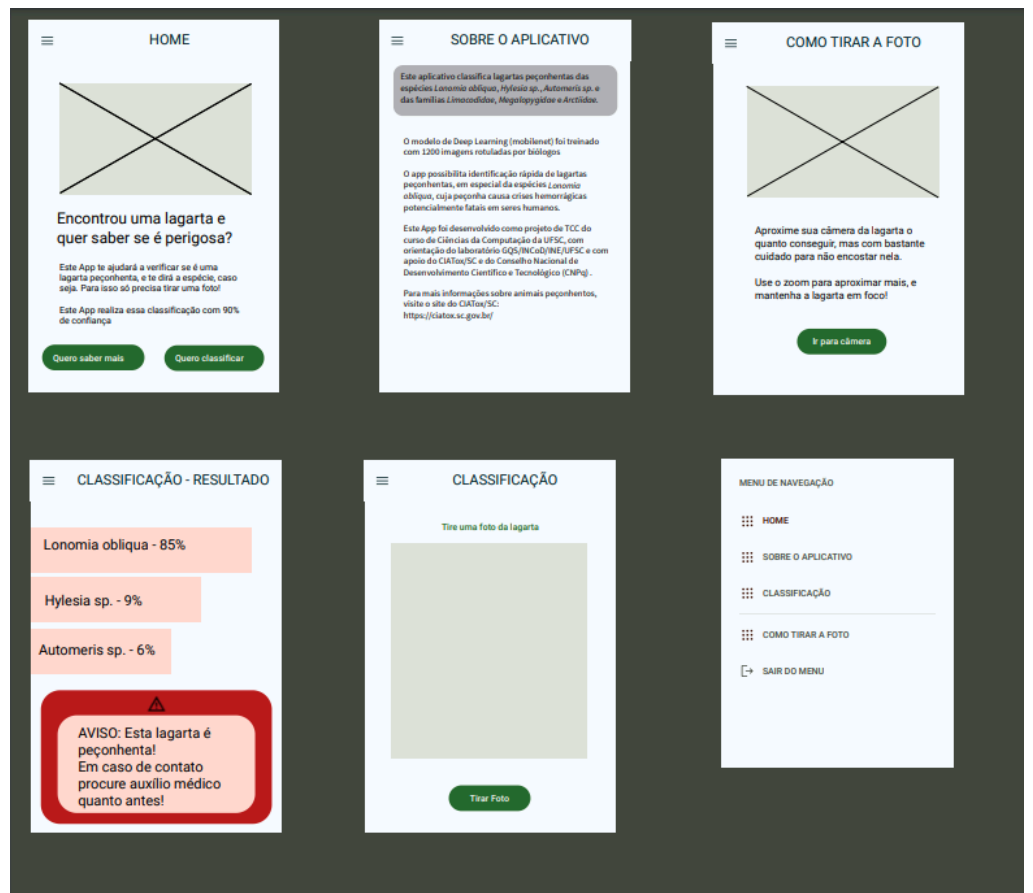
O design de interface foi desenvolvido de forma iterativa, inicialmente em forma de rascunhos feitos à mão, que depois foram adaptados para *wireframes* de baixa fidelidade. A partir dos *wireframes* foi criado um protótipo de *design* visual do aplicativo.

Tabela 24. Iterações de Interface do App.

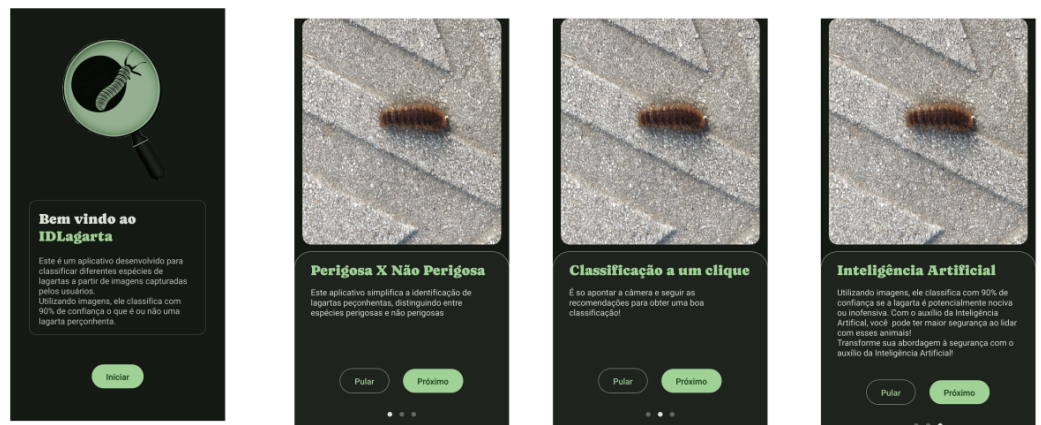
Sketch 1



Wireframe



Protótipo de design visual





A partir do *design* visual foi criado o protótipo do aplicativo no app inventor. Para criar componentes de tela compatíveis com a identidade visual proposta foram usadas extensões criadas pela comunidade de usuários da plataforma. As extensões usadas para elementos visuais foram: *AI2 Sidebar*, para criar abas de navegação laterais; *Custom Sheet* para diálogos estilo *pop-up*; *Infinite Progress Bars* para indicadores de progresso do processamento do modelo de *Deep Learning*.

Para possibilitar a integração de um modelo de classificação de imagens no MIT App Inventor, foi usada a extensão Teachable Machine Image Classifier (Oliveira, 2022). Esta extensão permite anexar um link de um modelo gerado pelo Google Teachable Machine à interface do aplicativo, e classificar imagens da câmera do dispositivo celular com o modelo anexado.

O comportamento do aplicativo foi programado com a ferramenta de blocos do *App Inventor*, de forma que futuras iterações deste aplicativo ou de similares possam ser de fácil implementação, mesmo para pesquisadores não familiarizados com desenvolvimento de aplicativos para dispositivos *Android*.

O projeto do protótipo de aplicativo no formato *.aia* está disponível publicamente sob a licença *Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International* (CC BY-NC-SA 4.0). Sob esta licença o projeto pode ser modificado e distribuído livremente para fins não comerciais. O acesso ao projeto é feito a partir do *link*:

<https://github.com/MatheusFBBueno/TCC-IDLagarta>

Figura 22. Recorte de implementação em blocos no *App Inventor*.

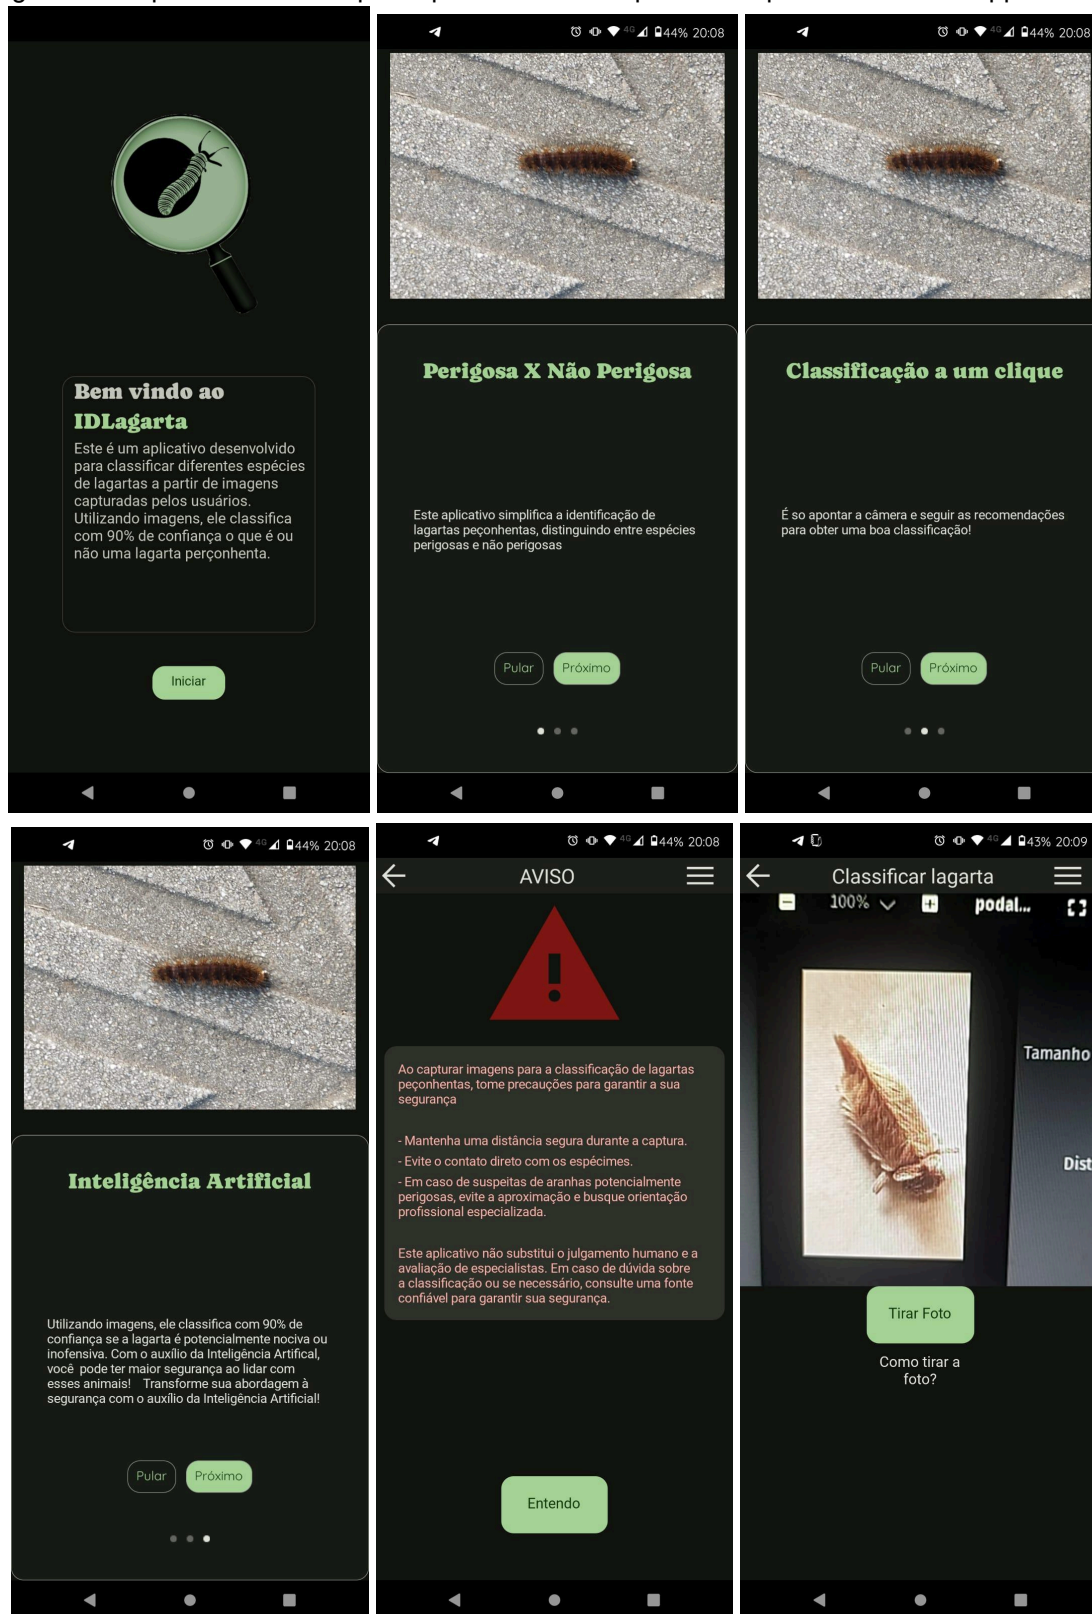
```

quando TeachableMachinelImageClassifier1 .GotClassification
  resultado
  fazer
    ajustar Orgloading . Visível para falso
    chamar TeachableMachinelImageClassifier1 .StopWebcam
    for each key with value in dictionary obter resultado
    do
      se
        obter value > obter global maiorconf
        então
          ajustar global maiorconf para obter value
          ajustar global especiidentificada para obter key
    chamar report

para report
  fazer
    ajustar OrgCamera . Visível para verdadeiro
    se
      obter global especiidentificada = " nao lagarta "
      então
        ajustar orgNaoLagarta . Visível para verdadeiro
        chamar CustomSheet1 .Show
          id 1
      senão, se
        obter global especiidentificada = " nao peçonhen..."
        então
          ajustar orgNaoPerigosa . Visível para verdadeiro
          chamar CustomSheet1 .Show
            id 2
      senão, se
        obter global especiidentificada = " lonomia "
        então
          ajustar orglonomia . Visível para verdadeiro
          chamar CustomSheet1 .Show
            id 3
      senão
        ajustar orgperigosa . Visível para verdadeiro
        chamar CustomSheet1 .Show
          id 4
  
```

Fonte: Elaborado pelo autor.

Figura 23. Capturas de tela de protótipo funcional de aplicativo implementado com App Inventor



Fonte: Elaborado por autor

5. Conclusão

Por meio de uma fundamentação teórica sobre lagartas peçonhentas de Santa Catarina (O1), e o estado da arte de identificação de lagartas utilizando Deep Learning (O2), foram estabelecidas fases para o desenvolvimento do estudo. Com relação ao objetivo específico 3, foram desenvolvidos modelos de classificação de lagartas peçonhentas de Santa Catarina a partir de um conjunto de imagens de lagartas encontradas em campo. Apesar do bom desempenho durante a validação, os melhores resultados de teste foram com os modelos Resnet18 e EfficientNetLite, com 89% e 88% de acurácia respectivamente, e ambos abaixo do objetivo de 95%. Este resultado indica que os modelos necessitam de melhorias para alcançar acurácias maiores. Ademais, com relação ao objetivo específico O4, um aplicativo para Android foi criado utilizando o MIT App Inventor, com um modelo de Machine Learning implantado.

Contudo, dado a quantidade limitada de estudo da aplicação de *Machine Learning* para identificação de lagartas peçonhentas, este estudo estabelece precedente para futuros estudos. Os resultados deste trabalho demonstram que é possível alavancar arquiteturas de Machine Learning e dados disponibilizados pela comunidade científica para gerar uma ferramenta que pode informar a população em geral sobre os perigos de lagartas peçonhentas, e direcionar usuários a procurar atendimento emergencial o quanto antes, potencialmente reduzindo o tempo de busca ao atendimento médico, quando este é necessário, e assim diminuindo os riscos de gravidade no contato com esses agentes. Porém, com os resultados deste trabalho ainda não foram atingidos os níveis de acurácia necessária para que uma ferramenta deste tipo possa ser seguramente disponibilizada para o público em geral, tendo em vista os perigos relacionados à uma classificação incorreta.

Este campo de estudo possui oportunidades de pesquisas futuras com grande potencial para a utilidade pública, principalmente direcionadas à melhoria dos modelos, para que estes alcancem níveis aceitáveis de acurácia. A acurácia dos modelos pode ser melhorada por meio de agregação de mais observações com

fotografias de espécies de lagartas peçonhentas de Santa Catarina. Ferramentas para integração de mais modelos em aplicativos móveis com App Inventor possibilitam que pesquisadores das ciências biológicas e até mesmo a população em geral possam criar aplicativos semelhantes com desempenhos melhores, mesmo com conhecimento mínimo de código. Com estas melhorias e avanços futuros, espera-se que o conhecimento sobre lagartas peçonhentas possa ser disseminado, e que a população em geral tenha mais ferramentas para garantir sua segurança ao lidar com a crescente quantidade de acidentes com estes animais em decorrência da mudança de habitat dos mesmos.

Referências

Affonso, C. *et al.* **Deep learning for biological image classification**, 2017. *Expert systems with applications*, 85, 114-122.

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

Azevedo, B. R. M.; & de Almeida, Z. D. S. **Percepção ambiental e proposta didática sobre a desmistificação de animais peçonhentos e venenosos para os alunos do ensino médio**, 2017. *Acta Tecnológica*, 12(1), 97-108.

Baştanlar, Y.; Özuysal, M. (2014). **Introduction to Machine Learning**, 2014. *miRNomics: MicroRNA Biology and Computational Analysis*. *Methods in Molecular Biology*, vol 1107. Humana Press, Totowa, NJ.

Cardoso, A. E. C.; & Haddad D Junior, V. **Acidentes por lepidópteros (larvas e adultos de mariposas): estudo dos aspectos epidemiológicos, clínicos e terapêuticos**, 2005. *Anais Brasileiros de Dermatologia*, 80(6), 571–578.

Cordeiro A. M. *et al.*, **Revisão sistemática: uma revisão narrativa**, 2007. *Revista do Colégio Brasileiro de Cirurgiões*, 34(6).

Chen *et al.*, **Agricultural Pests Damage Detection Using Deep Learning**, 2019. *Advances in Intelligent Systems and Computing*, vol 1036.

CIATOX/SC, **Centro de Informação e Assistência Toxicológica de Santa Catarina: Relatório Anual 2021**, 2022. Disponível em : <https://repositorio.ufsc.br/handle/123456789/238378> . Acesso em março de 2023.

CIATOX/SC, **Centro de Informação e Assistência Toxicológica de Santa Catarina: Lagartas peçonhentas**, 2023. Disponível em <https://ciatox.sc.gov.br/index.php/servicos/agentes-toxicos/animais-peconhentos/lagartas.html> . Acesso em março de 2023

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: Setembro de 2023.

DIVE. **Acidentes, incidências e óbitos por lagartas, por regiões de saúde, SC, 2011-2021**. Disponível em : <https://dive.sc.gov.br/phocadownload/doencas-agrivos/Animais%20pe%C3%A7onhetos/Boletins/Acidentes-l-Obitos-Lagartas-2011-2021.pdf>>

Elngar, A. A. *et al.* **Image classification based on CNN: a survey**, 2021. Journal of Cybersecurity and Information Management, 6(1), 18-50.

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 Setembro de 2023

Ferro, V. G. *et al.* **Mariposas Arctiinae (Lepidoptera: Erebidae) do estado de Santa Catarina, Brasil**, 2012. Biota Neotropica, v. 12, n. 4, p. 166–180.

Gamborgi, G. P. *et al* **Influência dos fatores abióticos sobre casos de acidentes provocados por Lonomia oblíqua**, 2012. Hygeia: Revista Brasileira de Geografia Médica e da Saúde, 8(14).

Google. **Higher Accuracy on Vision Models with EfficientNet-Lite**, 2020.

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

Gresse von Wangenheim, C.; Von Wangenheim, A. **Visão geral de um processo interativo centrado no ser humano para ensinar aprendizado de máquina no ensino fundamental e médio**, 2021. Disponível em

<<http://www.gqs.ufsc.br/files/2020/02/GQSTemplate-RelatorioTecnico-HumanCentricProcess-v10.pdf>>

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

Haddaway, N.R. *et al.* (2015). **The role of Google Scholar in evidence reviews and its applicability to grey literature searching**, 2015. PloS one, 10.9.

Helm, J.M. *et al.*, **Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions**, 2020. Curr Rev Musculoskelet Med 13, 69–76.

Howard, A. G. *et al.* **Mobilenets: Efficient convolutional neural networks for mobile vision applications**, 2017. arXiv preprint arXiv:1704.04861.

IBM. **What are neural networks?**, 2020. Disponível em: <https://www.ibm.com/cloud/learn/neural-networks> Acesso em setembro de 2023

INATURALIST. **Seek by INaturalist.** Disponível em : https://www.inaturalist.org/pages/seek_app Acesso em março de 2023

iNaturalist, Contribuidores de iNaturalist (2024). **iNaturalist Research-grade Observations**, 2024. Disponível em <https://doi.org/10.15468/ab3s5x>. Acesso em março de 2024.

Kaiming He et al., **Deep Residual Learning for Image Recognition**, 2015. arXiv preprint arXiv:1512.03385.

Khan, R. *et al.* **Harmful Insect Detection Using Deep Learning**, 2021. ResearchGate preprint. Disponível em https://www.researchgate.net/publication/348659953_Harmful_Insect_Detection_Using_Deep_Learning. Acesso em março de 2023

Kierski, M. **Machine Learning development process - you've got it wrong**, 2017. Disponível em: <https://medium.com/sigmoidal/machine-learning-development-process-youve-got-it-wrong-396270e653f4> Acesso em abril de 2023.

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

Lepesqueur, C. **Megalopygidae (Lepidoptera, Zygaenoidea): biologia, diversidade e biogeografia**, 2012. (Doutorado) Universidade de Brasília, Brasília.

Lisete M, L.; Corseuil, E. **Aspectos morfológicos de Lonomia obliqua walker (Lepidoptera: Saturniidae)**, 2001. *Neotropical Entomology*, v. 30, p. 373-379, 2001.

MIT **App Inventor**, disponível em: <https://appinventor.mit.edu/> Acesso e uso em maio de 2024.

Garcia, C.M. **Analytical Test On The Environmental Constraints Related To Accidents With The Lonomia Obliqua Walker 1855, In Southern Brazil**, 2013. *Journal of Ecosystem & Ecography*. 03.

Oliveira, F. P. **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, Florianópolis, Brasil.

Orlandin *et al.* **Borboletas e mariposas de Santa Catarina: uma introdução**. 1. ed, 2016. Campos Novos: edição Mario Arthur Favretto.

O'Shea, K.; Nash, R. **An introduction to convolutional neural networks**, 2015. arXiv preprint arXiv:1511.08458.

Pacheco, C.A.R.; Pereira, N.S. **Deep Learning: Conceitos e Utilização nas Diversas Áreas do Conhecimento**, 2018. Graduação em Computação. Trabalho de Conclusão de Curso (Engenharia de Computação). Universidade Evangélica de Goiás.

Pereira *et al.* **Biological and morphological characteristics of hylesia paulex (Lepidoptera: Saturniidae) fed with eucalyptus urophylla (Myrtaceae)**, 2009. INCI, Caracas, v. 34, n. 9, p. 645-649.

Petersen, *et al.* **Systematic Mapping Studies in Software Engineering**, 2008. Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering. Itália.

Polyzotis *et al.* **Data Management Challenges in Production Machine Learning**, 2017. Proceedings of the ACM International Conference on Management of Data, Chicago, IL, USA, p. 1723 – 1726.

Sagar *et al.* **Identification of Indian butterflies and moths with deep convolutional neural networks**, 2020. *CURRENT SCIENCE*, 118(9), 1456

Shafiq, M.; Gu, Z. **Deep Residual Learning for Image Recognition: A Survey**, 2022. *Applied Sciences*, 12, 8972.

Simonyan, K.; Zisserman, A. **Very deep convolutional networks for large-scale image recognition**, 2014. arXiv preprint arXiv:1409.1556.

Specht, *et al.* **Biologia de Hylesia nigricans (Berg) (Lepidoptera, Saturniidae, Hemileucinae)**, 2006. *Revista Brasileira de Zoologia*, v. 23, n. 1, p. 248–255.

Specht *et al.* **Biologia e aspectos morfológicos dos estágios imaturos de Automeris naranja Schaus (Lepidoptera, Saturniidae, Hemileucinae)**, 2007. *Revista Brasileira de Zoologia*, v. 24, n. 3, p. 523–534.

Specht *et al.* **Biologia de Automeris illustris (Walker) (Lepidoptera, Saturniidae, Hemileucinae)**, 2006. *Revista Brasileira de Zoologia*, v. 23, n. 2, p. 537–546.

Suárez *et al.* **Pest detection and classification to reduce pesticide use in fruit crops based on deep neural networks and image processing**, 2021. Proc. of the XIX Workshop on Information Processing and Control, SAN JUAN, Argentina.

Szegedy *et al.* **Going deeper with convolutions**, 2015. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. Boston, EUA.

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 Setembro de 2022.

Tiwari, V. *et al.* **Real-Time Soybean Crop Insect Classification Using Customized Deep Learning Models**, 2021. Sharma, N., Chakrabarti, A., Balas, V.E., Bruckstein, A.M. (eds) *Data Management, Analytics and Innovation. Lecture Notes on Data Engineering and Communications Technologies*, vol 70.

Weiss *et al.* **A survey of transfer learning**, 2016. *J Big Data* 3, 9.

Xin *et al.* **Fine-grained butterfly classification in ecological images using squeeze-and-excitation and spatial attention modules**, 2020. *Applied Sciences*, 10(5), 1681.

Zhu *et al.* **Hybrid Deep Learning for automated lepidopteran insect image classification**, 2017. *Oriental Insects*, 51(2), 79-9

Desenvolvimento de um modelo de classificação de imagens de lagartas peçonhentas usando deep learning

Matheus Felipe Bertonceli Bueno, Christiane Gresse von Wangenheim

Departamento de Informática e Estatística, Universidade
Federal de Santa Catarina,

Florianópolis, SC, Brasil

`matheus.felipe.bueno@grad.ufsc.br, c.wangenheim@ufsc.br`

Abstract. Many accidents involving venomous animals occur in Santa Catarina. Among these, a significant portion is caused by caterpillars. Therefore, in cases of accidents with caterpillars, or even beforehand upon encountering them, it is of fundamental importance to identify the species with which the victim has come into contact, due to the specific danger associated with caterpillars of the genus *Lonomia*. Given the importance of classifying venomous caterpillars in Santa Catarina within the context of public health, a possible and significant contribution would be the development of an intelligent mobile application that allows automated classification focused on venomous caterpillars found in SC. Thus, the overall objective of this work is to develop and compare image classification models dedicated to identifying venomous caterpillars of Santa Catarina. Deep Learning techniques are employed to automate the classification from photos of caterpillars taken with a mobile phone camera. The developed model was implemented in a prototype mobile application using App Inventor.

Resumo. Acontecem muitos acidentes com animais peçonhentos em Santa Catarina. Entre estes uma parcela considerável é causada por lagartas. Consequentemente, em casos de acidentes com lagartas ou mesmo antes no encontro com estes, é de fundamental importância identificar a espécie com a qual a vítima entrou em contato, em virtude do perigo associado especificamente com as lagartas do gênero *Lonomia*. Tendo em vista a importância dessa classificação de lagartas peçonhentas em Santa Catarina no contexto da saúde pública, uma possível e importante contribuição seria a criação de um aplicativo móvel inteligente que permite a classificação automatizada voltado ao escopo de lagartas peçonhentas de SC. Assim, o objetivo geral deste trabalho é desenvolver e comparar modelos de classificação de imagens dedicados à identificação de lagartas peçonhentas de Santa Catarina. São adotadas técnicas de Deep Learning para automatizar a classificação a partir de fotos de lagartas criadas com a câmera do celular. O modelo desenvolvido foi implantado em um protótipo de aplicativo móvel usando App Inventor.

Introdução



Acontecem muitos acidentes com animais peçonhentos em Santa Catarina. Entre estes uma parcela considerável é causada por lagartas. Estas lagartas são consideradas peçonhentas pois produzem e inoculam toxinas por meio de estruturas dedicadas. Diferentemente de animais venenosos, que secretam as toxinas produzidas (Azevedo & Almeida, 2017). Acidentes causados por contato com lagartas são comuns, constituindo 38% dos acidentes com animais peçonhentos ou venenosos na população entre 0 e 14 anos, e 16,62% dos acidentes com animais peçonhentos ou venenosos na população de 15 ou mais anos de idade em Santa Catarina em 2021 (CIATOX/SC, 2022)(DIVE,2021). Estes acidentes acontecem especialmente em regiões rurais, onde são consideradas um risco ocupacional. Mas também ocorrem em áreas urbanas, onde comumente os insetos podem ser encontrados em árvores frutíferas próximas às residências (Gamborgi et al., 2012).

Lagartas são insetos em fase larval de espécies de insetos da ordem Lepidoptera, que engloba borboletas e mariposas. A identificação das formas imaturas de Lepidópteros tem relevada importância na área da entomologia médica, visto que algumas destas espécies possuem peçonha em sua fase larval, e possuem cerdas urticantes que inoculam toxinas e funcionam como mecanismo de defesa contra predadores, podendo causar acidentes com humanos (Gamborgi et al., 2012).

Em casos de contato com lagartas urticantes, o tratamento é sintomático, focado em aliviar os sintomas causados pela peçonha (Gamborgi et al., 2012). Acidentes com lagartas do gênero *Lonomia* apresentam casos mais graves, pois a peçonha destas lagartas pode causar alterações na coagulação sanguínea e síndrome hemorrágica importante, potencialmente grave com risco de óbito, se não tratado. Por este motivo, o tratamento para acidentes com lagartas do gênero *Lonomia* necessitam da aplicação do soro antilonômico, produzido no Brasil pelo Instituto Butantan (Gamborgi et al., 2012).

Conseqüentemente, em casos de acidentes com lagartas, é de fundamental importância identificar a espécie com a qual a vítima entrou em contato, em virtude do perigo associado especificamente com as lagartas do gênero *Lonomia*. Para a identificação podem ser utilizadas as principais características morfológicas das lagartas incluindo a coloração, formato e densidade das cerdas. Por exemplo, as lagartas do gênero *Lonomia* possuem cerdas esverdeadas e em forma de pinheiros (Gamborgi et al., 2012)(CIATOX/SC, 2023). A Tabela 1 apresenta alguns exemplos de lagartas peçonhentas que habitam a região de Santa Catarina, destacando algumas características morfológicas que as diferenciam (CIATOX/SC, 2023).

Tabela 1. Exemplos espécies de lagartas peçonhentas de Santa Catarina (CIATox/SC, 2023)

			
<i>Lonomia obliqua</i>	<i>Hylesia sp</i>	<i>Podalia sp</i>	<i>Automeris sp</i>

No entanto, para a população em geral, pode ser difícil diferenciar as lagartas do gênero *Lonomia* das demais espécies e assim até correr riscos de danos de saúde grave, inclusive morte, caso não procurar e/ou não receber atendimento médico adequado imediatamente por não saber dos perigos associados ao contato.

Tendo em vista a importância dessa classificação de lagartas peçonhentas em Santa Catarina no contexto da saúde pública, uma possível solução seria a criação de um aplicativo móvel inteligente que permite a classificação automatizada. Essa solução pode ser criada utilizando Deep Learning (DL) Implantando o modelo de DL treinado em um aplicativo móvel que possibilita a classificação de espécies de lagartas por meio de uma fotografia da lagarta feita com a câmera do celular do próprio cidadão. Como resultado pode ser apresentada a espécie da lagarta, levantando um alerta caso haja risco de complicação de saúde grave caso o usuário faça contato com o inseto. Desta forma a identificação se tornaria fácil e acessível, sem necessidade de conhecimento prévio da morfologia das lagartas por parte do cidadão, e mesmo que este não conheça os riscos envolvidos em caso de acidente pode ser alertado e se encaminhar para um centro de atendimento de forma apropriada prevenindo maiores riscos a sua saúde.

Atualmente já existem alguns aplicativos para classificação de animais e plantas em geral, como o Seek da iNaturalist (INATURALIST, 2023), que utiliza uma base de dados com contribuições da comunidade de usuários para identificar espécies de animais, plantas e fungos. Existe também pesquisa voltada à criação de modelos de classificação de mariposas adultas (Zhu et al., 2017). Porém, não foi encontrado nenhum aplicativo atualmente voltado ao escopo de classificação de lagartas peçonhentas em SC.

Assim o objetivo do presente estudo é identificar se é possível o desenvolvimento de um aplicativo móvel inteligente que consegue de forma fácil classificar lagartas peçonhentas de SC por meio de fotos com um grau de precisão de no mínimo 95%.

Desenvolvimento do conjunto de imagens

Com base no escopo definido na análise de requisitos, o conjunto de imagens de treino foi criado a partir do conjunto de imagens iNaturalist Research-grade Observations (iNaturalist e contribuidores, 2024). Este conjunto de imagens agrega observações de usuários da plataforma iNaturalist, e contém um largo conjunto de espécies de seres vivos. Cada observação possui pelo menos uma foto, uma data e a localização da observação. O conjunto é rotulado com base no consenso dos usuários da plataforma quanto às espécies observadas. A partir do conjunto de imagens do iNaturalist, foram filtradas observações correspondentes às espécies que ocorrem no estado de Santa Catarina.

Também foram adicionadas imagens disponibilizadas e rotuladas pelo CIATOX/SC, assim como fotos tiradas por voluntários. Para a classe Não Lagarta, foram utilizadas fotos disponibilizadas pela iniciativa Computação na Escola/INCoD/INE/UFSC. Em total, o dataset totalizou 6001 imagens, divididas entre as seguintes classes:

Tabela 2. Conjunto de imagens coletadas.

Classe	Quantidade de imagens
Não Lagarta	640
Lagarta não peçonhenta	820
Lonomia sp.	124
Hylesia sp.	556
Acharia sp.	645
Automeris sp.	736
Megalopyge sp.	691
Podalia sp.	817

Phobetron sp.	355
Arctiidae sp.	617

Antes do treinamento, foi realizado um pré-processamento das imagens do conjunto de dados. Foram aplicadas transformações nas imagens para aumentar o tamanho do dataset. A partir das imagens originais, foram feitas novas imagens usando rotações, espelhamentos verticais, espelhamentos horizontais e distorções de perspectiva para gerar um novo dataset. As transformações de imagens foram aplicadas de forma aleatória, com valores fixos definindo a probabilidade de uma transformação ser aplicada seguindo a Tabela 3.

Tabela 3. Conjunto de imagens ampliado.

Transformação	Probabilidade
Rotação aleatória de 90 até 270 graus	70%
Espelhamento vertical	70%
Espelhamento horizontal	40%
Distorção de perspectiva	80%

As características do novo conjunto de imagens resultantes são apresentadas na Tabela 4.

Tabela 4. Conjunto de imagens ampliado.

Classe	Quantidade de imagens
Não Lagarta	1.500
Lagarta não peçonhenta	1.500
Lonomia sp.	1.500
Hylesia sp.	1.500
Acharia sp.	1.500

Automeris sp.	1.500
Megalopyge sp.	1.500
Podalia sp.	1.500
Phobetron sp.	1.500
Arctiidae sp.	1.500
Total de imagens	15.000

Treinamento dos modelos

Para o treinamento, foram selecionadas redes neurais com portabilidade para dispositivos móveis. Além disso, foram priorizadas redes neurais com baixo consumo de memória e com alto desempenho, pois o objetivo final é implantá-las em um aplicativo móvel. Dado estes critérios, foram selecionadas as seguintes redes: Resnet18; Resnet34; EfficientNetLite; EfficientNetB0; MobileNetV3 e Google Teachable Machine. Todos os treinamentos foram realizados em um ambiente Jupyter Notebook, com exceção do Teachable Machine, que foi treinado no ambiente web próprio da ferramenta.

Tabela 5. Resultados de desempenho no treinamento

Resultados da validação de desempenho	Acurácia total	Precisão	Recall	F1-Score
Resnet18	94%	94%	94%	94%
Resnet34	95%	95%	95%	95%

EfficientNetLite	95%	95%	95%	95%
EfficientNetB0	96%	96%	96%	96%
MobileNetV3	95%	95%	95%	95%
MobileNetV3 - Google Teachable Machine	80%	80%	80%	80%

Testes de desempenho

Os testes dos modelos treinados foram realizados por predição de imagens novas não utilizadas para o treinamento ou validação, em concordância com a norma ISO/IEC 4213 (2022).

Preparação do teste

O conjunto de teste contém 300 imagens no total, com as características qualitativas dos dados descrita na Tabela 6.

Tabela 6. Características do conjunto de dados de teste

Característica	Especificação							
Número total de imagens no conjunto de testes	300 imagens							
Distribuição do conjunto de imagens	<table border="1"> <thead> <tr> <th>Classe</th> <th>Número de imagens</th> </tr> </thead> <tbody> <tr> <td><i>Acharia sp.</i></td> <td>30</td> </tr> <tr> <td><i>Arctiidae sp.</i></td> <td>30</td> </tr> </tbody> </table>		Classe	Número de imagens	<i>Acharia sp.</i>	30	<i>Arctiidae sp.</i>	30
	Classe	Número de imagens						
	<i>Acharia sp.</i>	30						
	<i>Arctiidae sp.</i>	30						

	<table border="1"> <tbody> <tr> <td><i>Automeris sp.</i></td> <td>30</td> </tr> <tr> <td><i>Hylesia sp.</i></td> <td>30</td> </tr> <tr> <td><i>Lonomia obliqua</i></td> <td>30</td> </tr> <tr> <td><i>Megalopyge sp.</i></td> <td>30</td> </tr> <tr> <td>Não lagarta</td> <td>30</td> </tr> <tr> <td>Lagarta não peçonhenta</td> <td>30</td> </tr> <tr> <td><i>Phobetron sp.</i></td> <td>30</td> </tr> <tr> <td><i>Podalia sp.</i></td> <td>30</td> </tr> </tbody> </table>	<i>Automeris sp.</i>	30	<i>Hylesia sp.</i>	30	<i>Lonomia obliqua</i>	30	<i>Megalopyge sp.</i>	30	Não lagarta	30	Lagarta não peçonhenta	30	<i>Phobetron sp.</i>	30	<i>Podalia sp.</i>	30
<i>Automeris sp.</i>	30																
<i>Hylesia sp.</i>	30																
<i>Lonomia obliqua</i>	30																
<i>Megalopyge sp.</i>	30																
Não lagarta	30																
Lagarta não peçonhenta	30																
<i>Phobetron sp.</i>	30																
<i>Podalia sp.</i>	30																
Uso das imagens	Essas imagens não foram usadas para treinamento ou validação dos modelos.																
Fonte	As imagens foram separadas do conjunto de dados de nível de pesquisa do iNaturalist.																
Verdade Fundamental	As imagens foram rotuladas por pesquisadores usuários da plataforma iNaturalist e as rotulações foram confirmadas por pesquisadores da iniciativa Computação na Escola/INCoD/INE/UFSC em colaboração com biólogos do CIATox/SC e LBMM/UFSC																
Pré-processamento	Nenhum pré-processamento 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 no conjunto de teste
Consistência do conjunto de teste	As imagens são separadas em pastas de acordo com a classe. As imagens são nomeadas por classe e número
Autenticidade do conjunto de teste	As imagens foram coletadas em campo por contribuidores do iNaturalist tirando fotos de espécies encontradas na região de interesse (Santa Catarina/Brasil)
	As imagens correspondem às imagens a serem coletadas pelo público-alvo conforme definido no caso de uso
Robustez do conjunto de teste	As imagens foram coletadas variando o plano de fundo, ângulos, iluminação, distância, etc., a fim de evitar efeitos de canalização ou viés.
Confidencialidade do conjunto de teste	Não aplicável

Métricas

Para avaliar os modelos, as seguintes métricas foram utilizadas:

- Acurácia para avaliação de desempenho geral
- Precisão e *recall* para compreensão de como o modelo lida com falsos positivos e falsos negativos
- *F1-Score*, média harmônica de precisão e *recall* para avaliar a diferença entre as pontuações das medidas prévias.

Ambiente de execução

Os testes foram realizados usando Jupyter Notebooks no ambiente Google Colab. Os testes com Teachable Machine foram realizados utilizando a plataforma de prévia do mesmo para execução das predições das imagens de teste, e o cálculo das métricas foi realizado no mesmo ambiente de teste dos outros modelos.

Tabela 7. Resultados de desempenho nos testes.

Resultados da validação de desempenho	Acurácia total	Precisão	Recall	F1-Score
Resnet18*	89%	89%	89%	89%
Resnet34	87%	88%	87%	87%
EfficientNetLite*	88%	89%	88%	88%
EfficientNetB0	87%	88%	87%	87%
MobileNetV3	84%	85%	84%	84%
MobileNetV3-Google Teachable Machine	78%	78%	78%	78%

Discussão

Observa-se que no conjunto de testes os modelos ainda mantêm uma proporção de aproximadamente 1:1 de precisão e recall (Tabela 23). No entanto, os modelos não atingem a acurácia de 95% no conjunto de teste, e as outras medidas também são reduzidas em uma

proporção semelhante. Os modelos com melhor desempenho nos testes foram Resnet18 e EfficientNetLite.

Estes resultados são significativos pois os modelos utilizados priorizam desempenho em dispositivos móveis, e lidam com um conjunto de dados variado que pode ser de difícil identificação até para um especialista na área. Outro aspecto a ser considerado ao avaliar os resultados obtidos é o tratamento de overfitting. Durante o treinamento não foram usadas técnicas de mitigação de para tal, como validação cruzada. Também não foram usados ajustes de hiperparâmetro. Comparando os resultados de acurácia do treinamento e do teste, percebe-se que houve uma queda grande de acurácia, indicando ocorrência de overfitting.

Os modelos apresentaram resultados promissores durante o treinamento, mas os testes de desempenho demonstraram que ainda é necessária cautela se estes forem aplicados em cenários reais, pois uma classificação incorreta pode oferecer alto risco para os usuários. Em especial, observando as matrizes de confusão dos testes para a identificação de Lonomia obliqua, houveram múltiplos casos onde um espécime desta lagarta foi identificado como uma lagarta de outra espécie, algo que ocorreu com pouquíssima frequência durante o treinamento. Este erro de classificação em particular coloca um potencial usuário em risco direto, pois não comunica corretamente a severidade do risco em caso de contato com esta lagarta.

Ameaças à validade


Existem ameaças à validade em relação aos resultados obtidos que devem ser consideradas. A não utilização de técnicas para mitigação de overfitting é a principal ameaça à validade. Se tivessem sido aplicadas técnicas como validação cruzada e ajuste de hiperparâmetro, resultados melhores poderiam ser obtidos. Com relação ao viés de seleção, procurou-se criar uma amostra representativa de diferentes casos reais, com diferentes distâncias, condições de iluminação e variedade de espécimes. No entanto, existe a possibilidade do conjunto de dados pode não ser completamente abrangente, impedindo a generalização para todos os casos possíveis. Além disso, o tamanho da amostra pode ser insuficiente, uma vez que a quantidade de imagens encontradas para algumas espécies foi pequena para este tipo de tarefa de classificação. Ainda em relação ao tamanho da amostra, outra ameaça que se apresenta é o viés criado pelo pós-processamento de dados, que quando utilizado em um conjunto de dados muito pequeno gera um modelo capaz apenas de identificar variações de um conjunto pequeno de imagens. Este viés foi mitigado separando imagens de teste antes da aplicação do pós-processamento, impedindo que variações de uma mesma imagem estejam presentes nos conjuntos de treino e teste ao mesmo tempo. Finalmente, é necessário considerar o viés gerado pelas métricas de avaliação, mitigado pelo uso de diversas métricas para avaliar diferentes características do desempenho do modelo. Contudo, as métricas em si possuem limitações que devem ser consideradas para avaliar criticamente os resultados obtidos.

Implementação de aplicativo móvel

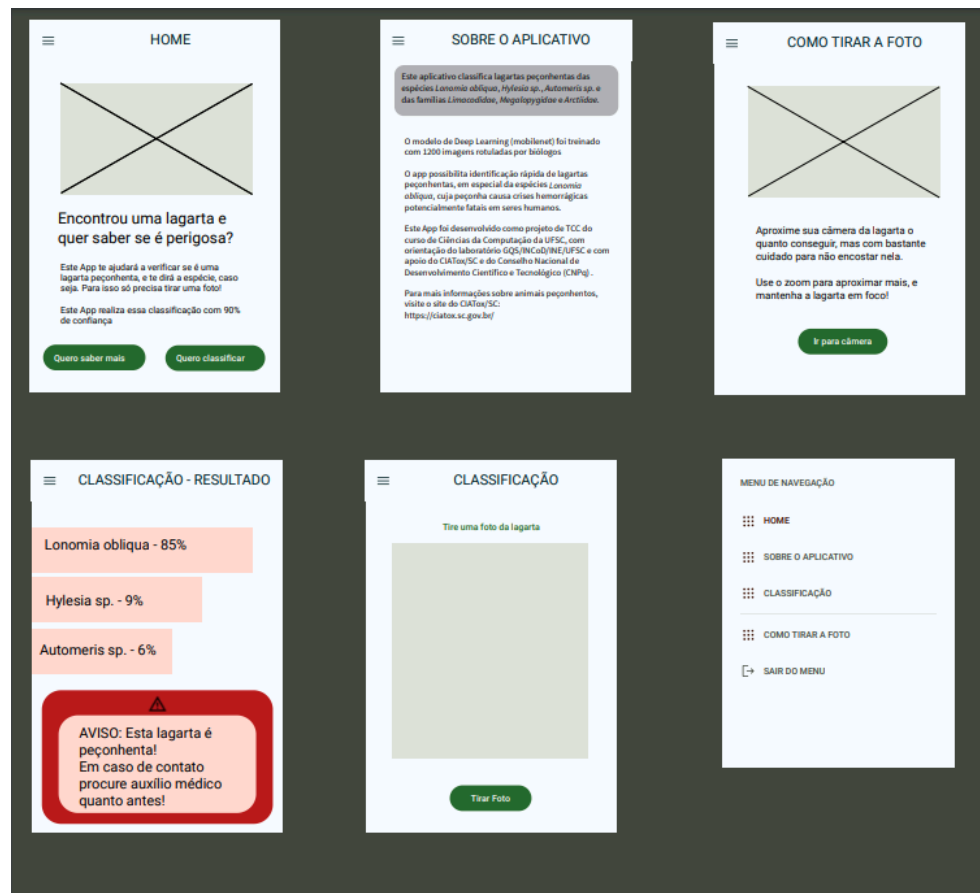
A implementação em aplicativo móvel foi feita usando o *MIT App Inventor (2023)*, para fazer uso de sua integração com *Teachable Machine* e velocidade para criação de um protótipo funcional. O modelo *Teachable Machine* foi escolhido pois não foram identificadas ferramentas para integração dos outros modelos com o MIT App Inventor

O design de interface foi desenvolvido de forma iterativa, inicialmente em forma de rascunhos feitos à mão, que depois foram adaptados para *wireframes* de baixa fidelidade. A partir dos *wireframes* foi criado um protótipo de *design* visual do aplicativo.

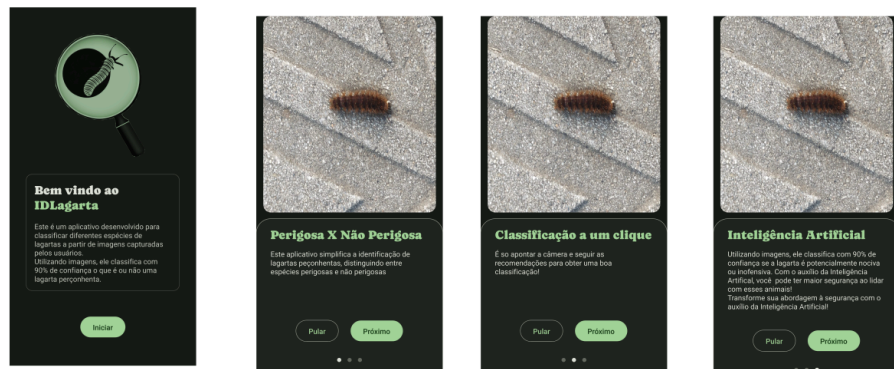
Tabela 8. Iterações de Interface do App.



Wireframe



Protótipo de design visual





A partir do *design* visual foi criado o protótipo do aplicativo no app inventor. Para criar componentes de tela compatíveis com a identidade visual proposta foram usadas extensões criadas pela comunidade de usuários da plataforma. As extensões usadas para elementos visuais foram: *AI2 Sidebar*, para criar abas de navegação laterais; *Custom Sheet* para diálogos estilo *pop-up*; *Infinite Progress Bars* para indicadores de progresso do processamento do modelo de *Deep Learning*.

Para possibilitar a integração de um modelo de classificação de imagens no MIT App Inventor, foi usada a extensão Teachable Machine Image Classifier (Oliveira, 2022). Esta extensão permite anexar um link de um modelo gerado pelo Google Teachable Machine à interface do aplicativo, e classificar imagens da câmera do dispositivo celular com o modelo anexado.

O comportamento do aplicativo foi programado com a ferramenta de blocos do *App Inventor*, de forma que futuras iterações deste aplicativo ou de similares possam ser de fácil implementação, mesmo para pesquisadores não familiarizados com desenvolvimento de aplicativos para dispositivos *Android*.

O projeto do protótipo de aplicativo no formato .aia está disponível publicamente sob a licença *Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International* (CC BY-NC-SA 4.0). Sob esta licença o projeto pode ser modificado e distribuído livremente para fins não comerciais. O acesso ao projeto é feito a partir do *link*:
<https://github.com/MatheusFBBueno/TCC-IDLagarta>

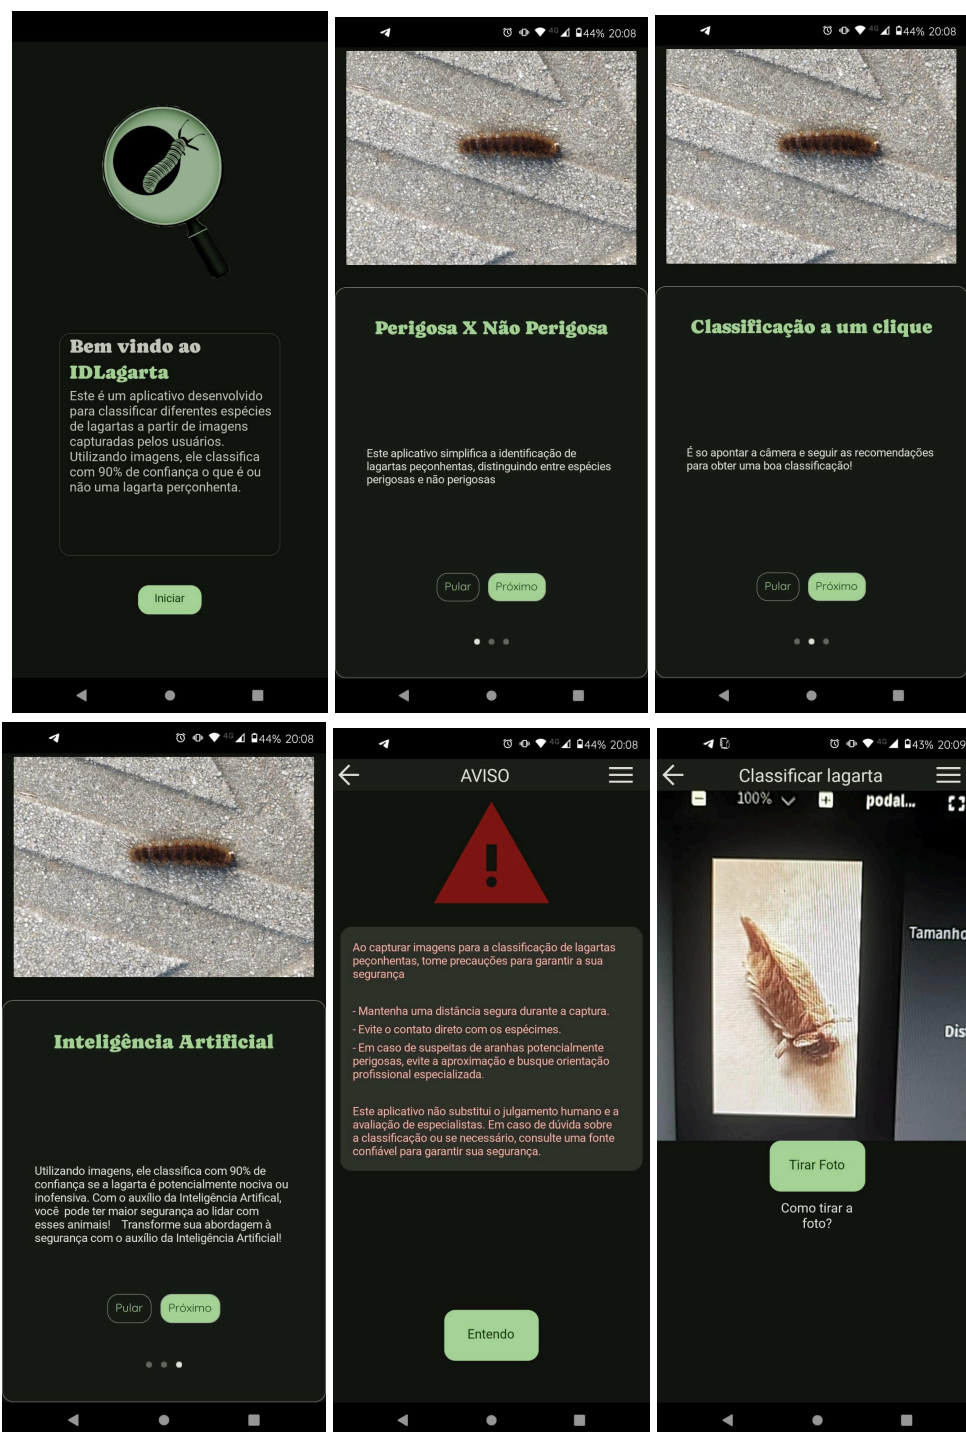


Figura 1. Capturas de tela de protótipo funcional de aplicativo implementado com App Inventor Fonte: Elaborado por autor

Conclusão

Por meio de uma fundamentação teórica sobre lagartas peçonhentas de Santa Catarina (O1), e o estado da arte de identificação de lagartas utilizando Deep Learning (O2), foram estabelecidas fases para o desenvolvimento do estudo. Com relação ao objetivo específico 3, foram desenvolvidos modelos de classificação de lagartas peçonhentas de Santa Catarina a partir de um conjunto de imagens de lagartas encontradas em campo. Apesar do bom desempenho durante a validação, os melhores resultados de teste foram com os modelos Resnet18 e EfficientNetLite, com 89% e 88% de acurácia respectivamente, e ambos abaixo do objetivo de 95%. Este resultado indica que os modelos necessitam de melhorias para alcançar acurácias maiores. Ademais, com relação ao objetivo específico O4, um aplicativo para Android foi criado utilizando o MIT App Inventor, com um modelo de Machine Learning implantado.

Contudo, dado a quantidade limitada de estudo da aplicação de Machine Learning para identificação de lagartas peçonhentas, este estudo estabelece precedente para futuros estudos. Os resultados deste trabalho demonstram que é possível alavancar arquiteturas de Machine Learning e dados disponibilizados pela comunidade científica para gerar uma ferramenta que pode informar a população em geral sobre os perigos de lagartas peçonhentas, e direcionar usuários a procurar atendimento emergencial o quanto antes, potencialmente reduzindo o tempo de busca ao atendimento médico, quando este é necessário, e assim diminuindo os riscos de gravidade no contato com esses agentes. Porém, com os resultados deste trabalho ainda não foram atingidos os níveis de acurácia necessária para que uma ferramenta deste tipo possa ser seguramente disponibilizada para o público em geral, tendo em vista os perigos relacionados à uma classificação incorreta.

Este campo de estudo possui oportunidades de pesquisas futuras com grande potencial para a utilidade pública, principalmente direcionadas à melhoria dos modelos, para que estes alcancem níveis aceitáveis de acurácia. A acurácia dos modelos pode ser melhorada por meio de agregação de mais observações com fotografias de espécies de lagartas peçonhentas de Santa Catarina. Ferramentas para integração de mais modelos em aplicativos móveis com App Inventor possibilitam que pesquisadores das ciências biológicas e até mesmo a população em geral possam criar aplicativos semelhantes com desempenhos melhores, mesmo com conhecimento mínimo de código. Com estas melhorias e avanços futuros, espera-se que o conhecimento sobre lagartas peçonhentas possa ser disseminado, e que a população em geral tenha mais ferramentas para garantir sua segurança ao lidar com a crescente quantidade de acidentes com estes animais em decorrência da mudança de habitat dos mesmos.

Referências

Affonso, C. et al. Deep learning for biological image classification, 2017. *Expert systems with applications*, 85, 114-122.

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

Azevedo, B. R. M.; & de Almeida, Z. D. S. Percepção ambiental e proposta didática sobre a desmistificação de animais peçonhentos e venenosos para os alunos do ensino médio, 2017. *Acta Tecnológica*, 12(1), 97-108.

Baştanlar, Y.; Özuysal, M. (2014). *Introduction to Machine Learning*, 2014. *miRNomics: MicroRNA Biology and Computational Analysis*. *Methods in Molecular Biology*, vol 1107. Humana Press, Totowa, NJ.

Cardoso, A. E. C.; & Haddad D Junior, V. Acidentes por lepidópteros (larvas e adultos de mariposas): estudo dos aspectos epidemiológicos, clínicos e terapêuticos, 2005. *Anais Brasileiros de Dermatologia*, 80(6), 571–578.

Cordeiro A. M. et al., Revisão sistemática: uma revisão narrativa, 2007. *Revista do Colégio Brasileiro de Cirurgiões*, 34(6).

Chen et al., *Agricultural Pests Damage Detection Using Deep Learning*, 2019. *Advances in Intelligent Systems and Computing*, vol 1036.

CIATOX/SC, Centro de Informação e Assistência Toxicológica de Santa Catarina: Relatório Anual 2021, 2022. Disponível em : <https://repositorio.ufsc.br/handle/123456789/238378> . Acesso em março de 2023.

CIATOX/SC, Centro de Informação e Assistência Toxicológica de Santa Catarina: Lagartas peçonhentas, 2023. Disponível em <https://ciatox.sc.gov.br/index.php/servicos/agentes-toxicos/animais-peconhentos/lagartas.html> . Acesso em março de 2023

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: Setembro de 2023.

DIVE. Acidentes, incidências e óbitos por lagartas, por regiões de saúde, SC, 2011-2021. Disponível em : <https://dive.sc.gov.br/phocadownload/doencas-agrivos/Animais%20pe%C3%A7onhetos/Boletins/Acidentes-I-Obitos-Lagartas-2011-2021.pdf>

Elngar, A. A. et al. Image classification based on CNN: a survey, 2021. Journal of Cybersecurity and Information Management, 6(1), 18-50.

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 Setembro de 2023

Ferro, V. G. et al. Mariposas Arctiinae (Lepidoptera: Erebidae) do estado de Santa Catarina, Brasil, 2012. Biota Neotropica, v. 12, n. 4, p. 166–180.

Gamborgi, G. P. et al Influência dos fatores abióticos sobre casos de acidentes provocados por Lonomia obliqua, 2012. Hygeia: Revista Brasileira de Geografia Médica e da Saúde, 8(14).

Google. Higher Accuracy on Vision Models with EfficientNet-Lite, 2020.

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

Gresse von Wangenheim, C.; Von Wangenheim, A. Visão geral de um processo interativo centrado no ser humano para ensinar aprendizado de máquina no ensino fundamental e médio, 2021. Disponível em

<<http://www.gqs.ufsc.br/files/2020/02/GQSTemplate-RelatorioTecnico-HumanCentricProcess-v10.pdf>>

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

Haddaway, N.R. et al. (2015). The role of Google Scholar in evidence reviews and its applicability to grey literature searching, 2015. PloS one, 10.9.

Helm, J.M. et al., Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions, 2020. Curr Rev Musculoskelet Med 13, 69–76.

Howard, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications, 2017. arXiv preprint arXiv:1704.04861.

IBM. What are neural networks?, 2020. Disponível em: <https://www.ibm.com/cloud/learn/neural-networks> Acesso em setembro de 2023

INATURALIST. Seek by INaturalist,. Disponível em : https://www.inaturalist.org/pages/seek_app Acesso em março de 2023

iNaturalist, Contribuidores de iNaturalist (2024). iNaturalist Research-grade Observations, 2024. Disponível em <https://doi.org/10.15468/ab3s5x>. Acesso em março de 2024.

Kaiming He et al., Deep Residual Learning for Image Recognition, 2015. arXiv preprint arXiv:1512.03385.

Khan, R. et al. Harmful Insect Detection Using Deep Learning, 2021. ResearchGate preprint. Disponível em https://www.researchgate.net/publication/348659953_Harmful_Insect_Detection_Using_Deep_Learning. Acesso em março de 2023

Kierski, M. Machine Learning development process - you've got it wrong, 2017. Disponível em: <https://medium.com/sigmoidal/machine-learning-development-process-youve-got-it-wrong-396270e653f4> Acesso em abril de 2023.

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

Lepesqueur, C. Megalopygidae (Lepidoptera, Zygaenoidea): biologia, diversidade e biogeografia, 2012. (Doutorado) Universidade de Brasília, Brasília.

Lisete M, L.; Corseuil, E. Aspectos morfológicos de *Lonomia obliqua* walker (Lepidoptera: Saturniidae), 2001. Neotropical Entomology, v. 30, p. 373-379, 2001.

MIT App Inventor, disponível em: <https://appinventor.mit.edu/> Acesso e uso em maio de 2024.

Garcia, C.M. Analytical Test On The Environmental Constraints Related To Accidents With The *Lonomia Obliqua* Walker 1855, In Southern Brazil, 2013. Journal of Ecosystem & Ecography. 03.

Oliveira, F. P. 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, Florianópolis, Brasil.

Orlandin et al. Borboletas e mariposas de Santa Catarina: uma introdução. 1. ed, 2016. Campos Novos: edição Mario Arthur Favretto.

O'Shea, K.; Nash, R. An introduction to convolutional neural networks, 2015. arXiv preprint arXiv:1511.08458.

Pacheco, C.A.R.; Pereira, N.S. Deep Learning: Conceitos e Utilização nas Diversas Áreas do Conhecimento, 2018. Graduação em Computação. Trabalho de Conclusão de Curso (Engenharia de Computação). Universidade Evangélica de Goiás.

Pereira et al. Biological and morphological characteristics of *Hylesia paulex* (Lepidoptera: Saturniidae) fed with *Eucalyptus urophylla* (Myrtaceae), 2009. INCI, Caracas, v. 34, n. 9, p. 645-649.

Petersen, et al. Systematic Mapping Studies in Software Engineering, 2008. Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering. Itália.

Polyzotis et al. Data Management Challenges in Production Machine Learning, 2017. Proceedings of the ACM International Conference on Management of Data, Chicago, IL, USA, p. 1723 – 1726.

Sagar et al. Identification of Indian butterflies and moths with deep convolutional neural networks, 2020. CURRENT SCIENCE, 118(9), 1456

Shafiq, M.; Gu, Z. Deep Residual Learning for Image Recognition: A Survey, 2022. Applied Sciences, 12, 8972.

Simonyan, K.; Zisserman, A. Very deep convolutional networks for large-scale image recognition, 2014. arXiv preprint arXiv:1409.1556.

Specht, et al. Biologia de *Hylesia nigricans* (Berg) (Lepidoptera, Saturniidae, Hemileucinae), 2006. Revista Brasileira de Zoologia, v. 23, n. 1, p. 248–255.

Specht et al. Biologia e aspectos morfológicos dos estágios imaturos de *Automeris naranja* Schaus (Lepidoptera, Saturniidae, Hemileucinae), 2007. Revista Brasileira de Zoologia, v. 24, n. 3, p. 523–534.

Specht et al. Biologia de *Automeris illustris* (Walker) (Lepidoptera, Saturniidae, Hemileucinae), 2006. Revista Brasileira de Zoologia, v. 23, n. 2, p. 537–546.

Suárez et al. Pest detection and classification to reduce pesticide use in fruit crops based on deep neural networks and image processing, 2021. Proc. of the XIX Workshop on Information Processing and Control, SAN JUAN, Argentina.

Szegedy et al. Going deeper with convolutions, 2015. In Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, EUA.

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 Setembro de 2022.

Tiwari, V. et al. Real-Time Soybean Crop Insect Classification Using Customized Deep Learning Models, 2021. Sharma, N., Chakrabarti, A., Balas, V.E., Bruckstein, A.M. (eds) Data Management, Analytics and Innovation. Lecture Notes on Data Engineering and Communications Technologies, vol 70.

Weiss et al. A survey of transfer learning, 2016. J Big Data 3, 9.

Xin et al. Fine-grained butterfly classification in ecological images using squeeze-and-excitation and spatial attention modules, 2020. Applied Sciences, 10(5), 1681.

Zhu et al. Hybrid Deep Learning for automated lepidopteran insect image classification, 2017. Oriental Insects, 51(2), 79-9