

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

**Desenvolvimento de um Modelo de Classificação de Imagens de Escorpiões
usando *Deep Learning***

Artur Carmezini Cardoso

Florianópolis

2024

Universidade Federal de Santa Catarina
Departamento de Informática e Estatística

**Desenvolvimento de um Modelo de Classificação de Imagens de Escorpiões
usando *Deep Learning***

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

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

Florianópolis

2024

AGRADECIMENTOS

À Universidade Federal de Santa Catarina, por proporcionar uma formação gratuita e de qualidade e por me preparar de maneira sólida para o mercado de trabalho. Agradeço também ao corpo docente, à direção e à administração desta universidade, por sempre ter dado o máximo enquanto se tinha o mínimo.

Ao meu amor, pelo companheirismo, pela compreensão, pelo acolhimento e por me ensinar o ressignificado de amor, eu serei sempre grato. Que possamos continuar construindo e crescendo juntos, o meu maior desejo.

Às amigas que construí ao longo desse caminho, que foram fonte de apoio e companheirismo nos momentos mais desafiadores. Vocês fizeram esta jornada muito mais leve e especial.

Aos professores, meu sincero agradecimento pelas horas dedicadas ao ensino, pelo conhecimento compartilhado e pelo incentivo constante. Cada um de vocês contribuiu de maneira significativa para a minha formação, com menção honrosa para a professora Christiane, orientadora deste trabalho, que mesmo em um período de saúde frágil, foi capaz de me guiar de maneira exemplar e cuidadosa.

À minha família, por toda a base e suporte ao longo desses anos. Agradeço especialmente às minhas duas avós pela criação e pela força que sempre me deram. Vocês são a minha maior inspiração e motivação para seguir em frente.

RESUMO

Atualmente, acidentes causados por escorpiões são considerados um problema de saúde pública em Santa Catarina e podem apresentar sintomas como dor intensa no local da picada, inchaço, náuseas, vômitos, sudorese e taquicardia. Em casos mais graves, pode ocorrer insuficiência respiratória e óbito. Porém, a população carece de medidas de conscientização sobre os principais riscos destes animais, assim como não há conhecimento por parte da população na classificação dos mesmos. Uma possível solução para esse problema é o desenvolvimento de um aplicativo móvel utilizando *deep learning*, que identifica a espécie dos escorpiões por meio de fotos. Ainda não existe um modelo de *deep learning* que classifique escorpiões em Santa Catarina/Brasil com uma acurácia aceitável, já que se trata de um tratamento direto a vidas humanas. Assim, o objetivo geral deste trabalho é desenvolver um modelo de classificação de imagens de escorpiões para classificar as espécies tipicamente encontradas em Santa Catarina: *Tityus serrulatus*, *Tityus costatus* e *Tityus bahiensis* e o gênero *Bothriurus*. São adotadas técnicas de *deep learning* para automatizar a classificação a partir de fotos de escorpiões obtidas com a câmera do celular. Como parte do trabalho, é criado um conjunto de imagens de escorpiões em colaboração com o Centro de Informação e Assistência Toxicológica de Santa Catarina (CIATox/SC). São realizados experimentos com diferentes modelos de redes neurais comparando o seu desempenho. Ao final do modelo desenvolvido, é implantado um aplicativo móvel usando *App Inventor*. Com isso, espera-se contribuir para a prevenção de ataques escorpiônicos, assim como a conscientização da população, além de fornecer um exemplo de um aplicativo útil no contexto do ensino de computação.

LISTA DE FIGURAS

Figura 1 -	Escorpião <i>Tityus costatus</i>	14
Figura 2 -	Escorpião <i>Tityus serrulatus</i>	14
Figura 3 -	Escorpião <i>Tityus bahiensis</i>	14
Figura 4 -	Acidentes por animais peçonhentos segundo o tipo de acidente, Santa Catarina, 2011-2021	15
Figura 5 -	<i>Parioscorpio venator</i> , holótipo, detalhe da região medial mostrando estruturas pulmocardiovasculares	20
Figura 6 -	Classificação atual dos escorpiões	20
Figura 7 -	Morfologia do escorpião	21
Figura 8 -	Estrutura do último segmento da cauda	22
Figura 9 -	<i>Bothriurus jesuít</i> a	23
Figura 10 -	Télson do gênero <i>Bothriurus</i>	24
Figura 11 -	Télson do gênero <i>Tityus</i>	24
Figura 12 -	Ocorrências por mês em Santa Catarina em 2022 da <i>Tityus</i> spp.	25
Figura 13 -	Distribuição dos acidentes com <i>Tityus</i> spp. em Santa Catarina no ano de 2022	27
Figura 14 -	Imagem captura de um <i>Tityus serrulatus</i>	28
Figura 15 -	Imagem captura de um <i>Tityus costatus</i>	29
Figura 16 -	Imagem captura de um <i>Tityus bahiensis</i>	30
Figura 17 -	Diagrama de Venn ilustrando o campo da inteligência artificial	31
Figura 18 -	Estrutura típica de neurônio	31

Figura 19 -	Estrutura e camadas de uma rede neural profunda	32
Figura 20 -	Visão geral do processo iterativo de <i>Machine Learning</i> centrado em humanos	34
Figura 21 -	Exemplo de matrizes tridimensionais recebidas pelas CNNs	36
Figura 22 -	Fluxo de classificação de uma rede neural convolucional	37
Figura 23 -	Estrutura e camadas de uma rede neural profunda	38
Figura 24 -	Arquiteturas e desempenhos das ResNets com o ImageNet	39
Figura 25 -	Exemplo de um bloco residual	40
Figura 26 -	Diferenças das etapas em redes convolucionais tradicionais e de separáveis em profundidade	41
Figura 27 -	Diferentes métodos de dimensionamento	42
Figura 28 -	Resultados da classificação de imagens no ImageNet	43
Figura 29 -	Exemplo de matriz de confusão	44
Figura 30 -	Método de acurácia	44
Figura 31 -	Método de precisão	44
Figura 32 -	Método de <i>recall</i>	45
Figura 33 -	Métrica de <i>F1-Score</i>	45
Figura 34 -	Tamanho dos modelos vs Acurácia	46
Figura 35 -	Comparação da acurácia e tamanho de modelos	47
Figura 36 -	<i>Wireframes</i> do App	81
Figura 37 -	Blocos lógicos do ScorplD SC no App Inventor	88

LISTA DE TABELAS

Tabela 1 -	Espécies de escorpião do gênero <i>Tityus</i> presentes em Santa Catarina	13
Tabela 2 -	Diferença do Telson do gênero <i>Bothriurus</i> e <i>Tityus</i>	23
Tabela 3 -	Termos de busca utilizados no protocolo de revisão	48
Tabela 4 -	<i>String</i> de busca para cada fonte	49
Tabela 5 -	Resultado das <i>Strings</i> de busca para cada fonte	49
Tabela 6 -	Classificação de espécies nas extensões encontradas	51
Tabela 7 -	Informações sobre os conjuntos de dados utilizados	51
Tabela 8 -	Informações sobre o treinamento dos modelos	53
Tabela 9 -	Métricas de teste do desempenho dos modelos treinados	54
Tabela 10 -	Análise da necessidade	56
Tabela 11 -	Requisitos de um modelo de <i>ML</i> para classificação de imagens de escorpiões	57
Tabela 12 -	Informações do conjunto de dados utilizado para o treinamento	58
Tabela 13 -	Treinamento com a rede ResNet18	60
Tabela 14 -	Treinamento com a rede ResNet34	61
Tabela 15 -	Treinamento com a rede EfficientNet-Lite	63
Tabela 16 -	Treinamento com a rede EfficientNet-B0	64
Tabela 17 -	Treinamento da rede MobileNetV3	65
Tabela 18 -	Treinamento da rede MobileNetV2 com a ferramenta GTM	67
Tabela 19 -	Características do conjunto de dados de teste	68

Tabela 20 - Testes com a rede ResNet18	69
Tabela 21 - Testes com a rede ResNet34	70
Tabela 22 - Testes com a rede EfficientNet-Lite.	71
Tabela 23 - Testes com a rede Efficient-Net B0	72
Tabela 24 - Testes com a rede MobileNetV3	73
Tabela 25 - Testes com a rede MobileNetV2 com a ferramenta GTM	74
Tabela 26 - Resultado dos treinamentos de diferentes modelos.	75
Tabela 27 - Resultado dos testes dos diferentes modelos.	76
Tabela 28 - Necessidades identificadas	78
Tabela 29 - Caracterização do ambiente de uso.	79
Tabela 30 - <i>Sketches</i> do aplicativo ScorpID SC	80
Tabela 31 - Design do aplicativo ScorpID SC	81
Tabela 32 - Imagens utilizadas no aplicativo ScorpID SC	86
Tabela 33 - Capturas de tela do aplicativo ScorpID SC implementado no <i>App Inventor</i>	88

LISTA DE ABREVIATURAS E SIGLAS

CIATox/SC	Centro de Informação e Assistência Toxicológica de Santa Catarina
DL	Deep learning
MIT	Massachusetts Institute of Technology
IA	Inteligência artificial
AI	App Inventor
ML	Machine learning (Aprendizado de máquina)
RNA	Rede neural artificial
DNN	Deep neural network (Rede neural profunda)
CNN	Convolutional neural network (Rede neural convolucional)
MBCConv	Mobile inverted bottleneck convolution

SUMÁRIO

1	INTRODUÇÃO	13
	1.1 Contextualização	13
	1.2 Objetivos	17
	1.3 Metodologia de Pesquisa	17
	1.4 Estrutura do Documento	19
2	FUNDAMENTAÇÃO TEÓRICA	19
	2.1 Quem são os Escorpiões?	19
	2.2 Morfologia dos Escorpiões	21
	2.3 Escorpiões sem Peçonha Letal	22
	2.4 Escorpiões com Peçonha Letal	24
	2.4.1 <i>Tityus serrulatus</i>	27
	2.4.2 <i>Tityus costatus</i>	28
	2.4.3 <i>Tityus bahiensis</i>	29
	2.5 Classificação de Imagens com <i>Deep Learning</i>	30
	2.5.1 Visão geral	30
	2.5.2 Processo de desenvolvimento de modelos de deep learning para classificação de imagens	33
	2.5.3 Tipos de redes neurais para classificação de imagens ..	35
	2.5.3.1 ResNets	38
	2.5.3.2 MobileNet	40

	2.5.3.3 EfficientNet	41
	2.5.3.4 Comparação do desempenho padrão dos modelos	43
3	ESTADO DA ARTE	47
	3.1 Definição do Protocolo de Revisão	47
	3.2 Execução da Busca	49
	3.3 Resultados da Revisão	50
	3.3.1 Quais pesquisas relacionadas existem?	50
	3.3.2 Como é formado o conjunto de dados e quantas imagens possui	51
	3.3.3 Como e quais modelos foram treinados?	53
	3.3.4 Quais os desempenhos relatados?	54
	3.4 Discussão	55
4	DESENVOLVIMENTO DE MODELO DE CLASSIFICAÇÃO DE IMAGENS DE ESCORPIÃO	56
	4.1 Requisitos	56
	4.2 Preparação do Conjunto de Imagens	58
	4.3 Treinamento, Avaliação do Desempenho e Teste	59
	4.3.1 Treinamento das redes	60
	4.4 Testes de Desempenho	68
	4.4.1 Preparação do teste	68
	4.5 Discussão	75

5	DESENVOLVIMENTO DO APLICATIVO MÓVEL	77
	5.1 Requisitos do Aplicativo	78
	5.2 Design de Interface	80
	5.2.1 <i>Sketch</i>	80
	5.2.2 <i>Wireframe</i>	80
	5.2.3 Design visual	81
	5.3 Desenvolvimento do Aplicativo	87
6	CONCLUSÃO	94
	REFERÊNCIAS BIBLIOGRÁFICAS.	96

1 INTRODUÇÃO

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

1.1 Contextualização

No Brasil, há animais que compõem a nossa biodiversidade que possuem veneno, uma substância tóxica que é produzida por animais como forma de defesa e de ataque a presas. Entre estes animais peçonhentos, estão os escorpiões. Os escorpiões são animais invertebrados, que podem medir, quando adultos, de 5 a 9 centímetros e pertencem a classe de aracnídeos. Todas as espécies de escorpiões possuem veneno, mas apenas algumas trazem consequências sérias em humanos. Com o avanço das áreas urbanas, o escorpião começou a dividir espaços com os humanos e as ocorrências se tornaram mais comuns com o avançar das últimas décadas. Os escorpiões são encontrados com mais frequência em terrenos baldios, em construções civis e fossos de lixo, podendo ser encontrados em residências adjacentes a estes ambientes (Butantan, 2021).

No Brasil, os acidentes escorpiônicos mais graves são causados por escorpiões do gênero *Tityus* e as principais espécies são *Tityus serrulatus*, *Tityus bahiensis*, *Tityus costatus*, *Tityus stigmurus* e *Tityus cambridgei* ou chamado de *obscurus* (Neto e Pardal, 1996; Silva et al., 2000; Albuquerque et al., 2004). Em Santa Catarina, sofremos por infestações de principalmente três dessas espécies, todas contendo peçonhas letais: o *Tityus costatus*, *Tityus serrulatus* (escorpião-amarelo) e o *Tityus bahiensis* (escorpião-marrom), conforme ilustrado na Tabela 1.

Tabela 1: Espécies de escorpião do gênero *Tityus* presentes em Santa Catarina

Espécie	Foto
---------	------

<p><i>Tityus costatus</i></p>	 <p>Fonte: CIATox/SC</p>
<p><i>Tityus serrulatus</i></p>	 <p>Fonte: CIATox/SC</p>
<p><i>Tityus bahiensis</i></p>	 <p>Fonte: CIATox/SC</p>

Os escorpiões podem se reproduzir de diferentes maneiras, como a vivípara, em que a mãe gera o filhote na placenta, assim como em mamíferos placentários. Há espécies que denominamos de ovovivíparas, quando o filhote é gerado dentro do

ovo e alojado dentro do corpo da fêmea. Além disso, algumas espécies realizam a partenogênese, uma forma de reprodução assexuada que facilita infestações dessas espécies. O escorpião-amarelo, presente em Santa Catarina, é um exemplo de espécie que é tanto vivípara quanto partenogenética, o que aumenta os riscos para a população local. A mãe tem aproximadamente dois partos com, em média, 20 filhotes cada, por ano, chegando a 160 filhotes durante a vida (Ministério da Saúde, 2009, p.9). Segundo Scholte (2009), existem cerca de 20 gêneros e quase 120 espécies de escorpiões no Brasil, das quais 95% se reproduzem sexualmente.

No Brasil e também em Santa Catarina, picadas de escorpiões são consideradas uma questão de segurança pública. Santa Catarina vem registrando um aumento de mais de 100 casos de acidentes escorpiônicos comparado a dez anos atrás, conforme apresentado na Figura 4.

Figura 4: Acidentes por animais peçonhentos segundo o tipo de acidente, Santa Catarina, 2011-2021 (DIVE, 2022).

Tipo de Acidente	Anos											Total
	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	
Ign/Branco	343	365	373	383	463	184	121	125	98	60	61	2576
Serpente	767	771	732	735	763	695	731	668	677	714	648	7901
Aranha	6136	5572	6176	5616	6356	5756	5843	5717	6366	4440	4249	62227
Escorpião	220	211	217	207	324	286	321	378	410	341	339	3254
Lagarta	545	408	356	517	514	450	755	835	649	223	322	5574
Abelha	789	916	811	842	825	687	994	895	965	710	588	9022
Outros	504	496	658	597	506	301	301	280	278	211	200	4332
Total	9304	8739	9323	8897	9751	8359	9066	8898	9443	6699	6407	94886

Fonte: Sistema de Informação de Agravos de Notificação – SINAN. Dados coletados em 25/05/2022

O envenenamento pela picada pode causar dores locais, inchaço, inflamação e sintomas sistêmicos como náusea, vômito, sudorese, hipertensão e arritmias cardíacas. É importante para o cidadão que foi picado por um escorpião procurar atendimento para a classificação da espécie para direcionar de forma correta o seu atendimento médico (Bruna, 2020). Um dos fatores de complicações em caso de escorpionismo é o da conscientização da população de que é um risco real e hoje há uma falta de conhecimento sobre o assunto. Como nem todos os escorpiões encontrados pela população são de risco à saúde humana, a classificação taxonômica dos escorpiões pode ajudar na prevenção e combate nesses casos. Há

várias características importantes para denominar as espécies dos escorpiões, sendo a principal delas, a cor, mas também, pode ser analisado seu tamanho, sua serrilha e o formato do seu telson.

Geralmente, é necessário a consulta de um especialista para determinar se o animal encontrado é realmente um escorpião com peçonha letal com base numa análise aprofundada. A identificação da espécie ou de suas características após o acidente, auxilia no atendimento ao paciente, facilitando aos profissionais de saúde na diferenciação de um animal peçonhento ou não, assim, escolhendo a melhor forma de tratamento (UFMG, 2023). Normalmente, a pessoa que se envolveu em um acidente escorpiônico tenta visualizar algumas características do animal e às vezes até manusear o animal ainda vivo e levá-lo ao hospital, fazendo com que a pessoa que se envolveu em um acidente escorpiônico sofra um risco desnecessário para coletar as informações necessárias para a identificação.

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

Hoje, já existem aplicativos que classificam a fauna e a flora utilizando modelos de *Machine Learning (ML)*, como o iNaturalist, que são capazes de realizar esse tipo de classificação de animais. Alguns destes aplicativos também podem classificar escorpiões. Também há aplicativos que fornecem somente informações sobre as espécies de escorpiões, que pode-se usar para tentar classificar o animal manualmente. Porém, ainda não há um aplicativo voltado especificamente para a classificação de espécies peçonhentas de escorpiões no estado de Santa Catarina que utilize de *ML*.

A proposta visa um aplicativo capaz de classificar espécies letais de escorpiões presentes em Santa Catarina, que seja capaz de obter essa classificação a partir de uma foto tirada com a câmera de celular, propondo assistir um cidadão que se acidentou ou que quer se informar sobre um possível perigo. Assim, o objetivo do presente estudo é identificar se é possível o desenvolvimento de um aplicativo móvel inteligente que consegue de forma fácil classificar escorpiões letais

vs. não letais por meio de fotos capturadas pela câmera do celular com um grau de precisão de, no mínimo, 95%.

1.2 Objetivos

Objetivo geral

O objetivo geral deste trabalho é desenvolver um modelo de classificação de imagens de escorpiões letais em Santa Catarina/Brasil. São adotadas técnicas de *DL* para automatizar a classificação da espécie a partir de fotos de escorpiões obtidas com a câmera do celular e espera-se atingir no mínimo uma acurácia de 95% ao final do desenvolvimento. O modelo desenvolvido é implantado em um aplicativo móvel Android usando App Inventor.

Objetivos Específicos

01. Analisar a fundamentação teórica sobre escorpiões e *deep learning*.
02. Analisar o estado da arte em relação a classificação de escorpiões com *deep learning*.
03. Desenvolver e testar um modelo utilizando *deep learning* para a classificação de escorpiões letais presentes em SC.
04. Implantar o modelo treinado em um aplicativo Android.

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 modelo proposto tem como foco a classificação de escorpiões presentes no estado de Santa Catarina. Não são abordadas outras espécies.

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 escorpiões (principalmente os com peçonha letal a seres humanos) de Santa Catarina/Brasil

A1.2 – Análise teórica sobre *deep learning* (principalmente 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. (2008) para identificar e analisar aplicativos/modelos de *Deep Learning* existentes voltados a classificação de escorpiões. Esta etapa é dividida nas seguintes atividades:

A2.1 – Definição do protocolo da revisão

A2.2 – Execução da busca e seleção de materiais 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 escorpiões, seguindo um processo de desenvolvimento de redes neurais/*deep learning* 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 (Oliveira, 2022), seguindo um processo de engenharia de software proposto por Pressman (2011). 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

Para melhor compreensão do desenvolvimento deste trabalho e visando o alcance pleno dos objetivos propostos, a estrutura está dividida em capítulos complementares entre si. No capítulo 2 é apresentada a fundamentação teórica, que inclui conceitos sobre os escorpiões, espécies de escorpiões e classificação de imagens. A seguir, o capítulo 3 apresenta o estado da arte sobre a classificação de imagens de espécies de escorpiões usando *Machine Learning*. O capítulo 4 é focado no desenvolvimento de modelo de classificação de imagens de escorpiões, seguido pelo capítulo 5, que fala sobre o desenvolvimento do aplicativo móvel. Por fim, o capítulo 6 apresenta a conclusão do trabalho realizado durante o presente estudo.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são definidos os conceitos de escorpiões, suas espécies e acidentes em Santa Catarina. Também serão abordados os conceitos de *Deep Learning*, assim como a abordagem de classificação e imagens.

2.1 Quem são os Escorpiões?

O escorpião é um dos animais mais antigos dos quais temos conhecimento e datam de cerca de 430 milhões de anos, no período Siluriano. É importante destacar que, por ser um grupo muito antigo, boa parte da sua história evolutiva é de especulações iniciais. Há divergência de opiniões entre os pesquisadores sobre suas origens serem em território terrestre e/ou marinho (Wendruff et al., 2020). Na Figura 5, pode ser visto um fóssil datado do período Siluriano, encontrado onde hoje é o estado de Wisconsin, Estados Unidos.

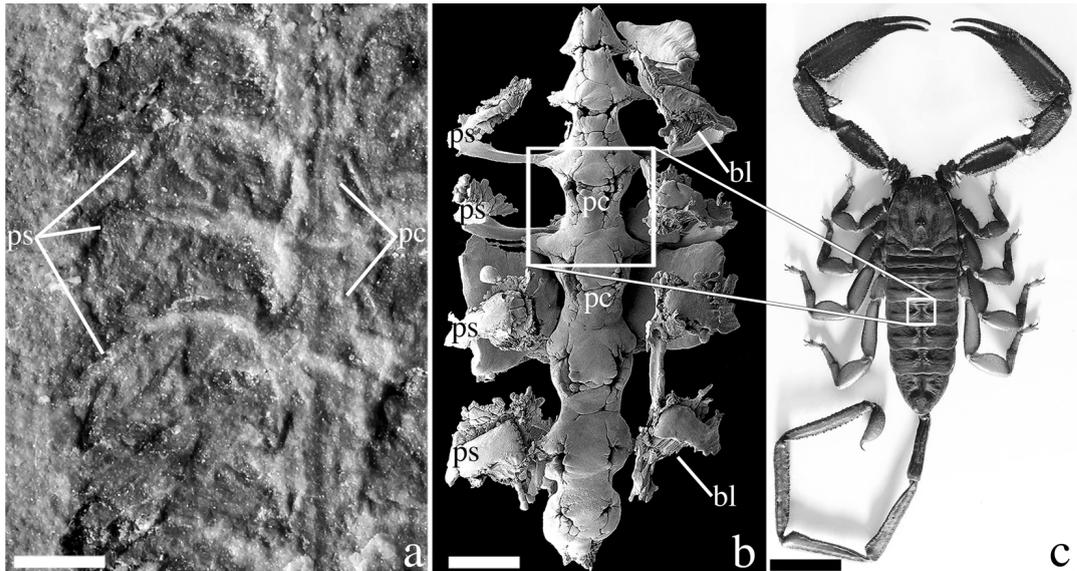


Figura 5: *Parioscorpio venator*, holótipo, detalhe da região medial mostrando estruturas pulmocardiavasculares. Fonte: (Wendruff et al., 2020)

Os escorpiões estão entre os primeiros animais a se tornarem completamente terrestres (Wendruff et al., 2020). Hoje, a classificação de escorpiões é feita da maneira ilustrada na Figura 6.

- Reino Animalia
 - Filo Arthropoda
 - Classe Arachnida
 - Ordem Scorpiones

Figura 6: Classificação atual dos escorpiões.

Os escorpiões alimentam-se de animais vivos como baratas, grilos, aranhas e pequenos vertebrados. Quando encontram condições favoráveis, as espécies se domicíliam com facilidade. São comumente encontrados em ambientes externos e no interior dos imóveis onde haja refúgio e alimento, tais como: terrenos baldios com mato, entulho ou lixo, locais com material de construção, galerias de águas pluviais e esgoto, canais, caixas de passagem e de gordura, caixas e pontos de energia, lixeiras e/ou fosso de lixo. Os escorpiões são animais terrestres e apresentam hábitos noturnos (Candido et al., 2019).

Scorpiones é a ordem de artrópodes aracnídeos terrestres que apresentam corpo alongado e quelíceras com três artículos. Este animal apresenta hábitos noturnos, crípticos e comportamento pouco ativo (Brownell; Polis, 2001). Portanto, os escorpiões integram a Classe Arachnida, juntamente com as aranhas (Araneae), ácaros (Acari), opiliões (Opiliones), dentre outros. Os aracnídeos destacam-se para os seres humanos como animais perigosos e de importância médica pela capacidade de transmitir doenças ou causar danos a plantações agrícolas (ácaros), e/ou pela ação do veneno de algumas espécies (aranhas e escorpiões) (Brazil; Porto, 2011, p. 15).

2.2 Morfologia dos Escorpiões

O corpo dos escorpiões é dividido em duas partes: prossoma (cefalotórax) e opistossoma, este último subdividido em mesossoma (tronco) e metassoma (cauda) (Figura 7). Os escorpiões apresentam uma carapaça (prossoma) contendo um par de quelíceras, um par de pedipalpos (pinças) e quatro pares de pernas. O abdômen (opistossoma) é dividido entre o tronco (mesossoma) e a cauda (metassoma). No primeiro se encontram o opérculo genital, os apêndices sensoriais (pentes) e os espiráculos (aberturas externas do pulmão), no segundo localiza-se, ao final de sua extremidade, o télson, que termina em um ferrão usado para inocular o veneno, servindo-lhe tanto para a caça como para defesa de possíveis predadores (Ministério da Saúde, 2009, p. 7).

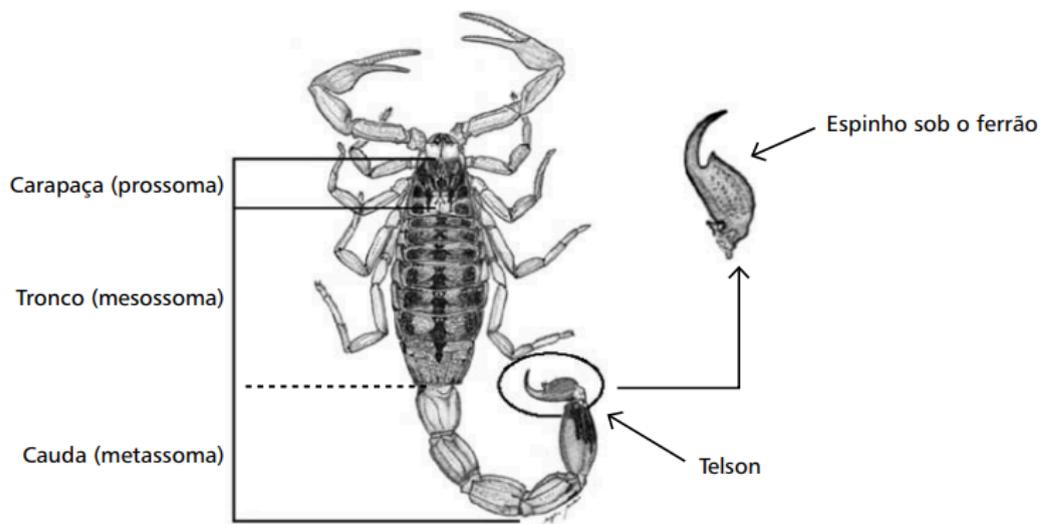


Figura 7: Morfologia do escorpião (Ministério da Saúde, 2009)

O abdômen dos escorpiões é segmentado e possui um formato alongado. Ele é coberto por uma série de placas duras chamadas tergitos. Na parte final do abdômen, os escorpiões possuem uma estrutura característica: o télson, que contém o ferrão. O ferrão é utilizado como mecanismo de defesa e contém um par de glândulas de veneno, que é injetada nas vítimas.

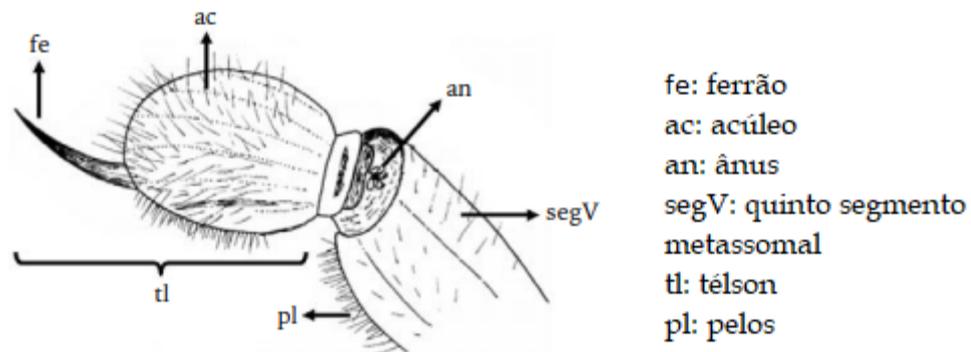


Figura 8: Estrutura do último segmento da cauda. Fonte: ((Brazil; Porto, 2011) adaptado de Hjelle (1990))

2.3 Escorpiões sem Peçonha Letal

No estado de Santa Catarina podem ser encontrados escorpiões de dois gêneros distintos, o *Tityus* e o *Bothriurus*, ambos pertencentes à ordem Scorpiones. Em ambos os gêneros, os escorpiões possuem características típicas, como corpo segmentado, quelíceras e cauda curvada com um aguilhão venenoso. Entretanto, as espécies do gênero *Bothriurus* não têm importância médica por seu veneno não ser capaz de trazer grandes malefícios para os seres humanos. Porém, é importante lembrar que mesmo o gênero *Bothriurus* tendo venenos menos tóxicos e, portanto, suas picadas tendem a ser menos graves, isso não significa que as picadas de escorpiões do gênero *Bothriurus* sejam completamente inofensivas, pois ainda podem causar dor localizada, inchaço e desconforto.



Figura 9: *Bothriurus jesuita*.

Observado em 2012 em Corrientes, Argentina por Hugo Hulsberg

Segundo o CIATox/SC (2023), a maneira mais assertiva de se diferenciar escorpiões com e sem importância médica no estado, é a de que escorpiões sem peçonha letal não possuem um espinho logo abaixo do ferrão (agulhão) conforme o exemplo na Tabela 2. Além disso, sua coloração é mais opaca, diferente dos escorpiões sem importância médica, que aparentam serem naturalmente envernizados, pois sua coloração é mais “brilhante”.

Tabela 2: Diferença do Telson do gênero *Bothriurus* e *Tityus*

Gênero	Característica	Imagem
--------	----------------	--------

<p>Gênero <i>Bothriurus</i></p>	<p>Télson não possui espinho</p>	 <p>Fonte: CIATox/SC</p>
<p>Gênero <i>Tityus</i></p>	<p>Télson possui espinho</p>	 <p>Fonte: CIATox/SC</p>

2.4 Escorpiões com Peçonha Letal

O escorpionismo é um desafio de saúde pública em várias partes do mundo devido a sua alta frequência e severidade dos acidentes, especialmente em crianças e idosos. Milhões de casos são relatados a cada ano globalmente (Chippaux; Goyffon, 2008; Lourenço, 2018; Ward et al., 2018). Acredita-se que há cerca de 2.000 espécies distintas deste animal espalhados em todos os continentes, menos

na Antártida. Eles são mais comuns em regiões tropicais e subtropicais, onde as temperaturas são mais elevadas, o que pode explicar o aumento na frequência de ocorrências desse animal no país, inclusive no estado de Santa Catarina, durante os meses mais quentes do ano, como é mostrado na Figura 12.

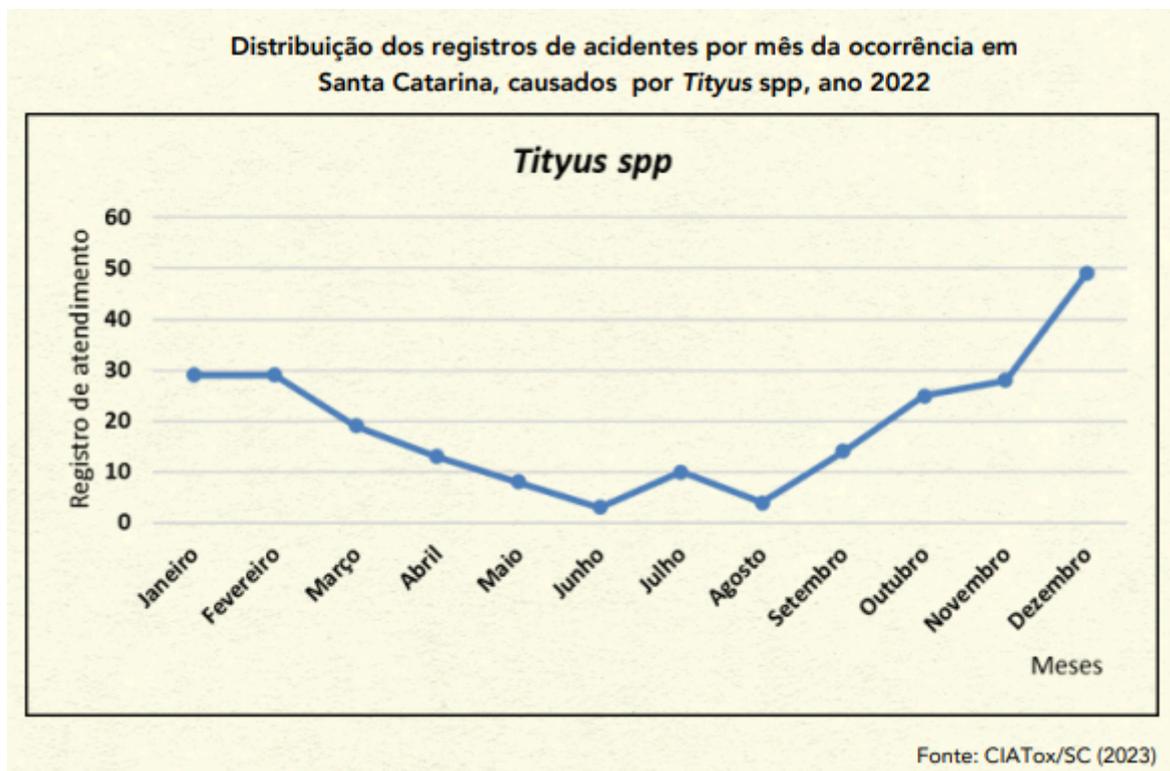


Figura 12: Ocorrências por mês em Santa Catarina em 2022 de *Tityus spp*.

No entanto, também existem espécies adaptadas a climas mais frios e temperados. No Brasil, foram relatados cerca de 547.000 casos de acidentes com escorpiões de 2014 a 2018, de acordo com o Sistema de Informação de Agravos de Notificação (SINAN), resultando em 466 casos fatais no mesmo período (Ministério da Saúde, 2018).

Animais peçonhentos são animais que, por meio de um mecanismo de defesa ou caça, são capazes de injetar em suas presas uma substância tóxica produzida por eles, através de glândulas especializadas (dente, ferrão, agulhão), por onde passa o veneno, o que denominamos de peçonha. As peçonhas podem ser compostas de diversas formas, sendo comum a presença de proteínas e peptídeos. A peçonha pode ser citotóxica, a qual afeta as células e tecidos, gerando necrose na região afetada, a hemotóxica, que afeta as células sanguíneas, gerando hemorragia interna, ou a miotóxica e a neurotóxica, que afetam os músculos e o sistema

nervoso, respectivamente. Segundo Cavalcanti (2018, citado por Manir, 2018), “O veneno do escorpião tem uma ação neurotóxica, afetando o sistema nervoso central”.

A fauna de escorpiões do Brasil é bastante vasta, destacando-se o gênero *Tityus*. Dados do Ministério da Saúde (2021) registraram em 2018, 141,4 mil casos de acidentes com escorpiões em todo o país. Em 2017, foram 125 mil registros de acidentes (Butantan, 2021).

No estado de Santa Catarina, a presença de escorpiões se tornou uma ameaça crescente nos últimos anos, gerando uma preocupação alarmante. Os dados do Centro de Informação e Assistência Toxicológica de Santa Catarina (CIATox/SC, 2023) revelam um aumento significativo nos casos de acidentes envolvendo escorpiões. Em 2021, os escorpiões representavam uma parcela de 3,58% (184 casos) em registros de ocorrências com animais peçonhentos no estado, no entanto, em 2022, os casos envolvendo escorpiões saltaram para 343, representando 7,7% dos chamados relacionados a animais peçonhentos. Os registros de acidentes por *Tityus* spp., o escorpião mais perigoso encontrado na região, aumentaram em 25,5% em 2022, com 231 casos registrados, em comparação com os 184 casos do ano anterior.

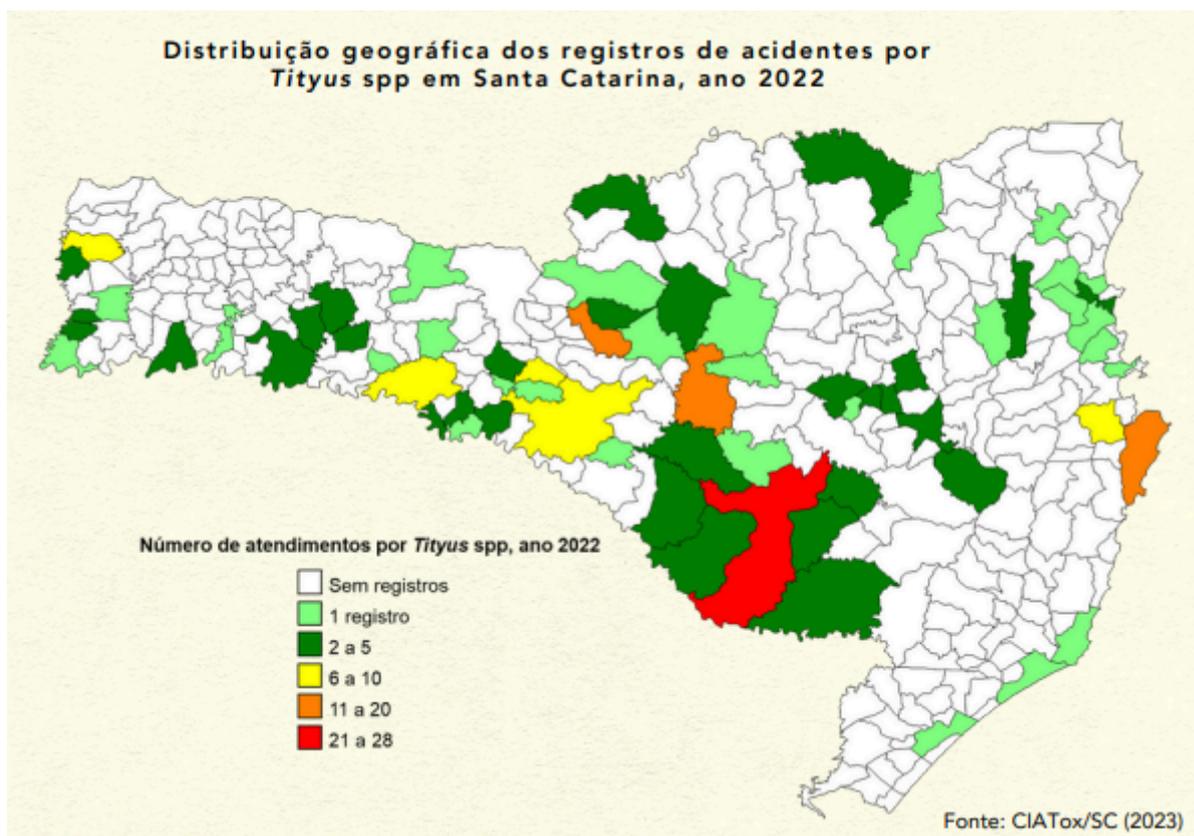


Figura 13: Distribuição dos acidentes com *Tityus* spp. em SC no ano de 2022. Fonte: (CIATox, 2023).

Esses números alarmantes revelam um cenário de risco em que os escorpiões estão cada vez mais presentes e representam uma ameaça real para a população de Santa Catarina. É fundamental que a população esteja ciente e tome medidas preventivas.

Há três escorpiões considerados de importância médica no estado, que correspondem ao gênero *Tityus* e pertencem à família Buthidae, encontrada principalmente na América Latina e no Caribe. O escorpião do gênero *Tityus* é considerado um dos mais venenosos do mundo, e suas espécies podem representar uma ameaça séria à saúde humana, principalmente em regiões onde há uma alta incidência desses animais.

2.4.1 *Tityus serrulatus*

O *Tityus serrulatus* é a espécie considerada a mais venenosa de toda América Latina, e como dito anteriormente, se encontra presente em todo o estado catarinense. É responsável pelo maior número de acidentes escorpiônicos no país.

Pela sua coloração, ganhou-se o apelido de escorpião-amarelo. Esta espécie é típica do sudeste e centro-oeste brasileiro, mas ultimamente vem ganhando amplitude nos estados e regiões brasileiras. Uma das características únicas desta espécie é sua habilidade de se reproduzir por partenogênese, o que permitiu sua rápida proliferação em todo o país (Pucca et. al., 2014). Em Santa Catarina, não esteve presente até a virada do último século, mas no ano de 2022, foi responsável por mais de 5% das ocorrências de *Tityus* spp. no estado de Santa Catarina (CIATox/SC, 2023).

A espécie *Tityus serrulatus* mede entre 6 e 7 cm, possui coloração marrom-escuro e pedipalpos e patas amareladas. A cauda, que também é amarelada, apresenta uma serrilha dorsal nos dois últimos segmentos e uma mancha escura no lado ventral da vesícula (Ministério da Saúde, 1999). É um animal endêmico frequente no Brasil e ocorre do estado da Bahia, Espírito Santo, Minas Gerais até o Rio de Janeiro, São Paulo, Paraná e Goiás, abrangendo as regiões Nordeste, Centro-Oeste e Sudeste (Ministério da Saúde, 1999).



Figura 14: *Tityus serrulatus*. Fonte: (Observado em Brasília, 2020 pelo usuário jbio, que publicou a imagem no site iNaturalist).

2.4.2 *Tityus costatus*

Tityus costatus costuma ter de 5 a 7 cm de comprimento, um colorido geral castanho amarelado e com manchas nas pernas e palpos. As espécies encontradas

na Região Sul apresentam uma coloração mais escura; presença de três faixas longitudinais na face dorsal do tronco e de um espinho sob o ferrão (Ministério da Saúde, 2009).

É a espécie que representa o maior número de chamados no estado no ano de 2022, representando 24,5% dos chamados envolvendo a *Tityus* spp. (CIATox/SC, 2023).



Figura 15: *Tityus costatus*. Fonte: (CIATox/SC, 2023)

2.4.3 *Tityus bahiensis*

O *Tityus bahiensis*, entre a espécie, é o que menos causa chamados no estado, representando apenas 2%, mas continua sendo de importância médica. Também chamado de escorpião-marrom, essa espécie tem o tronco escuro, pernas e palpos com manchas escuras e cauda marrom-avermelhado. Não possui serrilha na cauda, e mede cerca de 7 cm. O macho é diferenciado por possuir pedipalpos volumosos com um vão arredondado entre os dedos (Butantan, 2019).



Figura 16: *Tityus bahiensis*. Fonte: (CIATox/SC, 2023)

2.5 Classificação de Imagens com *Deep Learning*

2.5.1 Visão geral

Machine Learning (ML), ou Aprendizado de Máquina, é um subcampo da Inteligência Artificial que se dedica ao desenvolvimento de sistemas capazes de aprender e aprimorar seu desempenho a partir dos dados que processam (Oracle, 2014) e é ilustrado na Figura 17. É o campo de estudo de IA que desenvolve algoritmos e técnicas que permitem aos computadores aprenderem a partir dos dados, sem serem explicitamente programados (Russel; Norvig, 2021).

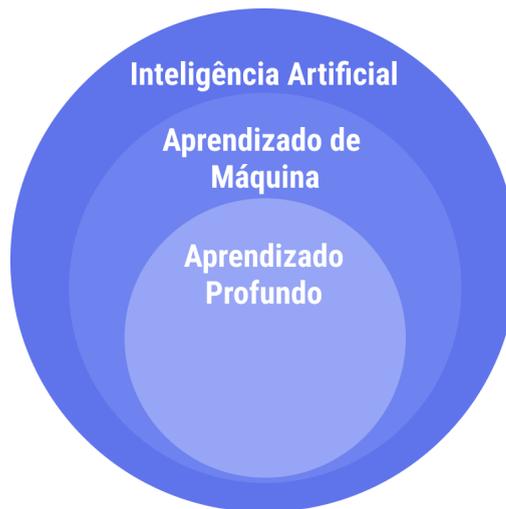


Figura 17: Diagrama de Venn ilustrando o campo da inteligência artificial. Fonte: (Goodfellow, 2016 (adaptado pelo autor))

O *ML* utiliza diversas técnicas, incluindo redes neurais artificiais. De acordo com o estudo de Haykin (2016), estas redes são modelos computacionais inspirados no funcionamento do sistema neural humano capazes de aprender com experiências anteriores e identificar padrões. As redes neurais são estruturadas em camadas: a camada de entrada, uma ou mais camadas ocultas, e a camada de saída. Cada neurônio está interligado, com associações de peso e valor, formando a rede. O resultado da aplicação de um algoritmo de aprendizado em um conjunto de dados é chamado de modelo.

Na Figura 18 é ilustrado um neurônio biológico e assim como os neurônios biológicos, os neurônios em RNAs transmitem informações através de conexões, processando e transmitindo sinais que resultam no aprendizado e na tomada de decisões pelo modelo.

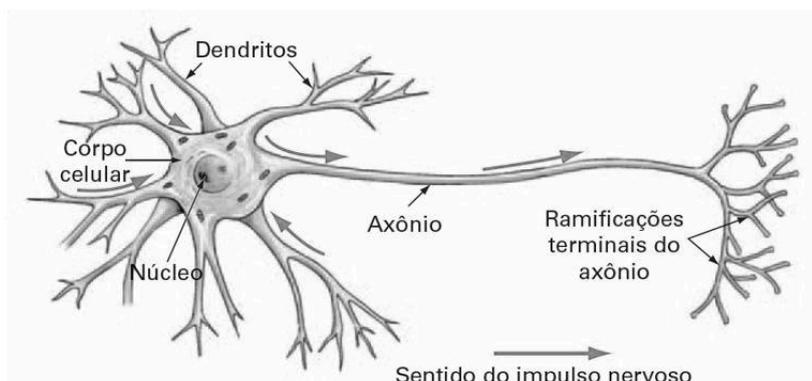


Figura 18: Estrutura típica de neurônio. Fonte: (DSA, 2018)

Modelos gerados por algoritmos de *ML* visam melhorar sua aprendizagem e precisão na resolução de problemas à medida que processam mais dados. Um modelo é treinado utilizando dados, como por exemplo imagens, e após o treinamento, pode realizar previsões sobre como as características de um exemplo se comportarão em determinados cenários, mesmo para valores não presentes nos dados de treinamento.

Nesse contexto, o *DL* é caracterizado pelo uso de redes neurais profundas, o que melhorou drasticamente o estado da arte em áreas de reconhecimento de imagens (LeCun et al., 2015). O *DL* usa camadas de neurônios matemáticos para processar dados, compreender a fala humana e reconhecer objetos visualmente. A informação é passada através de cada camada, com a saída da camada anterior fornecendo entrada para a próxima camada. A primeira camada em uma rede é chamada de camada de entrada, enquanto a última é chamada de camada de saída. Todas as camadas entre as duas são referidas como camadas ocultas. Cada camada é tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação (DSA, 2018).

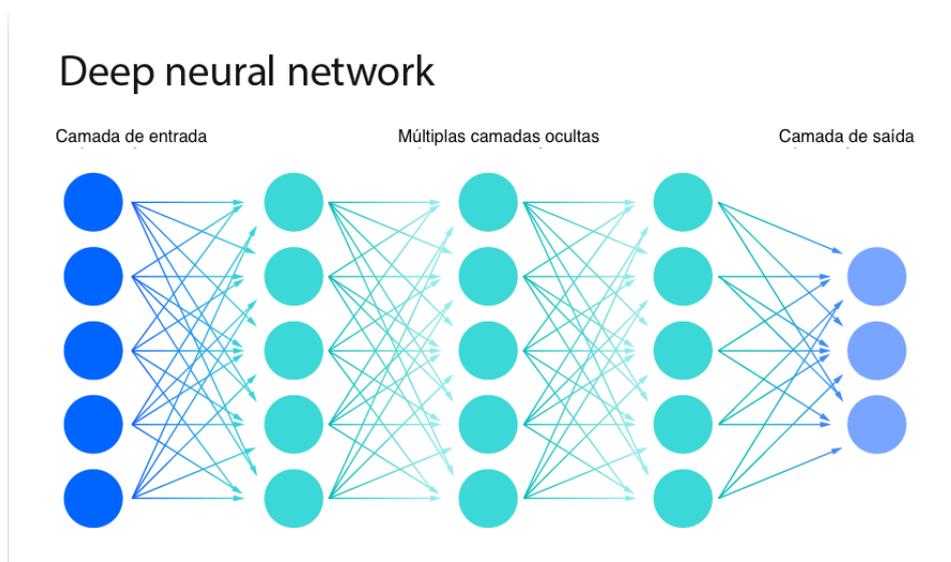


Figura 19: Estrutura e camadas de uma rede neural profunda. Fonte: (IBM Cloud Computing, 2020 (adaptado pelo autor))

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

A classificação de imagens é a capacidade de um modelo de *DL* analisar uma imagem e identificar a “classe” à qual a imagem pertence, ou fornecer uma probabilidade de a imagem pertencer a essa classe. Uma classe é essencialmente um rótulo, como ‘mês’, ‘cor’ ou ‘escorpião’.

Existem diferentes tipos de classificação de imagens: *Single-Label* e *Multi-Label*. A diferença entre os dois tipos reside no número de classes que um objeto ou exemplo pode ter. Na classificação *Single-Label*, cada objeto é vinculado exclusivamente a um único rótulo de um conjunto pré-definido. Por exemplo, ao identificar espécies de animais, cada imagem é classificada como uma única espécie. Em contraste, a classificação *Multi-Label* permite que uma única imagem seja associada a múltiplas classes simultaneamente. Por exemplo, um modelo que prevê quais peças de roupa uma pessoa está usando deve utilizar a classificação *Multi-Label*, já que pode haver vários itens de vestuário na mesma imagem, como ‘camisa’, ‘calça’ e ‘chapéu’.

Também existem várias abordagens para aprendizagem, entre elas a aprendizagem supervisionada. Na aprendizagem supervisionada os dados usados para o treinamento são rotulados indicando a classe de cada um dos artefatos de entrada. Um modelo de classificação consiste em separar os dados em várias classes categóricas, dando significado aos dados e rotulando-os de acordo com alguns parâmetros que o modelo analisa.

2.5.2 Processo de desenvolvimento de modelos de *deep learning* para classificação de imagens

O desenvolvimento de modelos de *DL* deve seguir um processo sistemático, conforme ilustrado na Figura 20 com base nos estudos de Gresse von Wangenheim e von Wangenheim (2021).

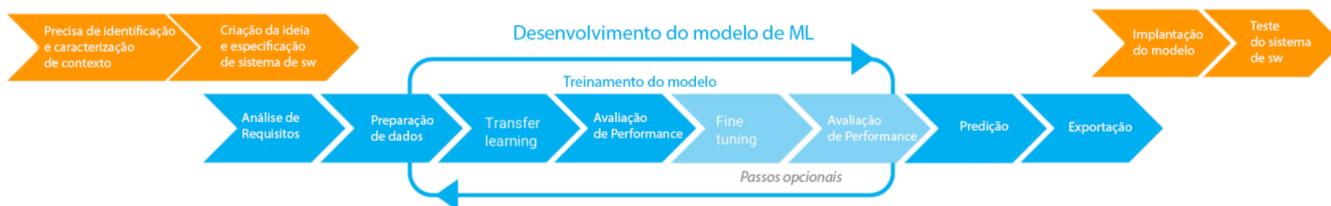


Figura 20: Visão geral do processo iterativo de *ML* centrado em humanos; Fonte: (Gresse von Wangenheim e von Wangenheim, 2021)

A primeira etapa desse processo é a análise de requisitos, onde se especifica o objetivo principal do modelo de *DL* e suas características alvo, incluindo a caracterização das entradas e saídas esperadas, os riscos e o desempenho esperado. Em seguida, ocorre a preparação de dados, onde os dados que serão consumidos pelo algoritmo são coletados, limpos e preparados. Isso pode envolver o uso de um conjunto de dados existente ou a coleta própria dos dados. Após a coleta, é necessário limpar os dados, removendo informações incorretas e/ou repetidas. Nas abordagens de aprendizagem supervisionada, os dados são rotulados e divididos em conjunto de treinamento, conjunto de validação e conjunto de teste, cada um com seu papel específico no desenvolvimento do modelo.

A etapa de treinamento do modelo envolve o algoritmo de aprendizado de máquina adquirindo conhecimento a partir de um conjunto de dados de treinamento para identificar padrões e criar um modelo que capture essas relações (Chollet, 2016).

Como é difícil obter um conjunto de dados suficientemente grande, raramente as redes neurais convolucionais (CNNs) são treinadas do zero. Além disso, CNNs muito profundas são extremamente caras para serem treinadas. Os modelos mais complexos podem levar uma semana para treinar, utilizando centenas de GPUs de alto custo (Meazzini, 2019). O *Transfer Learning* pode ser utilizado para reduzir o tempo de treinamento, aproveitando modelos pré-treinados com conjuntos menores de imagens (Chollet, 2016). Esse processo envolve o pré-treinamento do modelo com imagens, como as ResNets 18 e 34, utilizando conjuntos de dados como o Imagenet (He, 2015). Para melhorar ainda mais o desempenho, o *Fine-Tuning* ajusta o modelo pré-treinado ao reorganizar as camadas da rede e treiná-lo novamente para uma tarefa similar (Guo et al., 2019).

Durante o treinamento, o desempenho é avaliado utilizando métricas como a função de perda (*loss function*) e a taxa de erro (*error rate*). A função de perda mede a distância entre a saída atual do algoritmo e a saída esperada, enquanto a taxa de erro representa a proporção de imagens classificadas incorretamente. Essas métricas ajudam a avaliar a eficácia e o progresso do modelo durante o treinamento.

Após o treinamento, é necessário avaliar o desempenho do modelo. Existem diversas ferramentas que ajudam a calcular e visualizar as métricas utilizadas para avaliar os modelos de *ML*, sendo a mais comum em problemas de classificação, a matriz de confusão. As medidas mais comuns neste caso são as de acurácia geral, que é a proporção de classificações corretas em relação ao total de exemplos, a acurácia por categoria, que avalia o desempenho do modelo em cada classe específica e outras métricas importantes, que incluem a precisão e recall, onde a precisão é a proporção de exemplos classificados corretamente como positivos em relação ao total de exemplos positivos, e o recall é a proporção de exemplos positivos reais identificados corretamente pelo modelo. O *F1-score*, que é a média harmônica entre precisão e *recall*, também é amplamente utilizado para avaliar o equilíbrio entre essas duas medidas (Escovedo, 2020).

Após o modelo ser treinado com dados históricos, ele pode ser usado para tomar decisões (realizar inferências) em novos dados que não foram vistos durante o treinamento. É possível que o modelo performe bem nos dados históricos, mas falhe em tomar boas decisões em dados inéditos. Quando isso ocorre, acontece o *overfitting*, indicando que o modelo não se generaliza bem para novos dados. Se o modelo não consegue tomar boas decisões nem mesmo nos dados de treinamento, ocorre o *underfitting*, e pode ser necessário utilizar um modelo mais complexo. O termo "predição" pode ser usado como sinônimo de "inferência" (Gessoni, 2021).

Finalmente, na implantação do modelo, o modelo treinado e exportado é utilizado em artefatos computacionais, como aplicações web ou móveis, para ser operacionalizado e gerar valor em contextos reais.

2.5.3 Tipos de redes neurais para classificação de imagens

As Redes neurais convolucionais (ConvNets ou CNNs) são redes neurais artificiais profundas que podem ser usadas para classificar imagens, agrupá-las por

similaridade (busca de fotos) e realizar reconhecimento de objetos dentro de cenas. São algoritmos que podem identificar rostos, indivíduos e muitos outros aspectos dos dados visuais (DSA, 2018). 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; Pereira, 2018). As redes convolucionais percebem imagens como volumes; isto é, objetos tridimensionais, em vez de estruturas planas a serem medidas apenas por largura e altura. Isso porque as imagens de cores digitais têm uma codificação vermelho-verde-azul (*RGB – Red-Green-Blue*), misturando essas três cores para produzir o espectro de cores que os seres humanos percebem. Uma rede convolucional recebe imagens como três estratos separados de cores empilhadas uma em cima da outra (DSA, 2018), como exemplado na Figura 21.

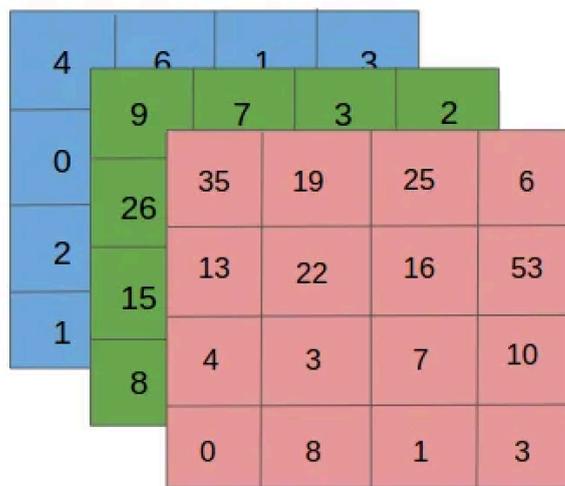


Figura 21: Exemplo de matrizes tridimensionais recebidas pelas CNNs. Fonte: (Alves, 2018 (adaptado pelo autor))

No contexto das CNNs, a entrada inicialmente é processada por meio de camadas convolucionais. Essas camadas aplicam um conjunto de filtros (*kernels*) de tamanho reduzido em diferentes regiões da entrada, em vez de processar todos os dados de uma vez. Esses filtros têm dimensões menores do que os dados de entrada, permitindo que eles se movam através dos dados, capturando padrões locais. Em cada posição, o filtro calcula um produto escalar entre si e a região

correspondente da entrada, gerando um único valor na saída, conhecido como mapa de características. O deslocamento do filtro ao longo da entrada é chamado de operação de convolução. Este processo é caracterizado pela sobreposição das regiões de entrada, onde cada pixel na saída é influenciado por uma região da entrada, mas também compartilha informações com pixels adjacentes. Isso resulta em uma representação hierárquica dos dados, onde características simples são detectadas nas camadas iniciais, enquanto características mais complexas são combinadas em camadas posteriores.

Além das camadas convolucionais, as CNNs também incluem camadas de *pooling*. Estas camadas são responsáveis por reduzir o tamanho da entrada antes que a informação siga adiante para uma camada totalmente conectada, enquanto mantém as características mais relevantes. Operações comuns de *pooling* incluem o *max pooling*, onde uma janela deslizante é aplicada aos mapas de características, e apenas o valor máximo dentro dessa janela é preservado, e o *average pooling*, ou *pooling* médio, que realiza a redução de tamanho dividindo o mapa de características em regiões e calcula a média de cada região. As CNNs também contam com camadas totalmente conectadas. Essas camadas recebem os dados processados pelas camadas anteriores e são responsáveis por realizar a classificação ou a regressão final com base nessas características extraídas.

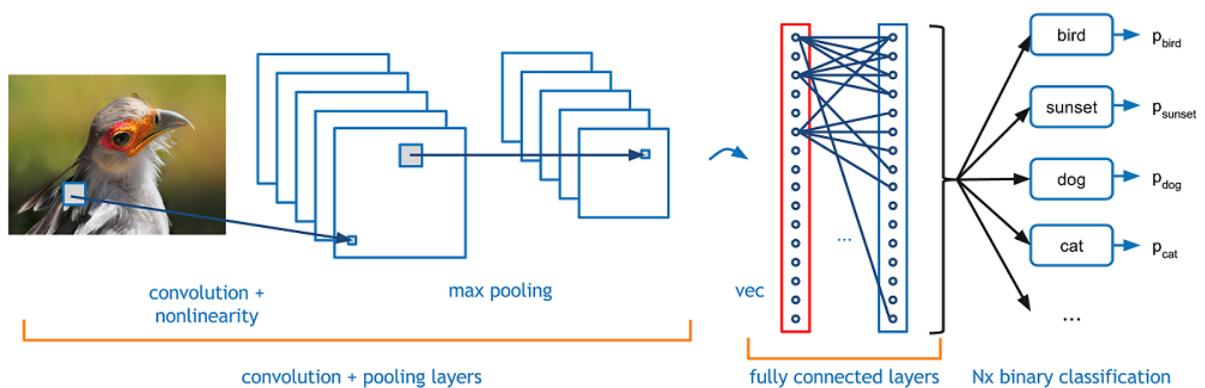


Figura 22: Fluxo de classificação de uma rede neural convolucional. Fonte: (Deshpande, 2016)

Na fase de treinamento, o processo de *backpropagation* é empregado para ajustar os pesos da rede, minimizando a função de perda. Durante a fase de propagação para frente (*forward propagation*), os dados são passados pela rede, camada por camada, até que a saída final seja gerada. Em seguida, a diferença

entre a saída prevista e a saída verdadeira é calculada através da função de perda.

Na fase de retropropagação (*backpropagation*), esse erro é propagado de volta através da rede, ajustando gradualmente os pesos de todas as camadas para minimizar a função de perda.

A combinação de camadas convolucionais e de *pooling* permite que as CNNs capturem eficientemente informações espaciais e hierárquicas nos dados de entrada, tornando-as particularmente eficazes em tarefas de processamento de imagens. A Figura 23 ilustra a arquitetura básica de uma CNN, destacando as camadas convolucionais e de pooling em sua estrutura.

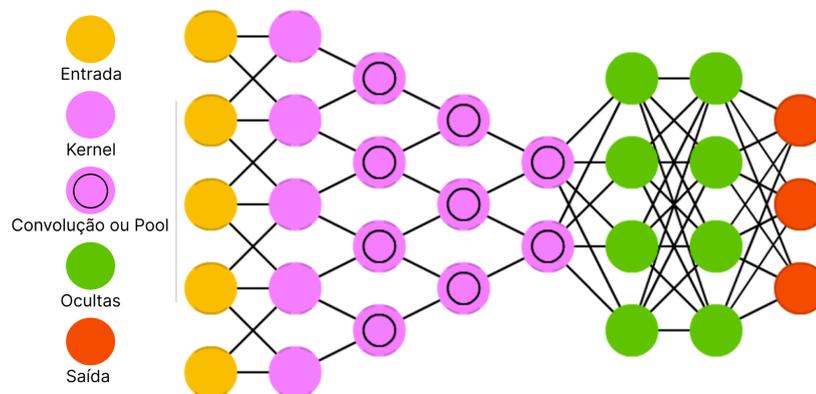


Figura 23: Estrutura e camadas de uma rede neural profunda. Fonte: (Van Veen, 2016 (adaptado pelo autor))

2.5.3.1 ResNets

As Redes Neurais Residuais (ResNets) são arquiteturas empregadas em tarefas de visão computacional, como a detecção de objetos e classificação de imagens. Em comparação com outras redes convolucionais, como VGG, GoogleNet e Inception, as ResNets representaram um marco importante no campo do aprendizado profundo (He et al., 2015).

As CNNs enfrentam um problema conhecido como gradiente de fuga, no qual os gradientes calculados durante o treinamento diminuem drasticamente nas camadas iniciais. Isso dificulta o aprendizado nessas camadas e afeta a precisão da rede, aumentando o erro de treinamento e reduzindo sua capacidade de generalização. As ResNets resolvem esse problema adicionando conexões especiais que permitem que os gradientes fluam diretamente das camadas finais para as camadas iniciais, facilitando o treinamento e melhorando a precisão da rede.

A principal inovação das ResNets é a introdução de conexões residuais, ou conexões de salto, que permitem que os gradientes fluam diretamente das camadas finais para as camadas iniciais da rede. Isso ajuda a mitigar o desaparecimento do gradiente, tornando o treinamento de redes muito mais profundas, mais eficiente e eficaz.

Existem muitas variantes da arquitetura ResNet, ou seja, a mesma arquitetura mas com uma quantidade diferente de camadas, como p.ex. ResNet-18, ResNet-34, ResNet-50, ResNet-101, etc. 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. As ResNets foram projetadas para superar a degradação de desempenho, permitindo a adição de camadas sem que haja queda expressiva na precisão do modelo, logo, na construção de redes mais profundas.

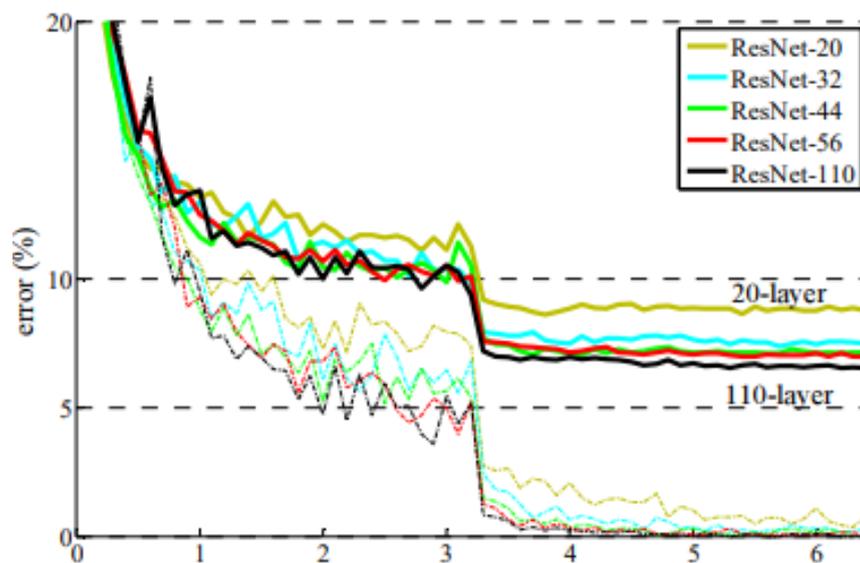


Figura 24: Arquiteturas e desempenhos das ResNets com o ImageNet. Fonte: (He et al., 2015).

As ResNets são construídas a partir de algo chamado bloco residual, um bloco fundamental que revolucionou a maneira como as redes neurais são construídas (Raghuvanshi, 2024). Este bloco consiste em uma conexão de salto que aprende funções residuais com base nos inputs da camada. Ao contrário das camadas convolucionais tradicionais, que tentam aprender um mapeamento direto do input para o output, os blocos residuais aprendem a diferença entre o input e o output, conhecida como mapeamento de identidade. A Figura 25 mostra uma

visualização da conexão de atalho, que contribui para a eficiência da rede em treinamentos mais profundos.

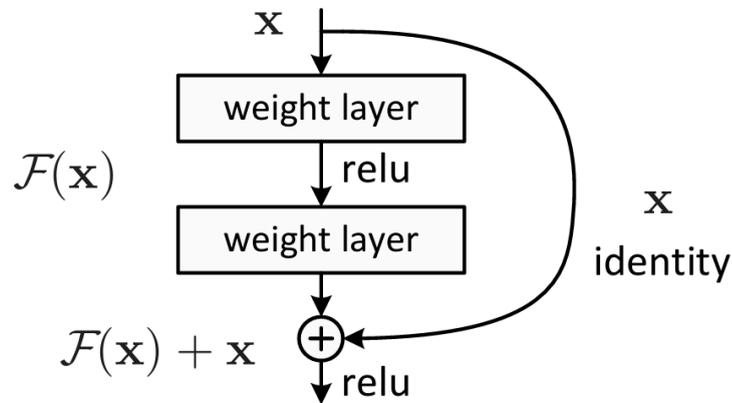


Figura 25: Exemplo de um bloco residual. Fonte: (He et al., 2015)

Normalmente, para modelos integrados a aplicativos móveis, são utilizados ResNet-18 e ResNet-34 devido ao bom desempenho e custo computacional compatível com o processamento encontrado em *smartphones*.

2.5.3.2 MobileNet

MobileNet (Howard et al., 2017) é uma rede neural convolucional simples, mas eficiente e não muito intensiva em termos computacionais, projetada para aplicações de visão em dispositivos móveis (Srudeep, 2020).

A rede MobileNet, diferente das arquiteturas convencionais, se concentra em reduzir a complexidade computacional sem comprometer o desempenho. Em seu núcleo, essa arquitetura introduz duas operações-chave: convolução separável em profundidade e projeção (Muzammil, 2023). As convoluções tradicionais realizam a convolução espacial em cada canal de entrada, resultando em um ônus computacional significativo. Já as convoluções separáveis em profundidade dividem a convolução em duas operações distintas: convolução em profundidade e convolução ponto a ponto, como ilustrado na Figura 26, já as convoluções tradicionais realizam a convolução espacial em cada canal de entrada, resultando em um ônus computacional significativo. Segundo Howard et al. (2017), essa fatoração tem um efeito de redução drástica da computação e do tamanho do modelo.

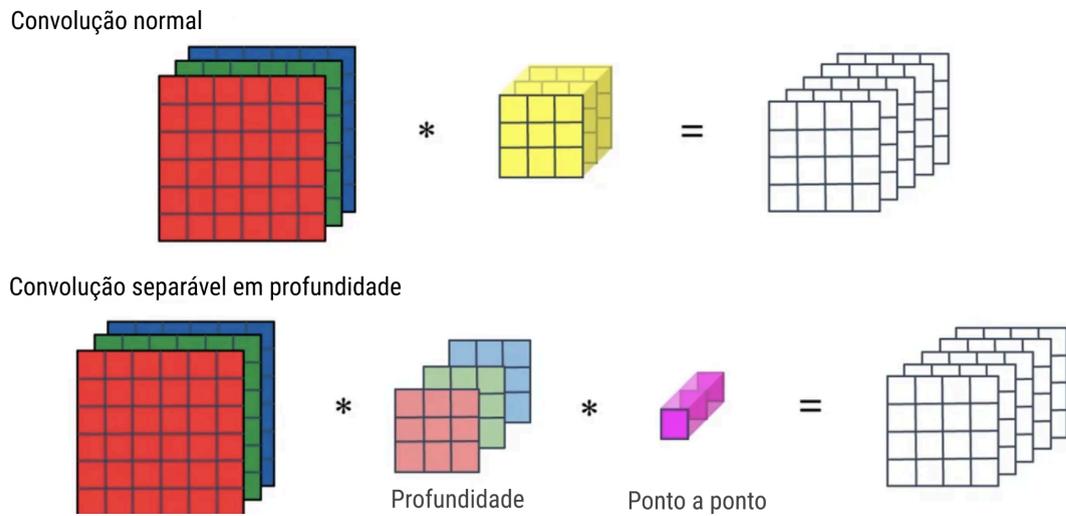


Figura 26: Diferenças das etapas em redes convolucionais tradicionais e de separáveis em profundidade. Fonte: (Muzammil, 2023 (adaptado pelo autor))

Além da versão original do MobileNet, conhecida como MobileNetV1, existem as versões MobileNetV2 e MobileNetV3. A MobileNetV2 é uma versão atualizada da V1 que a torna ainda mais eficiente e poderosa em termos de desempenho (Dwivedi, 2019). A MobileNetV3, por outro lado, faz uso do *AutoML* para otimizar a arquitetura do modelo para aplicações de visão computacional móvel. Ela incorpora avanços como a não linearidade *h-swish* e camadas de *squeeze-and-excitation*, além de ajustes finos nos blocos de construção principais da rede. Isso resulta em uma arquitetura ainda mais eficiente em termos de computação e memória (Pochetti, 2023).

2.5.3.3 EfficientNet

A EfficientNet (Tan; Le, 2020) é uma rede eficiente desenvolvida pela Google Research utilizando a tecnologia de busca de arquitetura de redes neurais (Li et al., 2022). A EfficientNet é uma arquitetura de CNN e um método de escalonamento que aumenta uniformemente as dimensões de profundidade, largura e resolução (Figura 27) usando um coeficiente composto. Diferentemente da prática convencional que escala esses fatores de maneira arbitrária, o método de escalonamento da EfficientNet aumenta uniformemente as dimensões da rede com um conjunto de coeficientes de escalonamento fixos.

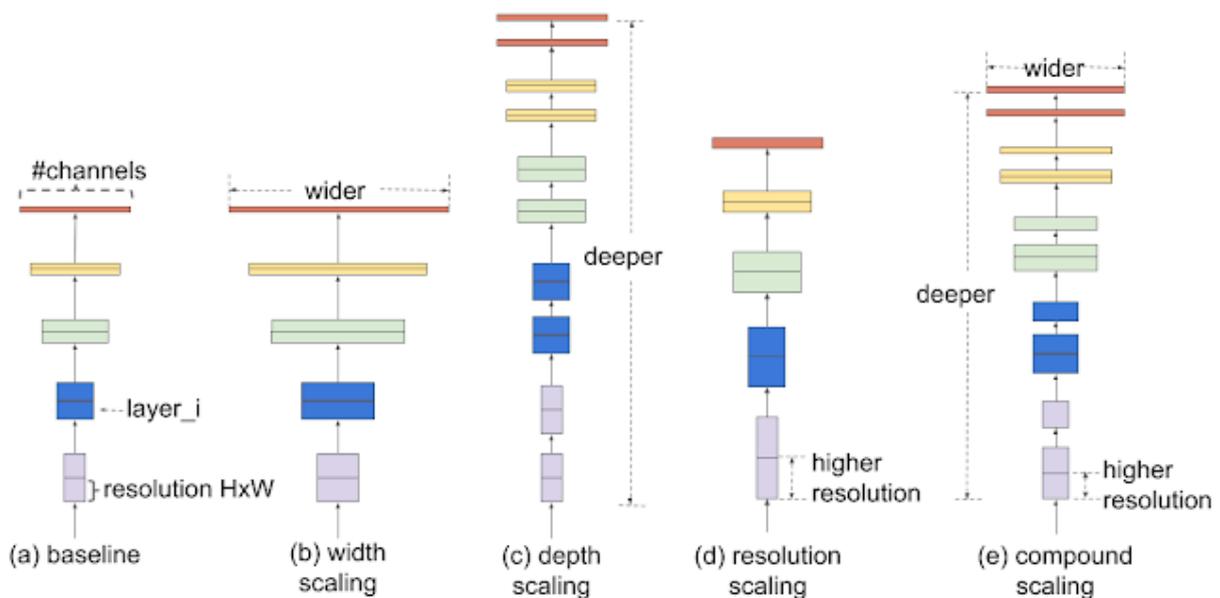


Figura 27: Diferentes métodos de dimensionamento. Fonte: (Tan, 2020).

A arquitetura da EfficientNet é baseada na rede de linha de base desenvolvida pela busca de arquitetura neural usando o framework *AutoML MNAS*. A rede é ajustada para obter máxima precisão, mas também é penalizada se for muito pesada computacionalmente (Sarkar, 2021). O EfficientNet utiliza camadas *Mobile inverted bottleneck convolution* (MBConv), que são uma combinação de convoluções separáveis em profundidade e blocos residuais invertidos. Além disso, a arquitetura do modelo também utiliza a otimização *Squeeze-and-Excitation* para aprimorar ainda mais o desempenho do modelo (Li et al., 2022). A camada MBConv é um bloco fundamental da arquitetura EfficientNet. Ela é inspirada nos blocos residuais invertidos do MobileNetV2, mas com algumas modificações (Potrimba, 2023).

Existem diversas versões do EfficientNet. Atualmente consistem em 8 variações de B0 a B7, onde cada número de modelo subsequente refere-se a variantes com mais parâmetros e maior precisão (Ahmed; Sabab, 2021).

Posteriormente foi concebida uma rede mais adequada para dispositivos móveis, chamada de EfficientNet-Lite, que roda a partir do TensorFlow Lite, introduz funções de ativação ReLU6, e remove a lógica de blocos *Squeeze-and-Excitation*.

Este modelo oferece cinco variantes. Isso permite escolher entre uma versão que prioriza menor latência e tamanho do modelo, como o EfficientNet-Lite0, ou uma versão que busca maior precisão, como o EfficientNet-Lite4.

Na Figura 28, são apresentados os resultados da classificação de imagens no conjunto de dados ImageNet, com métricas de top-1 e top-5.

MODEL	TOP 1 ACCURACY	TOP 5 ACCURACY
tf_efficientnet_lite4	81.54%	95.66%
tf_efficientnet_lite3	79.83%	94.91%
tf_efficientnet_lite2	77.48%	93.75%
tf_efficientnet_lite1	76.67%	93.24%
tf_efficientnet_lite0	74.83%	92.17%

Figura 28: Resultados da classificação de imagens no ImageNet. Fonte: (Tan; Le, 2019).

2.5.3.4 Comparação do desempenho padrão de modelos

O desempenho de modelos de classificação de imagens é frequentemente avaliado usando várias métricas, sendo as mais comuns a acurácia, precisão, recall e F1 Score. Essas métricas são calculadas com base nos diferentes tipos de erros, comparando os valores previstos com os valores reais. Os principais componentes utilizados para essas métricas são: Verdadeiro Positivo (VP), Falso Positivo (FP), Verdadeiro Negativo (VN) e Falso Negativo (FN).

Verdadeiro Positivo (VP): Representa uma instância que foi corretamente prevista como positiva. Por exemplo, um escorpião da espécie *Tityus serrulatus* que foi corretamente classificado como *Tityus serrulatus*.

Verdadeiro Negativo (VN): Refere-se a uma instância que foi corretamente prevista como negativa. Por exemplo, um escorpião da espécie *Tityus bahiensis* que foi corretamente identificado como não sendo um *Tityus bahiensis*.

Falso Positivo (FP): Indica uma instância que foi incorretamente prevista como positiva. Por exemplo, um escorpião que foi classificado como *Tityus serrulatus* (peçonha letal), mas na verdade pertence a uma espécie que não possui peçonha mortal para humanos.

Falso Negativo (FN): Representa uma instância que foi incorretamente prevista

como negativa. Por exemplo, um escorpião que foi classificado como não letal, mas na verdade é da espécie *Tityus costatus* (peçonha letal).

Essas métricas são frequentemente visualizadas através de uma matriz de confusão, uma ferramenta visual que permite observar os possíveis erros do modelo treinado (Figura 29).

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

Figura 29: Exemplo de matriz de confusão. Fonte: (Scudilio, 2020).

A **acurácia** pode ser calculada pela proporção de classificações corretas, tanto positivas quanto negativas, em relação ao total de classificações (Figura 30).

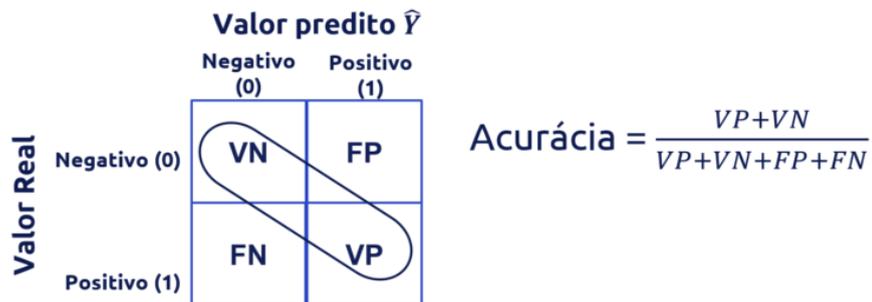


Figura 30: Método de acurácia. Fonte: (Scudilio, 2020)

A **precisão** é a proporção de instâncias corretamente classificadas como positivas em relação ao total de instâncias classificadas como positivas (Figura 31).

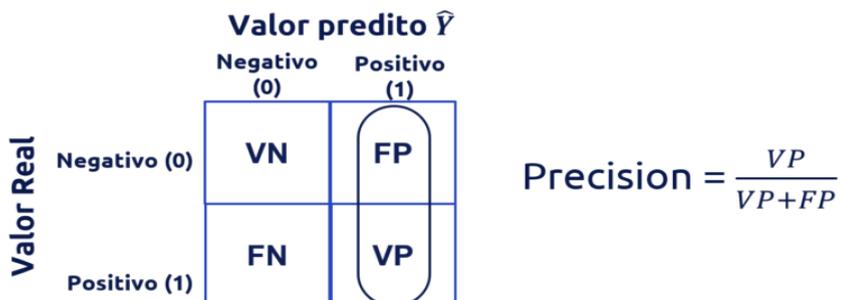


Figura 31: Método de precisão. Fonte: (Scudilio, 2020).

O **recall** é a proporção de instâncias corretamente classificadas como positivas em

relação ao total de instâncias que deveriam ser classificadas como positivas (Figura 32).

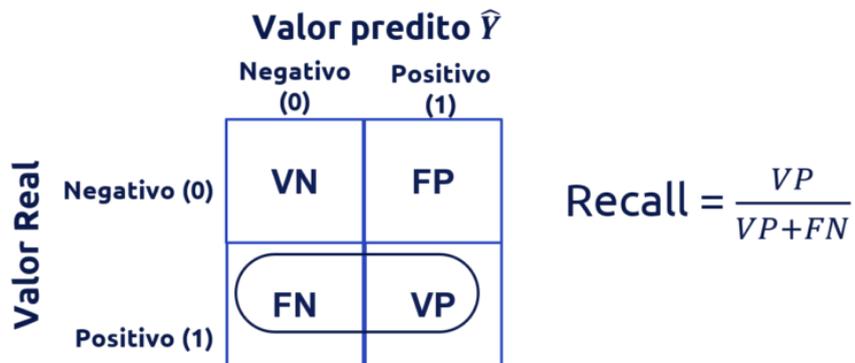


Figura 32: Método de recall. Fonte: (Scudilio, 2020).

O **F1-Score** é calculado como a média harmônica entre o recall e a precisão, fornecendo uma única métrica que balanceia ambos os aspectos (Figura 33).

$$\text{F1-Score} = \frac{2 * (\textit{precision} * \textit{recall})}{\textit{precision} + \textit{recall}}$$

Figura 33: Métrica de F1-Score. Fonte: (Scudilio, 2020).

A Figura 34 apresenta uma comparação dos desempenhos dos principais modelos de CNNs utilizando a base de dados ImageNet. O modelo EfficientNet-B7 obteve o melhor desempenho, com aproximadamente 84,4% de precisão top-1 e 97,3% de precisão top-5 no ImageNet.

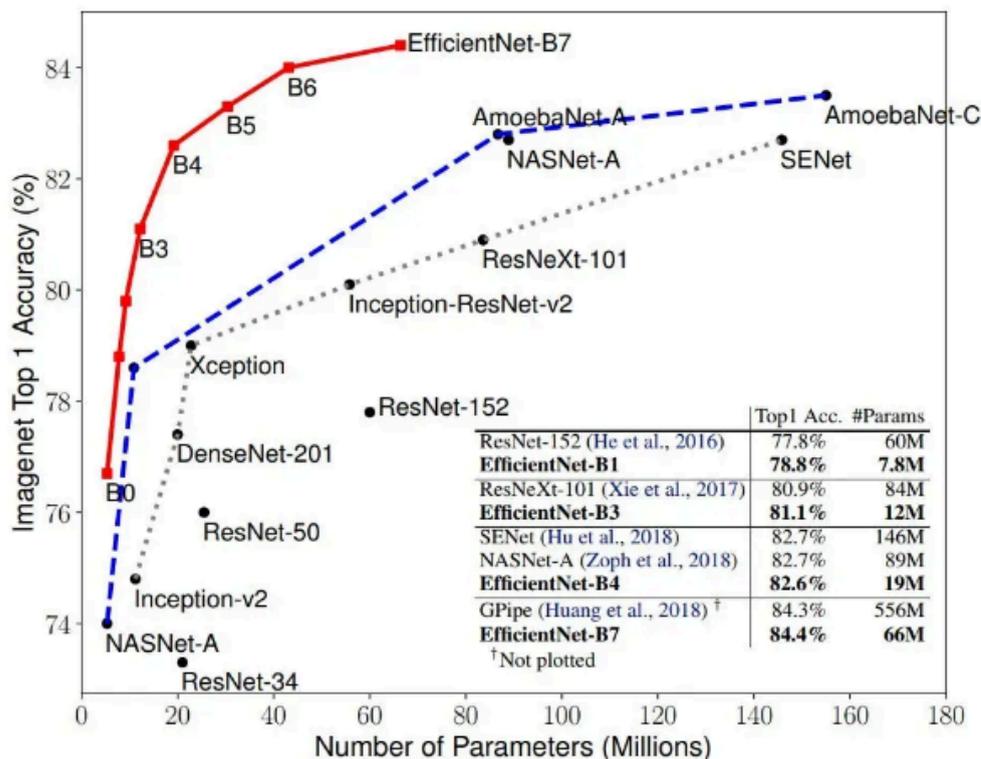


Figura 34: Tamanho dos modelos vs. Acurácia. Fonte:(Potrimba, 2023).

Segundo o gráfico comparativo, a EfficientNet-B7 se destaca tanto pela precisão quanto pela eficiência. A EfficientNet-B7, com 66 milhões de parâmetros, apresenta um desempenho superior ao de outros modelos, como a ResNet-152, que possui 60 milhões de parâmetros. Essa eficiência é alcançada graças à tecnologia de dimensionamento composto implementada no modelo, permitindo projetar imagens de forma mais eficaz e com menor custo computacional. No entanto, deve-se considerar que modelos com muitas camadas, como EfficientNet-B7, ResNet-152 ou ResNet-50, podem não ser ideais para dispositivos com recursos limitados, como aparelhos móveis, devido ao seu tamanho e complexidade de adaptação.

Para dispositivos móveis, modelos mais leves como EfficientNet-B0, EfficientNet-Lite, ResNet-34, ResNet-18 e MobileNetV2 são mais adequados, pois possuem menos camadas e, portanto, são mais fáceis de implementar nesses dispositivos (Espíndola, 2023). A Figura 27 ilustra o desempenho dos modelos EfficientNet-Lite, MobileNetV2 e ResNet-50 em relação ao seu tamanho.

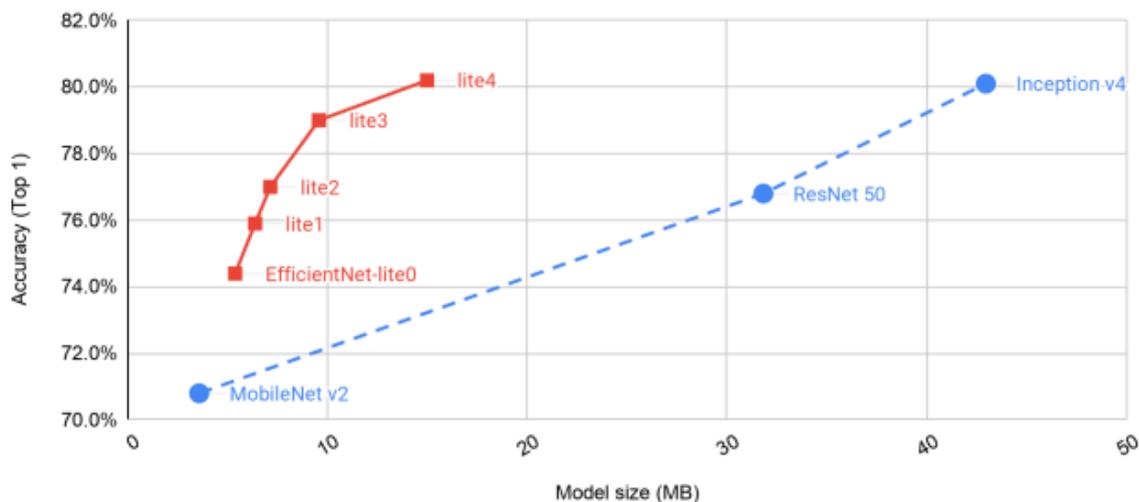


Figura 35: Comparação da acurácia e tamanho de modelos; Fonte: (Liu, 2020)

De acordo com o gráfico, as versões da EfficientNet-Lite apresentam um desempenho robusto, mas o modelo mais portátil é o MobileNetV2 (Figura 35), que oferece um bom equilíbrio entre desempenho e eficiência para dispositivos móveis.

3 ESTADO DA ARTE

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

3.1 Definição do Protocolo de Revisão

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

- AQ1. Quais pesquisas existem em termos de classificação e quais as espécies classificadas?
- AQ2. Como é formado o conjunto de dados e quantas imagens possui?
- AQ3. Quais e como os modelos foram treinados?
- AQ4. Quais os desempenhos relatados?

Critérios de inclusão/exclusão. Foram consideradas somente pesquisas voltadas para a classificação de escorpiões a partir de imagens. Foram excluídas pesquisas não focadas em imagens de espécies de escorpiões, além de pesquisas sobre animais peçonhentos no geral, como aranhas, serpentes, etc. Não foram consideradas também pesquisas que enfocam em outras tarefas a não ser classificação de imagens (detecção de objetos, uso de vídeos, etc.). Foram considerados somente trabalhos publicados nos últimos 10 anos.

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

Fontes dos dados. Foram examinados todos os materiais e artigos publicados em inglês e português disponíveis no *ACM Digital Portal*, *IEEE*, *Scopus* sendo das mais importantes bibliotecas digitais acessíveis por meio do Portal Capes. Foi também realizada uma busca via *Google Scholar*, por indexar um grande conjunto de dados de diferentes fontes (Haddaway *et al.* 2015), já que nessa área emergente não foram necessariamente publicados artigos científicos das extensões criadas.

Definição da *string* de busca. A *string* de busca foi composta de conceitos relacionados à questão de pesquisa, incluindo sinônimos para minimizar o risco de omissão (Tabela 3).

Tabela 3: Termos de busca utilizados no protocolo de revisão

Termo	Sinônimo
Escorpião	Scorpion, Scorpio, "Tityus Bahiensis", "Tityus Costatus", "Tityus Serrulatus", "Bothriurus"
Deep learning	"Machine Learning", "Artificial Intelligence", "Image classification", "Image recognition", "Neural network", "Convolutional network"

A partir disso foi gerada a seguinte *string* de busca genérica:

(Scorpion OR Scorpio OR "Tityus Bahiensis" OR "Tityus Costatus" OR "Tityus Serrulatus" OR Bothriurus) AND ("Deep learning" OR "Machine Learning" OR "Artificial Intelligence" OR "Image classification" OR "Image recognition" OR "Neural network" OR "Convolutional network").

A string de busca genérica foi adaptada para cada fonte de dados conforme apresentada na Tabela 4. O Google Scholar, por ter um motor de busca booleana com indexações diferentes dos algoritmos de referências, como IEEE, ACM e Scopus, foram realizadas quatro buscas distintas, relacionando termos padrões da pesquisa com o sinônimo “*Scorpion*”.

Tabela 4 - *String* de busca para cada fonte

Fonte	String de busca
ACM	[[[Abstract: scorpio] OR [Abstract: scorpion] OR [Abstract: "tityus bahiensis"] OR [Abstract: "tityus costatus"] OR [Abstract: "tityus serrulatus"] OR [Abstract: Bothriurus]] AND [[Abstract: "machine learning"] OR [Abstract: "artificial intelligence"] OR [Abstract: "image classification"] OR [Abstract: "image recognition"] OR [Abstract: "neural network"] OR [Abstract: "convolutional network"]]] OR [All:))] AND [E-Publication Date: (01/01/2013 TO 12/31/2023)]
IEEE	("Abstract":Scorpio OR "Abstract":Scorpion OR "Abstract":"tityus bahiensis" OR "Abstract":"tityus costatus" OR "Abstract":"tityus serrulatus" OR "Abstract": "Bothriurus") AND ("Abstract": "Deep learning" OR "Abstract": "Machine Learning" OR "Abstract": "Artificial Intelligence" OR "Abstract": "Image classification" OR "Abstract": "Neural network" OR "Abstract": "Convolutional network") Filters Applied: 2013 - 2023
Scopus	(TITLE-ABS-KEY (scorpion) OR TITLE-ABS-KEY (scorpio) OR TITLE-ABS-KEY ("tityus bahiensis") OR TITLE-ABS-KEY ("tityus costatus") OR TITLE-ABS-KEY ("tityus serrulatus") OR TITLE-ABS-KEY (Bothriurus) AND TITLE-ABS-KEY ("machine learning") OR TITLE-ABS-KEY ("Artificial Intelligence") OR TITLE-ABS-KEY ("image classification") OR TITLE-ABS-KEY ("image recognition") OR TITLE-ABS-KEY ("neural network") OR TITLE-ABS-KEY ("convolution network")) Filters Applied: 2013 - 2023
Scholar - 1	allinTitle: Scorpion “Deep learning” (2013-2023)
Scholar - 2	allinTitle: Scorpion “Machine Learning” (2013-2023)
Scholar - 3	allinTitle: Scorpion “Artificial Intelligence” (2013-2023) “Image classification” “Image recognition” “Neural network” “Convolutional network”
Scholar - 4	allinTitle: Scorpion “Image classification” (2013-2023)

3.2 Execução da Busca

A busca foi realizada nos meses de Agosto e Setembro 2023 pelo autor e revisada pela orientadora. Os resultados da busca e revisão bibliográfica são resumidos na Tabela 5.

Tabela 5 - Resultado das *Strings* de busca para cada fonte

	Quantidade de resultados da busca	Quantidade de artigos potencialmente relevantes	Quantidade de artigos relevantes
ACM	1	0	0

IEEE	5	1	0
SCOPUS	27	0	0
Scholar - 1	1	1	1
Scholar - 2	1	1	1
Scholar - 3	0	0	0
Scholar - 4	0	0	0
Total			2

De forma geral foram encontrados poucos artigos voltados a classificação de escorpiões. O artigo encontrado na busca executada na plataforma de busca da IEEE foi excluído por não usar *Deep Learning*.

3.3 Resultados da Revisão

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

3.3.1 Quais pesquisas relacionadas existem?

Em geral, a pesquisa realizada revelou uma escassez de trabalhos disponíveis sobre o tema em questão, sendo notável que os únicos dois artigos identificados pertencem a um único grupo de pesquisa representando duas pesquisas diferentes (Tabela 6). É importante destacar, também, que dentro de cada pesquisa, foram utilizadas mais de uma ferramenta, assim como também mais de uma técnica. Na pesquisa voltada ao “Sistemas de detecção e classificação de escorpiões baseados em visão computacional e aprendizado profundo para fins de segurança sanitária”, (Giambelluca et al. (2021a) utilizam a técnica de detecção de objetos, para identificar o que é um escorpião ou não, ou com a classificação de imagens, para classificar os gêneros *Tityus* e *Bothriurus*. Já em “Sistema inovador de detecção automática e reconhecimento de escorpiões com base em técnicas de aprendizado de máquina”, além da classificação entre os gêneros *Tityus* e *Bothriurus*, há a classificação entre as espécies do gênero *Tityus* presentes na cidade de La Plata, Argentina, onde foi realizado o estudo. Isso é detalhado na

Tabela 6.

Tabela 6 - Classificação de espécies nas extensões encontradas

Referência	Título do artigo	Espécies Classificadas	País
(Giambelluca et al., 2021 a)	Scorpion detection and classification systems based on computer vision and deep learning for health security purposes	<i>Tityus e Bothriurus</i>	La Plata, Argentina
		Escorpião e não Escorpião	
(Giambelluca et al, 2021 b)	Novel automatic scorpion-detection and -recognition system based on machine-learning techniques	<i>Tityus e Bothriurus</i>	La Plata, Argentina
		<i>Tityus trivittatus e Tityus confluens</i>	

Baseado nos resultados observados, nota-se que há distinção entre as espécies predominantes da região de La Plata, com as do sul brasileiro, especificamente, do estado de Santa Catarina. Isso implica com que não seja possível utilizar o modelo feito por Giambelluca et al. para classificar espécies de escorpião presentes em Santa Catarina.

Giambelluca et al. (2021a), apresentam resultados a nível de gênero, ou seja, a distinção feita não chega a nível de espécie. Já na outra pesquisa apresentada pelos mesmos autores (Giambelluca et al. 2021b), foram apresentados resultados de duas pesquisas, uma entre os gêneros e outra entre as espécies de *Tityus* presentes em La Plata, *Tityus trivittatus* e *Tityus confluens*.

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

A pesquisa foi realizada com os trabalhos selecionados anteriormente. Os resultados coletados foram compilados na Tabela 7.

Tabela 7: Informações sobre os conjuntos de dados utilizados

Referência	Fonte	Quantidade de imagens no conjunto de dados	Resolução das imagens	Técnicas de <i>data augmentation</i> aplicadas
(Giambelluca et al., 2021 a) Detecção de objetos	<i>Dataset Arachnology Laboratory</i> (CEPAVE)	Total: 809 imagens Escorpião: 612 imagens Negativo: 197 imagens Com roboflow: Total de 1937 imagens	416x416	Rotação horizontal e vertical) 90° Rotação (dois sentidos) 45° Rotação (dois sentidos) 45° Inclinação (dois sentidos) 48% Saturação (plus and

				minus) 25% Exposição (plus and minus) Blur (1.75pX) Ruído (5%)
(Giambelluca et al., 2021 a) Classificação de imagens	<i>Dataset Arachnology Laboratory</i> (CEPAVE)	Total: 278 imagens <i>Tityus</i> : 105 imagens <i>Bothriurus</i> : 113 imagens Negativo: 60 imagens Com roboflow: Total de 834 imagens	não informado	não informado
(Giambelluca et al., 2021 b) <i>Bothriurus</i> x <i>Tityus</i>	<i>Dataset Arachnology Laboratory</i> (CEPAVE)	Total: 132 imagens <i>Bothriurus</i> : 56 <i>Tityus</i> : 76	150x150	Rotação aleatória de até ±50 graus nas imagens Deslocamento aleatório de até 20% da largura da imagem Deslocamento aleatório de até 20% da altura da imagem Aplicação aleatória de cisalhamento nas imagens Possibilidade de espelhar horizontalmente as imagens Aplicação aleatória de zoom de até 30% nas imagens
(Giambelluca et al., 2021b) <i>Tityus trivittatus</i> x <i>Tityus confluens</i>	<i>Dataset Arachnology Laboratory</i> (CEPAVE)	Total de 76 imagens: 30 <i>trivittatus</i> 30 <i>confluens</i>	150x150	não informado

Ambos os trabalhos usam um conjunto de dados que são provenientes do estudo realizado por Giambelluca et al. (2021ab). O conjunto de dados foi obtido a partir do Arachnology Laboratory (CEPAVE). A origem do conjunto de dados é atribuída a este laboratório, que coletou e organizou as imagens previamente. É importante salientar, nesse ponto, que mesmo tendo os mesmo autores, são artigos diferentes, apesar de próximos.

Podemos observar que há uma diferença entre a quantidade de imagens nos diferentes conjuntos de dados, sendo apenas um que passa da marca de 1.000 imagens, com a ajuda de *data augmentation*. Na pesquisa que mais nos interessa e mais está vinculado com a proposta para este trabalho, Giambelluca et al. (2021b) utilizou poucas imagens para treinar um modelo que classifica-se as espécies pertencentes ao gênero *Tityus* em La Plata. Neste estudo, foram separadas 30

imagens da espécie *Tityus trivittatus* e 30 imagens da espécie *Tityus confluens*. Além da pequena quantidade de imagens, se mostra ser um dataset não idealmente equilibrado. Ele também não chega a informar o uso de *data augmentation* e nem do uso de uma classe para resultados negativos. A resolução de 150x150 também pode ser um fator que influencie nos resultados do modelo, podendo não se obter o máximo de informações relevantes para a classificação correta das espécies.

No estudo referente à detecção de objetos, feito por Giambelluca et al. (2021a), é interessante observar que o uso de uma ferramenta de *data augmentation* é capaz de aumentar consideravelmente o tamanho de um dataset. *Data augmentation* é o processo de criar permutações de imagens existentes em um conjunto de dados para gerar novas imagens. Por exemplo, é possível aumentar o brilho de uma imagem ou diminuí-lo, o que auxiliaria um modelo a aprender a identificar objetos de interesse em diferentes condições de iluminação. É possível também realizar aumento ao alterar o ângulo da imagem, ajudando o modelo a detectar um objeto em diferentes orientações (Gallagher, 2023).

3.3.3 Como e quais modelos foram treinados?

As informações sobre o treinamento dos modelos são resumidas na Tabela 8.

Tabela 8: Informações sobre o treinamento dos modelos

Referência	Modelo de DL	Épocas de treinamento	Taxa de aprendizagem	Tamanho de lote
(Giambelluca et al, 2021a)	MobileNet V2	200	0.001	512
(Giambelluca et al, 2021a)	YOLOv4	600	não informado	16
(Giambelluca et al, 2021b) Bothriurus x Tityus	VGG16 (Sem <i>data augmentation</i>)	20	0.001	30
(Giambelluca et al, 2021b) - 2 Tityus trivittatus x Tityus confluens	VGG16 (Com <i>data augmentation</i>)	50	não informado	30

Observa-se que foram utilizados três modelos diferentes: MobileNetV2, VGG16,

YOLOv4. Como são poucos os resultados do estudo da revisão, é possível debater detalhadamente sobre cada modelo de *DL* utilizado para o treinamento. Começando pela VGG16, ela é uma CNN comparativa que mostra, hoje, um desempenho abaixo de outras redes mais atuais, como a MobileNet, ResNet ou EfficientNet. Além disso, é uma rede com uma grande quantidade de camadas convolucionais, o que também dificulta a portabilidade para dispositivos móveis. Já o YOLOv4 não é um modelo de classificação de imagens, mas sim, uma rede neural convolucional profunda utilizada para detecção de objetos em tempo real (Giambelluca et al., 2021a). E conforme discutido na seção 2.5.3.2, o MobileNet (Howard et al., 2017), é um modelo pequeno e foi utilizado também por Giambelluca et al. (2021a) para a classificação de gêneros de escorpiões e obteve o melhor resultado nos desempenhos citados na Tabela 9.

Em relação ao número de épocas, os valores variam de 20 a 600. A taxa de aprendizado apresenta valores de 0.001, sendo que em dois casos não foi informada. O tamanho do lote (*batch size*) varia entre 16 a 512. Pela escassez de trabalhos correlatos e a taxa de aprendizado não especificada em duas das quatro oportunidades, dificulta a comparação direta entre eles.

3.3.4 Quais os desempenhos relatados?

Os desempenhos dos modelos treinados foram extraídos a partir de dados selecionados nos trabalhos relevantes (Tabela 9).

Tabela 9: Métricas de teste do desempenho dos modelos treinados

Referência	Modelo de DL	Acurácia	Precisão	Recall	F1-Score
(Giambelluca et al., 2021)	MobileNet V2 (<i>Bothriurus x Tityus</i>)	0.91	0.92	0.97	0.94
	YOLOv4 (<i>Bothriurus x Tityus</i>)	0.88	0.93	0.90	0.92
(Giambelluca et al., 2021)	VGG16 sem data augmentation (<i>Bothriurus x Tityus</i>)	0.78	0.77	0.93	0.84

	VGG16 com data augmentation (<i>Bothriurus</i> x <i>Tityus</i>)	0.78	0.79	0.89	0.84
	VGG16 com data augmentation (<i>confluens</i> x <i>trivittatus</i>)	0.72	0.83	0.74	0.82

Conforme se esperava, o modelo mais ultrapassado, o VGG 16, apresentou um desempenho inferior do que os outros modelos de forma geral. Entre os modelos treinados, o MobileNet atingiu o melhor desempenho com uma acurácia total de 0.91, numa classificação de gêneros, entre o *Tityus* e *Bothriurus*, o que indica a necessidade de expandir a análise para as espécies do gênero *Tityus*. Considerando o risco de erro de classificação de um modelo que classifica espécies de escorpião, também se torna necessário aumentar a acurácia conquistada no resultado do modelo, já que erros podem gerar resultados catastróficos a vidas humanas.

Pode-se observar nos resultados das métricas obtidas na Tabela 9 que o único modelo treinado para uma classificação de espécies de escorpião do gênero *Tityus* obteve uma acurácia baixa (0.72).

Em nenhum dos dois trabalhos foram comentados resultados de validação, apenas de teste, o que seria uma informação útil para os trabalhos realizados.

3.4 Discussão

Os resultados desta revisão sistemática da literatura demonstram que já existem pesquisas voltadas ao desenvolvimento de modelos de classificação de escorpiões, porém, numa quantidade relativamente baixa.

Observa-se que apenas uma das pesquisas encontradas tem como foco a classificação de espécies de escorpiões, enquanto nas outras pesquisas a classificação fica no nível de gênero de espécies, o que omite uma informação importante e interessante ao usuário.

Os modelos listados que abordam espécies de escorpiões, apenas abordam espécies originárias da região da qual foram desenvolvidos os trabalhos, que

correspondem a La Plata, Argentina. Os modelos não classificam outras espécies de escorpião, como o *Tityus serrulatus*, considerado o escorpião mais venenoso da América do Sul (Cologna et al., 2009), o que é objetivo deste trabalho, visando abordar escorpiões presentes em Florianópolis e Santa Catarina. Os modelos que abordam apenas gêneros *Tityus* x *Bothriurus* também não mostram resultados consideráveis, tendo um nível de acurácia máximo de 0.91, o que pode gerar um risco significativo para usuários e pôr em risco vidas humanas. E o único modelo treinado que contém uma classificação de espécies de escorpião do gênero *Tityus* obteve uma acurácia de (0.72), o que é considerado abaixo do razoável.

Uma das razões para os resultados de desempenho inferior pode ser explicada pela quantidade pequena de imagens, sendo o de classificação de espécies de apenas 76 imagens, 60 para treinamento (30 *trivittatus* e 30 *confluens*) e 16 para teste. Outra questão é a seleção dos modelos que foram utilizados para a classificação de imagens, sendo que não há um modelo mais recente e que apresente os melhores resultados (conforme indicado na Fundamentação teórica (Figura 35)), como Resnet ou EfficientNet.

Desta forma, os resultados do levantamento do estado da arte indicam a falta de um modelo de classificação incluindo todas as espécies relevantes de escorpiões presentes em Santa Catarina com um desempenho satisfatório para minimizar o risco de resultados errados.

4. DESENVOLVIMENTO DE MODELO DE CLASSIFICAÇÃO DE IMAGENS DE ESCORPIÃO

4.1 Requisitos

Visou-se desenvolver um aplicativo inteligente que classifica escorpiões, por meio de imagens obtidas de uma câmera de celular Android e que possibilite que usuários sem a expertise na classificação de escorpiões identifiquem sua espécie, e logo, seus perigos, tornando possível que haja prevenção de ataques escorpiônicos e que ajude nos primeiros socorros de interações humano-escorpião.

Tabela 10: Análise da necessidade

Qual é o problema/necessidade identificado?	Hoje, acidentes causados por escorpiões são considerados problemas de saúde pública em Santa Catarina e podem apresentar sintomas como dor intensa, inchaço, náuseas, sudorese e taquicardia. Em casos mais graves, pode ocorrer insuficiência respiratória e óbito. Com isso, foi identificado a necessidade do cidadão ter mais informações e autonomia em ocorrências envolvendo escorpiões para providenciar os primeiros socorros.
Ponto de Vista (POV)	O Cidadão PRECISA de maiores informações sobre escorpiões PORQUE isso minimizaria os perigos e possíveis mortes por picadas.
Como podemos (HMW)	COMO PODEMOS Disponibilizar um aplicativo que classifica escorpiões, torna-se possível que a prevenção de ataques e os primeiros socorros de interações humano-escorpião sejam feitas pela inteligência artificial e que o sistema de prevenção possa dar os primeiros socorros da maneira mais adequada possível.

Utilizando a notação de descrição de Mitchell (1997), o objetivo deste trabalho teve como desenvolver um modelo de *deep learning* portátil a um aplicativo móvel e capaz de aprender com a experiência (E) em relação a uma classe de tarefas (T) e com base na medida de desempenho (P). Especificamente, a tarefa (T) consiste em classificar as espécies de escorpião a partir de fotografias capturadas pela câmera de um dispositivo Android. A experiência (E) foi composta por um conjunto de imagens de gêneros de escorpiões das espécies *Tityus serrulatus*, *Tityus costatus* e *Tityus bahiensis*, assim como imagens do gênero de escorpião *Bothriurus*, bem como objetos não relacionados a escorpiões, todas elas devidamente rotuladas. O critério para a seleção das espécies consideradas neste trabalho são os presentes no estado de Santa Catarina (CIATox/SC, 2023). Em termos de desempenho (P), espera-se alcançar uma acurácia superior a 95%.

Tabela 11: Requisitos de um modelo de *ML* para classificação de imagens de escorpiões

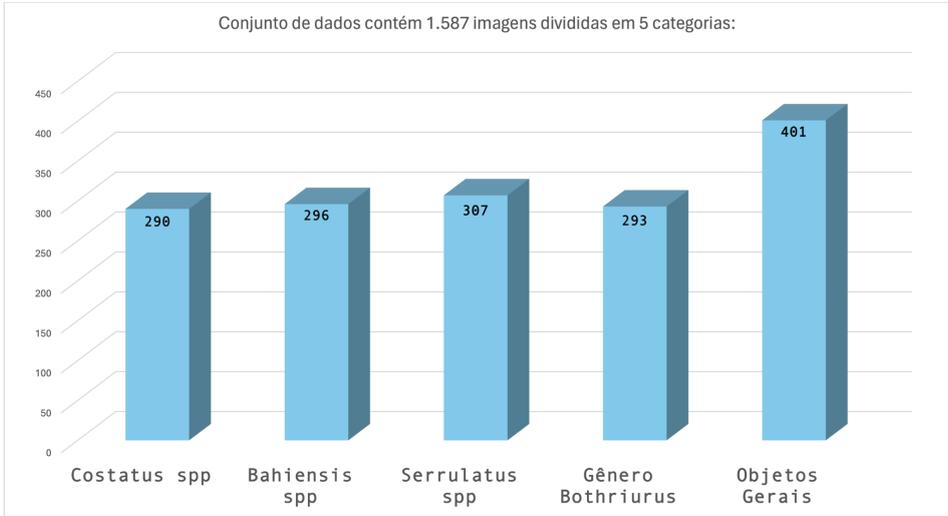
Objetivos do modelo de ML	
Tarefa	Classificar espécies de escorpião <i>Tityus serrulatus</i> , <i>Tityus costatus</i> e <i>Tityus bahiensis</i> , assim como o gênero de escorpião <i>Bothriurus</i> por meio de imagens capturadas de um celular Android.
Tipo da tarefa	Classificação de imagens (<i>Single-label</i>).
Categorias	Cinco categorias <div style="display: flex; justify-content: flex-end; margin-top: 5px;"> <div style="text-align: right; padding-right: 10px;"> <i>Tityus serrulatus</i> <i>Tityus costatus</i> <i>Tityus bahiensis</i> <i>Bothriurus</i> Non-scorpio </div> </div>

Contexto de uso	O modelo é utilizado por um cidadão como prevenção e minimização de perigo e possível morte por picadas escorpiônicas.	
Risco e requisitos de desempenho		
Risco	Risco Alto A classificação errônea de um escorpião pode ser detrimental para a saúde dos cidadãos envolvidos.	
Desempenho	O modelo de <i>ML</i> será otimizado para precisão porque precisamos de reduzir o risco de indicar a categoria errada ao usuário, levando ele a uma compreensão também errada.	
Medidas	Acurácia (total/por categoria)	No mínimo 0.95

4.2 Preparação do Conjunto de Imagens

Um conjunto de imagens de escorpiões presentes em Santa Catarina foram coletados do site iNaturalist¹, que tem o intuito de ser uma comunidade de biólogos e entusiastas que compartilham imagens de diversos animais e os rotulam. Apenas as imagens sem licença foram coletadas, limitando o número de imagens que pudessem ser armazenadas para o conjunto de dados. Com o objetivo de padronizar e potencializar o aprendizado do modelo, todas as imagens foram padronizadas na resolução 224x224.

Tabela 12: Informações do conjunto de dados utilizado para o treinamento

Conjunto de dados													
Fonte de dados	Imagens coletadas no site iNaturalist												
Quantidade de dados	<p>Conjunto de dados contém 1.587 imagens divididas em 5 categorias:</p>  <table border="1"> <caption>Distribuição de Imagens por Categoria</caption> <thead> <tr> <th>Categoria</th> <th>Quantidade</th> </tr> </thead> <tbody> <tr> <td>Costatus spp</td> <td>290</td> </tr> <tr> <td>Bahiensis spp</td> <td>296</td> </tr> <tr> <td>Serrulatus spp</td> <td>307</td> </tr> <tr> <td>Gênero Bothriurus</td> <td>293</td> </tr> <tr> <td>Objetos Gerais</td> <td>401</td> </tr> </tbody> </table>	Categoria	Quantidade	Costatus spp	290	Bahiensis spp	296	Serrulatus spp	307	Gênero Bothriurus	293	Objetos Gerais	401
Categoria	Quantidade												
Costatus spp	290												
Bahiensis spp	296												
Serrulatus spp	307												
Gênero Bothriurus	293												
Objetos Gerais	401												

¹ Disponível em: ><https://www.inaturalist.org><

Conjunto de dados	
Fonte de dados	Imagens coletadas no site iNaturalist
Rotulação de dados	As imagens foram rotuladas por um aluno de graduação da UFSC na área de biologia.

Foi realizada uma coleta minuciosa das imagens feitas principalmente no iNaturalist, incluindo diferentes ambientes, níveis de claridade e ângulos de captura, simulando de maneira real as condições que os usuários terão no momento de uso do aplicativo móvel.

Também é importante destacar que o conjunto de dados teve um acréscimo de imagens usando *data augmentation*. Seu uso foi encorajado por ter espécies com significativa diferença nas quantidades de imagens. Essas operações foram empregadas para expandir o conjunto de dados original, introduzindo variações nas imagens e tornando o modelo mais robusto em relação a diferentes perspectivas e configurações de imagem. As técnicas aplicadas foram as de rotação aleatória de 90 graus e espelhamento vertical e horizontal, gerando 250 novas imagens. Inicialmente, o conjunto de imagens continha 1.097 imagens, sendo geradas quase 500 novas imagens para comporem o conjunto de dados e deixá-lo equilibrado, chegando no total de 1.587 imagens divididas em 5 classes.

Para cada categoria, foram separadas 50 imagens para compor o conjunto de testes. Essas imagens não foram utilizadas em nenhum dos treinamentos. Importante ressaltar também que nenhuma imagem de teste foi resultado de alguma técnica de *data augmentation*, evitando a possibilidade de algum viés do modelo.

4.3 Treinamento, Avaliação do Desempenho e Teste

Os treinamentos foram realizados entre diferentes redes neurais que são portáteis para dispositivos móveis: ResNet-18, ResNet-34, EfficientNet-Lite, EfficientNet-B0 e MobileNetV3. Os modelos foram treinados utilizando *transfer learning*, utilizando modelos pré-treinados no *ImageNet*, aproveitando os pesos já treinados para inicializar o modelo. O modelo foi configurado para a nova tarefa com 5 classes, substituindo a camada final original, sem adicionar camadas adicionais. Em contrapartida, foi decidido não incluir a etapa de *fine-tuning* devido à nossa avaliação teórica de que, com um conjunto de dados limitado, essa etapa poderia

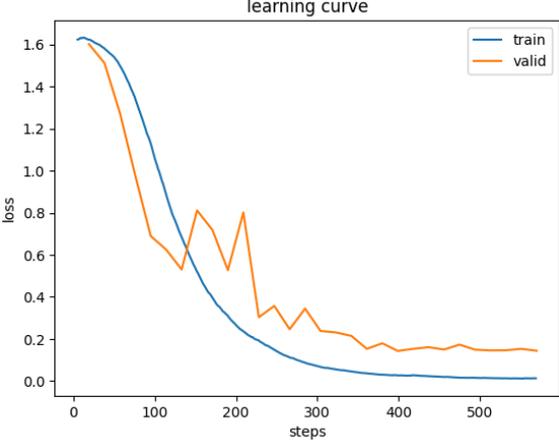
levar ao *overfitting*. A hipótese baseia-se na literatura existente e no entendimento de que *fine-tuning* em datasets pequenos pode ajustar excessivamente o modelo aos dados de treinamento, reduzindo a capacidade de generalização. Testes futuros podem incluir o uso de *fine-tuning* no conjunto de dados para comparar os resultados.

Todos os modelos foram desenvolvidos e treinados utilizando o ambiente *Jupyter Notebook*, por meio da plataforma *Google Colab*. A escolha dessas redes neurais foi baseada no entendimento do estudo contido durante a seção 2.5.3. Foram escolhidas as redes mais performáticas e que ocupassem pouco espaço de memória, já que serão disponibilizadas no futuro por meio de um aplicativo móvel.

Um treinamento utilizando a plataforma do *Google Teachable Machine* também foi realizado, que utiliza do modelo *MobileNetV2* como rede neural. Atualmente, ela é a única plataforma que pode disponibilizar uma rede neural num aplicativo concebido pelo *App Inventor*, por meio de uma extensão. Os resultados de treinamento podem ser observados na seção 4.3.6 e de teste na seção 4.4.6.

4.3.1 Treinamento das redes

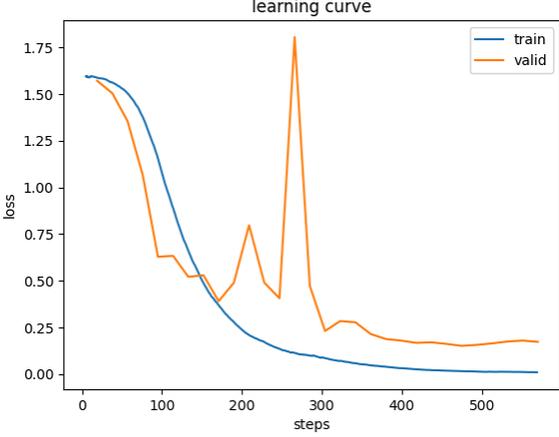
Tabela 13 - Treinamento com a rede ResNet18

Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0,001
Curva de loss	 <p>The graph, titled 'learning curve', plots 'loss' on the y-axis (ranging from 0.0 to 1.6) against 'steps' on the x-axis (ranging from 0 to 500). Two lines are shown: a blue line for 'train' and an orange line for 'valid'. Both lines start at a loss of approximately 1.6 at step 0. The training loss decreases steadily, reaching near 0 by step 500. The validation loss also decreases but remains higher than the training loss, ending around 0.15. There are noticeable fluctuations in the validation loss between steps 100 and 200.</p>
Acurácia total	97.80%

Matriz de confusão	<p style="text-align: center;">Confusion matrix</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <thead> <tr> <th>Actual \ Predicted</th> <th>Bahiensis</th> <th>Bothriurus</th> <th>Costatus</th> <th>ObjGerais</th> <th>Serrulatus</th> </tr> </thead> <tbody> <tr> <th>Bahiensis</th> <td>62</td> <td>0</td> <td>3</td> <td>0</td> <td>0</td> </tr> <tr> <th>Bothriurus</th> <td>0</td> <td>43</td> <td>1</td> <td>0</td> <td>0</td> </tr> <tr> <th>Costatus</th> <td>0</td> <td>0</td> <td>52</td> <td>0</td> <td>2</td> </tr> <tr> <th>ObjGerais</th> <td>0</td> <td>0</td> <td>0</td> <td>91</td> <td>1</td> </tr> <tr> <th>Serrulatus</th> <td>0</td> <td>0</td> <td>3</td> <td>0</td> <td>59</td> </tr> </tbody> </table>	Actual \ Predicted	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus	Bahiensis	62	0	3	0	0	Bothriurus	0	43	1	0	0	Costatus	0	0	52	0	2	ObjGerais	0	0	0	91	1	Serrulatus	0	0	3	0	59
Actual \ Predicted	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																
Bahiensis	62	0	3	0	0																																
Bothriurus	0	43	1	0	0																																
Costatus	0	0	52	0	2																																
ObjGerais	0	0	0	91	1																																
Serrulatus	0	0	3	0	59																																
Acurácia por classe	<table border="1" style="background-color: #333; color: #fff; text-align: center;"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td>Bahiensis</td> <td>0.953846</td> </tr> <tr> <td>Bothriurus</td> <td>0.977273</td> </tr> <tr> <td>Costatus</td> <td>0.962963</td> </tr> <tr> <td>ObjGerais</td> <td>0.98913</td> </tr> <tr> <td>Serrulatus</td> <td>0.951613</td> </tr> </tbody> </table>	Classe	Acurácia	Bahiensis	0.953846	Bothriurus	0.977273	Costatus	0.962963	ObjGerais	0.98913	Serrulatus	0.951613																								
Classe	Acurácia																																				
Bahiensis	0.953846																																				
Bothriurus	0.977273																																				
Costatus	0.962963																																				
ObjGerais	0.98913																																				
Serrulatus	0.951613																																				
Interpretação	O modelo demonstrou um alto nível de acurácia na identificação nas diferentes classes, com taxas variando de 95% a 98%.																																				
Aceitação do modelo	O modelo apresenta uma alta acurácia para todas as categorias e todas estão com a acurácia >95%.																																				

Tabela 14 - Treinamento com a rede ResNet34

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

Curva de loss	 <p>learning curve</p>																																										
Acurácia total	96.50%																																										
Matriz de confusão	<p>Confusion matrix</p> <table border="1" data-bbox="853 862 1412 1422"> <thead> <tr> <th></th> <th>Bahiensis</th> <th>Bothriurus</th> <th>Costatus</th> <th>ObjGerais</th> <th>Serrulatus</th> </tr> </thead> <tbody> <tr> <th>Bahiensis</th> <td>59</td> <td>1</td> <td>4</td> <td>0</td> <td>1</td> </tr> <tr> <th>Bothriurus</th> <td>0</td> <td>43</td> <td>1</td> <td>0</td> <td>0</td> </tr> <tr> <th>Costatus</th> <td>0</td> <td>0</td> <td>52</td> <td>0</td> <td>2</td> </tr> <tr> <th>ObjGerais</th> <td>0</td> <td>1</td> <td>0</td> <td>90</td> <td>1</td> </tr> <tr> <th>Serrulatus</th> <td>3</td> <td>0</td> <td>4</td> <td>0</td> <td>55</td> </tr> <tr> <td></td> <th>Bahiensis</th> <th>Bothriurus</th> <th>Costatus</th> <th>ObjGerais</th> <th>Serrulatus</th> </tr> </tbody> </table> <p>Actual</p> <p>Predicted</p>		Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus	Bahiensis	59	1	4	0	1	Bothriurus	0	43	1	0	0	Costatus	0	0	52	0	2	ObjGerais	0	1	0	90	1	Serrulatus	3	0	4	0	55		Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus
	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																						
Bahiensis	59	1	4	0	1																																						
Bothriurus	0	43	1	0	0																																						
Costatus	0	0	52	0	2																																						
ObjGerais	0	1	0	90	1																																						
Serrulatus	3	0	4	0	55																																						
	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																						
Acurácia por classe	<pre> Classe Acurácia ----- Bahiensis 0.907692 Bothriurus 0.977273 Costatus 0.962963 ObjGerais 0.978261 Serrulatus 0.887097 </pre>																																										
Interpretação	A acurácia por classe no treinamento foi bom, porém, com duas classes atingindo valores de acurácia abaixo de <95%.																																										
Aceitação do modelo	O modelo apresenta uma alta acurácia mas com valores de acurácia <95% para duas classes																																										

	que representam espécies perigosas.
--	-------------------------------------

Tabela 15 - Treinamento com a rede EfficientNet-Lite

Treinamento																																					
Quantidade de épocas	30																																				
Tamanho do lote	16																																				
Taxa de aprendizagem	0,001																																				
Curva de loss	<p>learning curve</p>																																				
Acurácia total	95.90%																																				
Matriz de confusão	<p>Confusion matrix</p> <table border="1"> <thead> <tr> <th></th> <th>Bahiensis</th> <th>Bothriurus</th> <th>Costatus</th> <th>ObjGeraiis</th> <th>Serrulatus</th> </tr> </thead> <tbody> <tr> <th>Bahiensis</th> <td>63</td> <td>0</td> <td>1</td> <td>0</td> <td>1</td> </tr> <tr> <th>Bothriurus</th> <td>1</td> <td>41</td> <td>1</td> <td>0</td> <td>1</td> </tr> <tr> <th>Costatus</th> <td>0</td> <td>0</td> <td>53</td> <td>0</td> <td>1</td> </tr> <tr> <th>ObjGeraiis</th> <td>0</td> <td>0</td> <td>0</td> <td>92</td> <td>0</td> </tr> <tr> <th>Serrulatus</th> <td>2</td> <td>2</td> <td>2</td> <td>0</td> <td>56</td> </tr> </tbody> </table>		Bahiensis	Bothriurus	Costatus	ObjGeraiis	Serrulatus	Bahiensis	63	0	1	0	1	Bothriurus	1	41	1	0	1	Costatus	0	0	53	0	1	ObjGeraiis	0	0	0	92	0	Serrulatus	2	2	2	0	56
	Bahiensis	Bothriurus	Costatus	ObjGeraiis	Serrulatus																																
Bahiensis	63	0	1	0	1																																
Bothriurus	1	41	1	0	1																																
Costatus	0	0	53	0	1																																
ObjGeraiis	0	0	0	92	0																																
Serrulatus	2	2	2	0	56																																

Acurácia por classe	<pre> Classe Acurácia ----- Bahiensis 0.969231 Bothriurus 0.931818 Costatus 0.981481 ObjGerais 1 Serrulatus 0.903226 </pre>
Interpretação	A acurácia por classe no treinamento teve bom desempenho, porém, com duas classes atingindo valores de acurácia abaixo de <95%.
Aceitação do modelo	O modelo apresenta bons resultados mas com valores de acurácia <95% para a classe <i>serrulatus</i> , que é uma espécie perigosa. <i>bothriurus</i> , não perigosa, também fica <95% de acurácia.

Tabela 16 - Treinamento com a rede EfficientNet-B0

Treinamento	
Quantidade de épocas	30
Tamanho do lote	16
Taxa de aprendizagem	0,001
Curva de loss	<p>The graph titled 'learning curve' plots 'loss' on the y-axis (ranging from 0.0 to 3.5) against 'steps' on the x-axis (ranging from 0 to 500). Two lines are shown: a blue line for 'train' and an orange line for 'valid'. Both lines show a sharp initial decrease in loss, with the training loss reaching near zero by 200 steps and the validation loss stabilizing around 0.2 after 100 steps.</p>
Acurácia total	98.10%

Matriz de confusão	<p style="text-align: center;">Confusion matrix</p> <table border="1"> <tr> <td></td> <td>Bahiensis</td> <td>Bothriurus</td> <td>Costatus</td> <td>ObjGerais</td> <td>Serrulatus</td> </tr> <tr> <td>Bahiensis</td> <td>61</td> <td>2</td> <td>2</td> <td>0</td> <td>0</td> </tr> <tr> <td>Bothriurus</td> <td>0</td> <td>43</td> <td>1</td> <td>0</td> <td>0</td> </tr> <tr> <td>Costatus</td> <td>1</td> <td>0</td> <td>52</td> <td>0</td> <td>1</td> </tr> <tr> <td>ObjGerais</td> <td>0</td> <td>1</td> <td>0</td> <td>91</td> <td>0</td> </tr> <tr> <td>Serrulatus</td> <td>0</td> <td>1</td> <td>1</td> <td>0</td> <td>60</td> </tr> <tr> <td></td> <td>Bahiensis</td> <td>Bothriurus</td> <td>Costatus</td> <td>ObjGerais</td> <td>Serrulatus</td> </tr> <tr> <td></td> <td colspan="5" style="text-align: center;">Predicted</td> </tr> </table>		Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus	Bahiensis	61	2	2	0	0	Bothriurus	0	43	1	0	0	Costatus	1	0	52	0	1	ObjGerais	0	1	0	91	0	Serrulatus	0	1	1	0	60		Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus		Predicted				
	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																												
Bahiensis	61	2	2	0	0																																												
Bothriurus	0	43	1	0	0																																												
Costatus	1	0	52	0	1																																												
ObjGerais	0	1	0	91	0																																												
Serrulatus	0	1	1	0	60																																												
	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																												
	Predicted																																																
Acurácia por classe	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td>Bahiensis</td> <td>0.938462</td> </tr> <tr> <td>Bothriurus</td> <td>0.977273</td> </tr> <tr> <td>Costatus</td> <td>0.962963</td> </tr> <tr> <td>ObjGerais</td> <td>0.98913</td> </tr> <tr> <td>Serrulatus</td> <td>0.967742</td> </tr> </tbody> </table>	Classe	Acurácia	Bahiensis	0.938462	Bothriurus	0.977273	Costatus	0.962963	ObjGerais	0.98913	Serrulatus	0.967742																																				
Classe	Acurácia																																																
Bahiensis	0.938462																																																
Bothriurus	0.977273																																																
Costatus	0.962963																																																
ObjGerais	0.98913																																																
Serrulatus	0.967742																																																
Interpretação	O modelo demonstrou um alto nível de acurácia na identificação nas diferentes classes, com taxas de acurácia variando de 93% a 98%.																																																
Aceitação do modelo	O modelo apresenta uma alta acurácia para todas as categorias, porém, a classe <i>bahiensis</i> , perigosa, fica abaixo dos 95%.																																																

Tabela 17 - Treinamento com a rede MobileNetV3

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

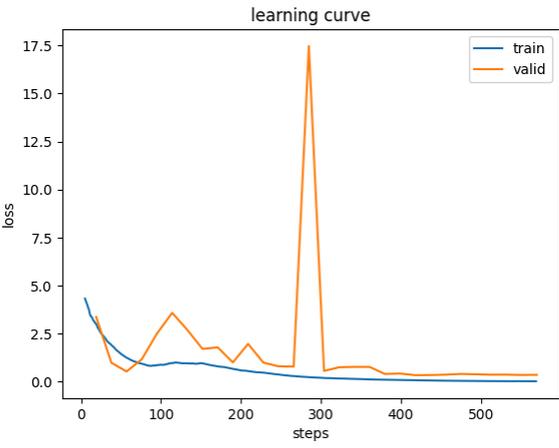
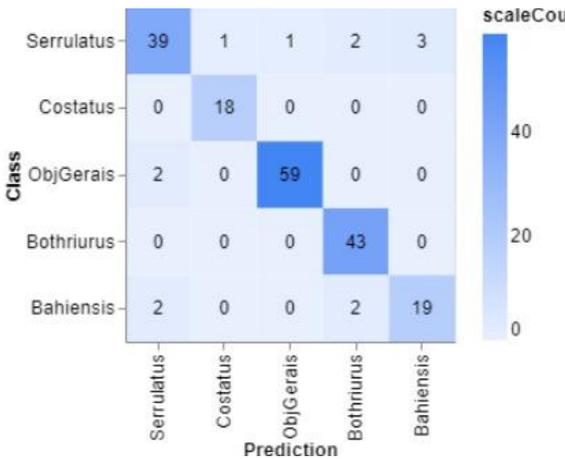
Curva de loss	 <p>learning curve</p>																																										
Acurácia total	94.20%																																										
Matriz de confusão	<p>Confusion matrix</p> <table border="1" data-bbox="858 869 1417 1420"> <thead> <tr> <th></th> <th>Bahiensis</th> <th>Bothriurus</th> <th>Costatus</th> <th>ObjGerais</th> <th>Serrulatus</th> </tr> </thead> <tbody> <tr> <th>Bahiensis</th> <td>60</td> <td>0</td> <td>4</td> <td>0</td> <td>1</td> </tr> <tr> <th>Bothriurus</th> <td>1</td> <td>42</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <th>Costatus</th> <td>0</td> <td>0</td> <td>52</td> <td>0</td> <td>2</td> </tr> <tr> <th>ObjGerais</th> <td>0</td> <td>2</td> <td>1</td> <td>87</td> <td>2</td> </tr> <tr> <th>Serrulatus</th> <td>4</td> <td>0</td> <td>4</td> <td>0</td> <td>54</td> </tr> <tr> <th></th> <th>Bahiensis</th> <th>Bothriurus</th> <th>Costatus</th> <th>ObjGerais</th> <th>Serrulatus</th> </tr> </tbody> </table> <p>Actual</p> <p>Predicted</p>		Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus	Bahiensis	60	0	4	0	1	Bothriurus	1	42	0	0	1	Costatus	0	0	52	0	2	ObjGerais	0	2	1	87	2	Serrulatus	4	0	4	0	54		Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus
	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																						
Bahiensis	60	0	4	0	1																																						
Bothriurus	1	42	0	0	1																																						
Costatus	0	0	52	0	2																																						
ObjGerais	0	2	1	87	2																																						
Serrulatus	4	0	4	0	54																																						
	Bahiensis	Bothriurus	Costatus	ObjGerais	Serrulatus																																						
Acurácia por classe	<pre> Classe Acurácia ----- Bahiensis 0.923077 Bothriurus 0.954545 Costatus 0.962963 ObjGerais 0.945652 Serrulatus 0.870968 </pre>																																										
Interpretação	O modelo apresenta apenas duas classes com acurácia >95%.																																										
Aceitação do modelo	O modelo apresenta uma acurácia geral abaixo de <95%, tendo apenas duas de cinco classes >95%.																																										

Tabela 18 - Treinamento da rede MobileNetV2 com a ferramenta GTM

Treinamento													
Quantidade de épocas	50												
Tamanho do lote	16												
Taxa de aprendizagem	0,001												
Curva de loss													
Acurácia total	$\text{Acurácia total} = \frac{0.85+1+0.97+1+0.83}{5} = \frac{4.65}{5} = 0.93$												
Acurácia por classe	<table border="1" style="margin-left: auto; margin-right: auto;"> <thead> <tr> <th>CLASS</th> <th>ACCURACY</th> </tr> </thead> <tbody> <tr> <td>Serrulatus</td> <td>0.85</td> </tr> <tr> <td>Costatus</td> <td>1.00</td> </tr> <tr> <td>ObjGerais</td> <td>0.97</td> </tr> <tr> <td>Bothriurus</td> <td>1.00</td> </tr> <tr> <td>Bahiensis</td> <td>0.83</td> </tr> </tbody> </table>	CLASS	ACCURACY	Serrulatus	0.85	Costatus	1.00	ObjGerais	0.97	Bothriurus	1.00	Bahiensis	0.83
CLASS	ACCURACY												
Serrulatus	0.85												
Costatus	1.00												
ObjGerais	0.97												
Bothriurus	1.00												
Bahiensis	0.83												

Matriz de confusão	 <table border="1" data-bbox="847 237 1412 696"> <thead> <tr> <th>Class</th> <th>Serrulatus</th> <th>Costatus</th> <th>ObjGeraiis</th> <th>Bothriurus</th> <th>Bahiensis</th> </tr> </thead> <tbody> <tr> <th>Serrulatus</th> <td>39</td> <td>1</td> <td>1</td> <td>2</td> <td>3</td> </tr> <tr> <th>Costatus</th> <td>0</td> <td>18</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <th>ObjGeraiis</th> <td>2</td> <td>0</td> <td>59</td> <td>0</td> <td>0</td> </tr> <tr> <th>Bothriurus</th> <td>0</td> <td>0</td> <td>0</td> <td>43</td> <td>0</td> </tr> <tr> <th>Bahiensis</th> <td>2</td> <td>0</td> <td>0</td> <td>2</td> <td>19</td> </tr> </tbody> </table>	Class	Serrulatus	Costatus	ObjGeraiis	Bothriurus	Bahiensis	Serrulatus	39	1	1	2	3	Costatus	0	18	0	0	0	ObjGeraiis	2	0	59	0	0	Bothriurus	0	0	0	43	0	Bahiensis	2	0	0	2	19
Class	Serrulatus	Costatus	ObjGeraiis	Bothriurus	Bahiensis																																
Serrulatus	39	1	1	2	3																																
Costatus	0	18	0	0	0																																
ObjGeraiis	2	0	59	0	0																																
Bothriurus	0	0	0	43	0																																
Bahiensis	2	0	0	2	19																																
Interpretação	O modelo apresenta três classes com acurácia $\geq 95\%$ (<i>costatus</i> , <i>bothriurus</i> e <i>ObjGeraiis</i>)																																				
Aceitação do modelo	O modelo apresenta uma acurácia aceitável, tendo três de cinco classes $\geq 95\%$. As duas classes que não chegam no requisito da acurácia são duas espécies perigosas.																																				

4.4 Testes de Desempenho

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

4.4.1 Preparação do teste

O conjunto de teste é composto por um total de 250 imagens, com as características descritas na Tabela 19.

Tabela 19: Características do conjunto de dados de teste

Característica	Especificação
Número total de imagens no conjunto de testes	250 novas imagens não utilizadas durante o treinamento
Distribuição do conjunto de testes	<i>bahiensis spp</i> - 50 imagens gênero <i>Bothriurus</i> - 50 imagens <i>bahiensis spp</i> - 50 imagens <i>costatus spp</i> - 50 imagens <i>serrulatus spp</i> - 50 imagens

Fonte	As imagens foram coletadas do site <i>iNaturalist</i> .
-------	---

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

- Acurácia, para avaliar o desempenho geral;
- Precisão e recall para apoiar a compreensão de como o modelo lida com falsos positivos e falsos negativos;
- F1-Score, a média harmônica dos resultados de precisão e recuperação.

Os testes foram executados utilizando o *Jupyter Notebook* na plataforma do *Google Colab*. Os testes realizados através do *Google Teachable Machine* foram feitos com 20 amostras. A ferramenta não conta com uma separação automatizada para testes, sendo necessário realizá-las manualmente.

Tabela 20 - Testes com a rede ResNet18

Testes													
Acurácia total	88.40%												
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td>testeBahiensis</td> <td>0.72</td> </tr> <tr> <td>testeBothriurus</td> <td>0.9</td> </tr> <tr> <td>testeCostatus</td> <td>0.88</td> </tr> <tr> <td>testeObjGerais</td> <td>0.98</td> </tr> <tr> <td>testeSerrulatus</td> <td>0.94</td> </tr> </tbody> </table>	Classe	Acurácia	testeBahiensis	0.72	testeBothriurus	0.9	testeCostatus	0.88	testeObjGerais	0.98	testeSerrulatus	0.94
Classe	Acurácia												
testeBahiensis	0.72												
testeBothriurus	0.9												
testeCostatus	0.88												
testeObjGerais	0.98												
testeSerrulatus	0.94												

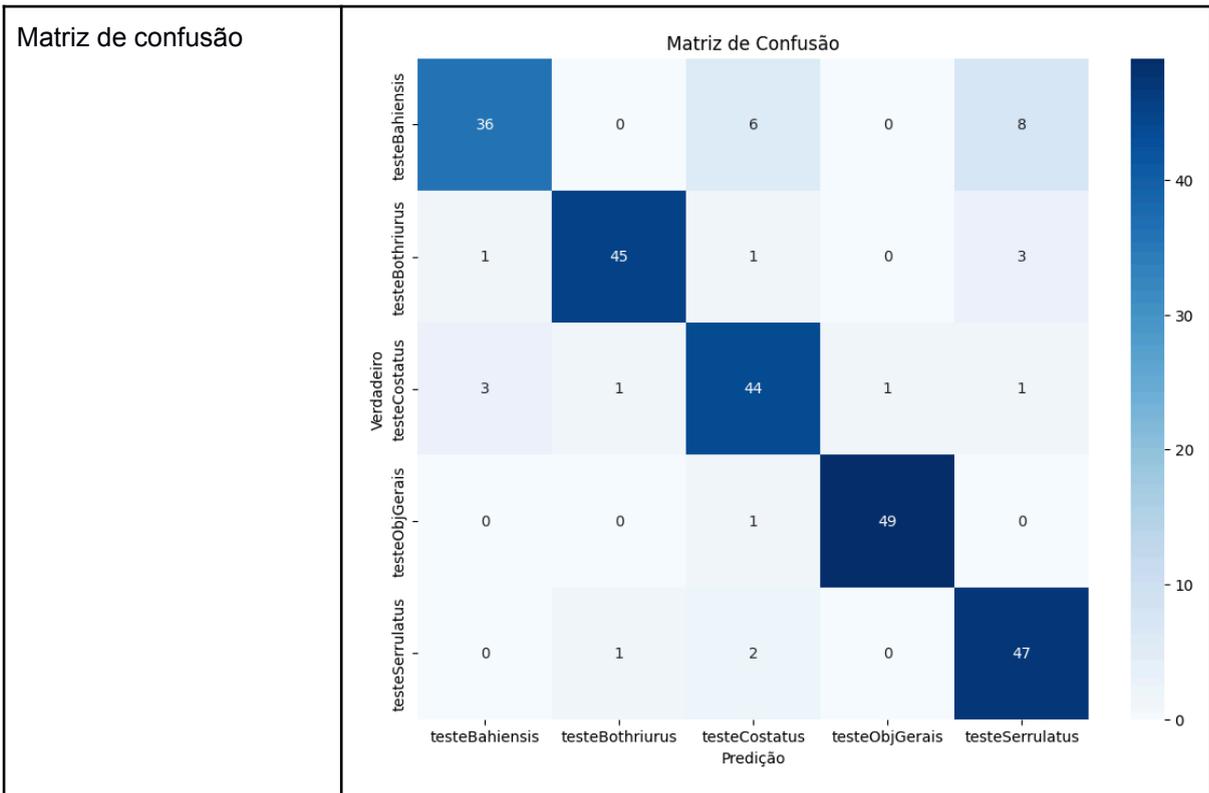


Tabela 21 - Testes com a rede ResNet34

Testes													
Acurácia Total	90%												
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td>testeBahiensis</td> <td>0.78</td> </tr> <tr> <td>testeBothriurus</td> <td>0.94</td> </tr> <tr> <td>testeCostatus</td> <td>0.86</td> </tr> <tr> <td>testeObjGeráis</td> <td>0.98</td> </tr> <tr> <td>testeSerrulatus</td> <td>0.94</td> </tr> </tbody> </table>	Classe	Acurácia	testeBahiensis	0.78	testeBothriurus	0.94	testeCostatus	0.86	testeObjGeráis	0.98	testeSerrulatus	0.94
Classe	Acurácia												
testeBahiensis	0.78												
testeBothriurus	0.94												
testeCostatus	0.86												
testeObjGeráis	0.98												
testeSerrulatus	0.94												

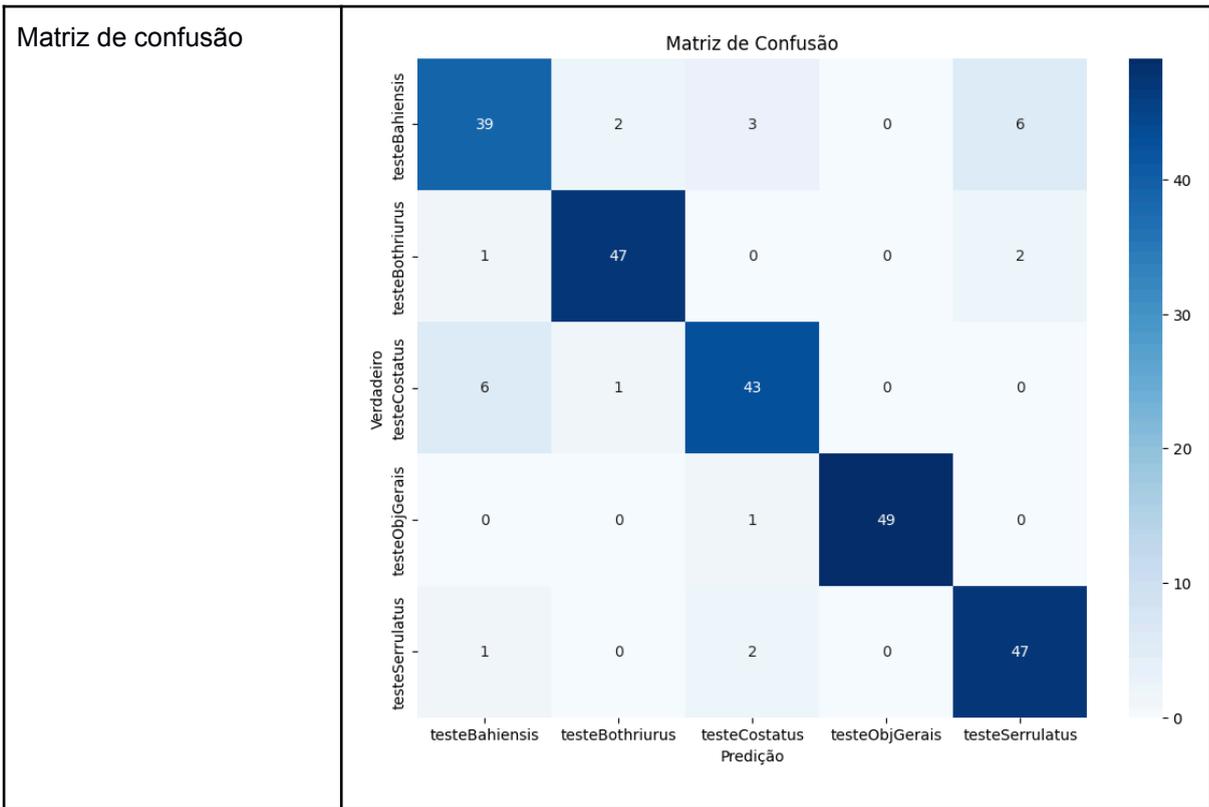


Tabela 22 - Testes com a rede EfficientNet-Lite

Testes													
Acurácia Total	84.80%												
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td>testeBahiensis</td> <td>0.74</td> </tr> <tr> <td>testeBothriurus</td> <td>0.8</td> </tr> <tr> <td>testeCostatus</td> <td>0.84</td> </tr> <tr> <td>testeObjGerais</td> <td>0.96</td> </tr> <tr> <td>testeSerrulatus</td> <td>0.88</td> </tr> </tbody> </table>	Classe	Acurácia	testeBahiensis	0.74	testeBothriurus	0.8	testeCostatus	0.84	testeObjGerais	0.96	testeSerrulatus	0.88
Classe	Acurácia												
testeBahiensis	0.74												
testeBothriurus	0.8												
testeCostatus	0.84												
testeObjGerais	0.96												
testeSerrulatus	0.88												

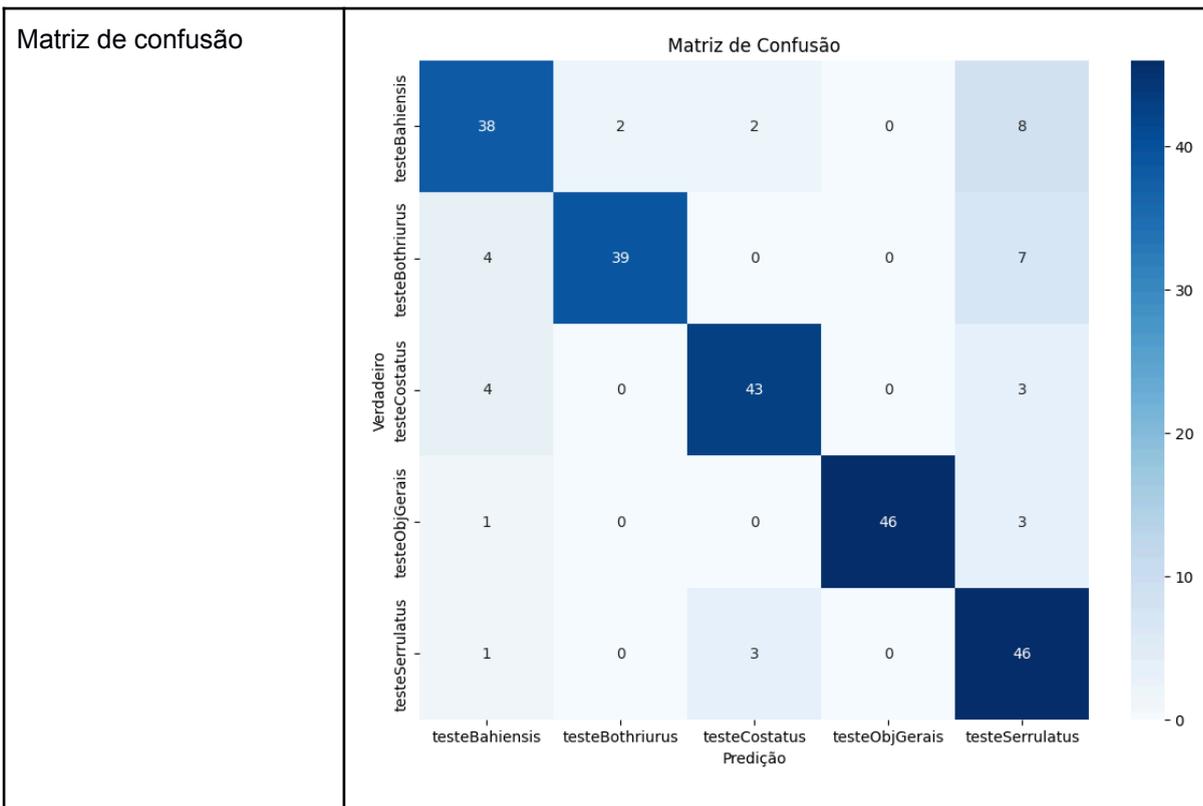


Tabela 23 - Testes com a rede Efficient-Net B0

Testes	
Acurácia Total	83.60%
Acurácia por categoria	<pre> Classe Acurácia ----- testeBahiensis 0.78 testeBothriurus 0.76 testeCostatus 0.84 testeObjGeraiis 0.92 testeSerrulatus 0.88 </pre>

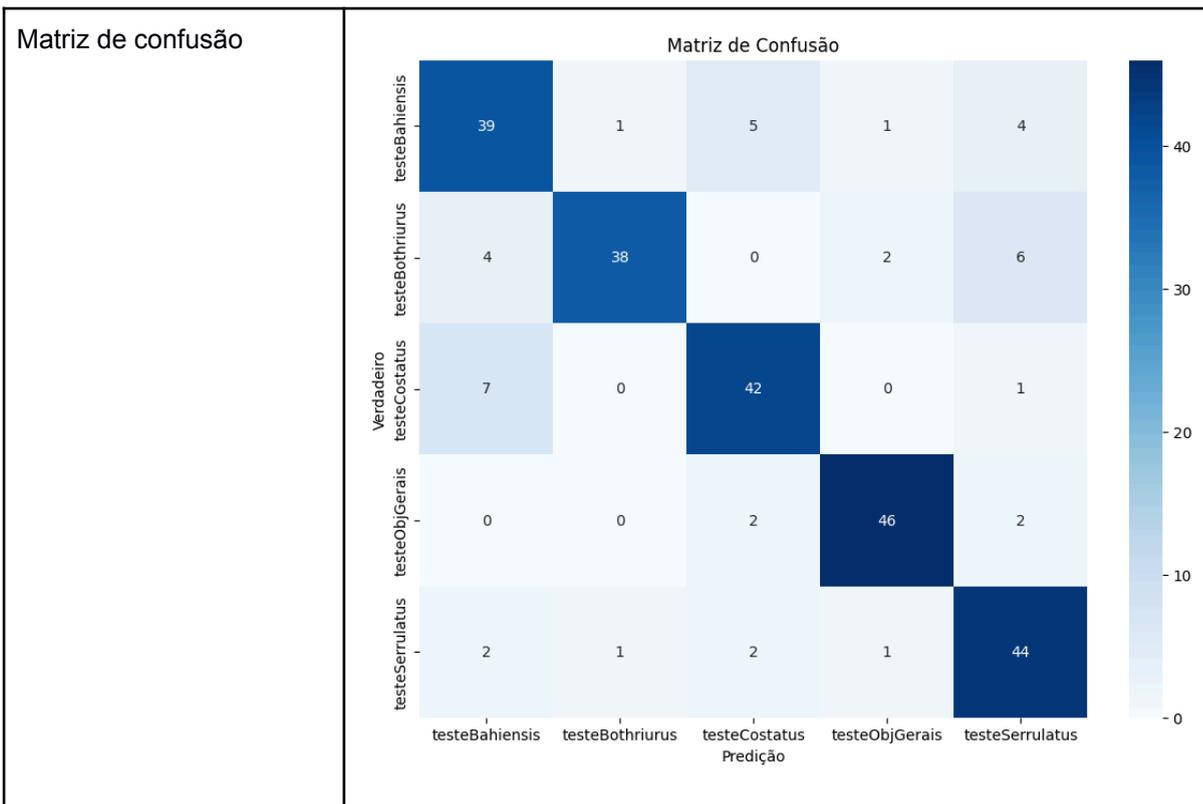


Tabela 24 - Testes com a rede MobileNetV3

Testes													
Acurácia Total	83.60%												
Acurácia por categoria	<table border="1"> <thead> <tr> <th>Classe</th> <th>Acurácia</th> </tr> </thead> <tbody> <tr> <td>testeBahiensis</td> <td>0.74</td> </tr> <tr> <td>testeBothriurus</td> <td>0.82</td> </tr> <tr> <td>testeCostatus</td> <td>0.82</td> </tr> <tr> <td>testeObjGerais</td> <td>0.96</td> </tr> <tr> <td>testeSerrulatus</td> <td>0.84</td> </tr> </tbody> </table>	Classe	Acurácia	testeBahiensis	0.74	testeBothriurus	0.82	testeCostatus	0.82	testeObjGerais	0.96	testeSerrulatus	0.84
Classe	Acurácia												
testeBahiensis	0.74												
testeBothriurus	0.82												
testeCostatus	0.82												
testeObjGerais	0.96												
testeSerrulatus	0.84												

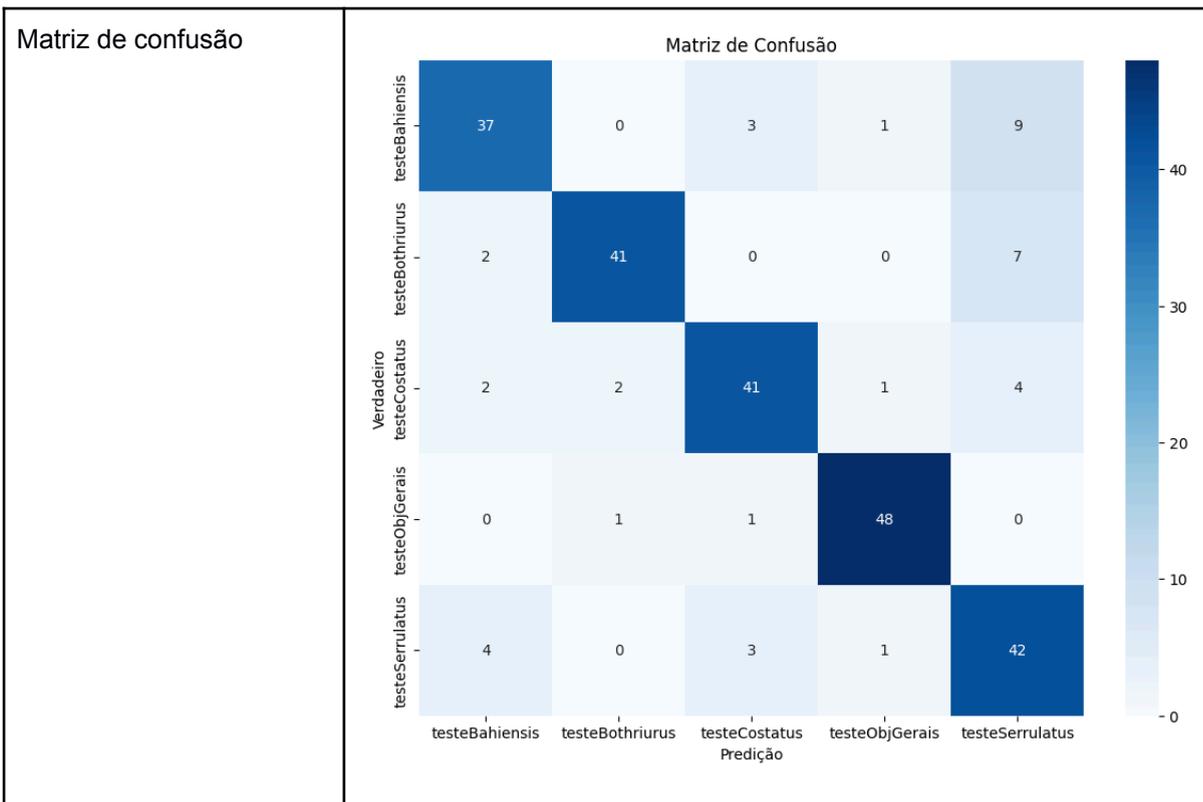
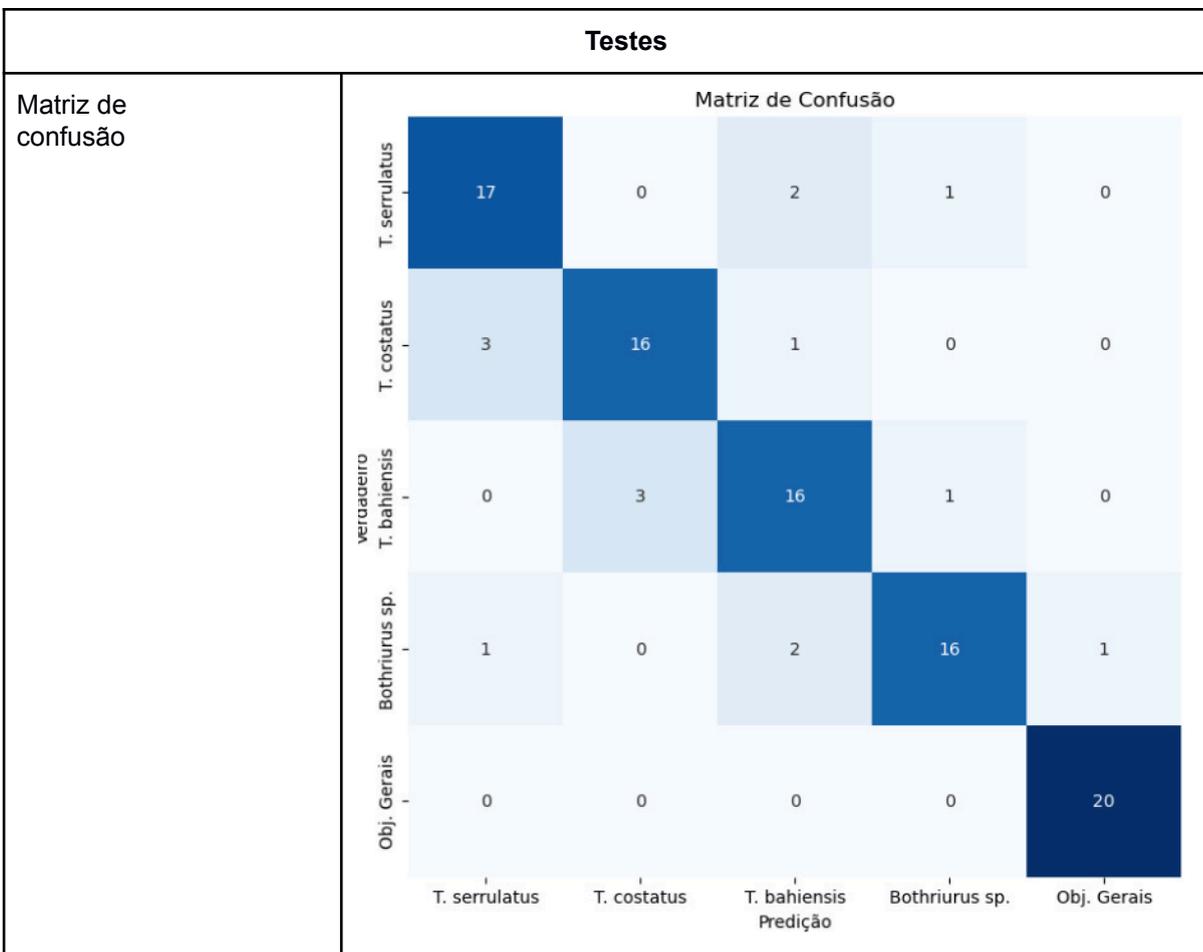


Tabela 25 - Testes com a rede MobileNetV2 com a ferramenta GTM



Acurácia por classe	<i>Tityus serrulatus</i>	0.85
	<i>Tityus bahiensis</i>	0.80
	<i>Tityus costatus</i>	0.80
	<i>Bothriurus</i>	0.80
	Objetos Gerais	1
Acurácia total	Total	$Acurácia\ total = \frac{0.85+0.80+0.80+0.80+1}{5} = \frac{4.25}{5} = 0.85$

4.5 Discussão

A análise abrangente da performance dos modelos de *ML* é apresentada, destacando métricas essenciais como acurácia, precisão, recall e F1-Score, conforme compilado na Tabela 26.

Tabela 26: Resultado dos treinamentos de diferentes modelos

Modelos analisados	Acurácia total	Precisão	Recall	F1-Score
ResNet-18	97.8%	97.8%	97.8%	97.8%
ResNet-34	96.5%	97%	96.5%	96.8%
EfficientNet Lite	95.9%	95.5%	95.9%	95.7%
EfficientNet B0	98.1%	97.7%	97.7%	97.7%
MobileNetV3	94.2%	93.6%	94.2%	93.9%
Google Teachable Machine				
MobileNetV2	93.2%	92.8%	93.2%	93%

A Tabela 27 exhibe os resultados dos testes realizados nos modelos, utilizando um conjunto de 50 imagens de cada uma das 5 classes.

Tabela 27: Resultados dos testes dos diferentes modelos

Modelos analisados	Acurácia total	Precisão	Recall	F1-Score
ResNet-18	88.4%	86.3%	88.4%	87.1%
ResNet-34	90%	87.9%	90%	88.8%
EfficientNet Lite	84.8%	84.8%	84.8%	84.8%
EfficientNet B0	83.6%	84.2%	83.6%	83.9%
MobileNetV3	83.6%	84.1%	83.6%	83.9%
Google Teachable Machine				
MobileNetV3	85%	81%	85%	82.7%

Pode-se observar que o modelo ResNet-34 atingiu os melhores resultados, com uma acurácia de 90% nos testes de classificação de escorpião. Além disso, outras métricas como precisão, recall e F1-Score também apresentam os melhores resultados com a ResNet-34, com resultados de 87.9%, 90% e 88.8%, respectivamente. Esses resultados são expressivos, considerando que as redes foram treinadas para serem implementadas em dispositivos móveis, e mesmo assim, foram capazes de fornecer uma classificação detalhada de escorpiões presentes no estado de Santa Catarina (*T. serrulatus*, *T. bahiensis*, *T. costatus* e gênero *Bothriurus*).

Também é importante destacar que o resultado obtido desses treinamentos aperfeiçoa significativamente os resultados obtidos vistos nos trabalhos correlatos, onde o único estudo capaz de identificar diferentes espécies de escorpião apresentou resultados de teste com 72% de acurácia, fazendo com que seja um salto importante para modelos preditivos de espécies escorpiônicas e também para a prevenção e primeiros socorros da população catarinense perante os riscos de interações com estes animais.

Mesmo com resultados expressivos e promissores durante o treinamento, os testes não conseguiram manter a alta acurácia, fazendo com que não atingissem um dos requisitos, o de acurácia maior que 95%. Os resultados que mais se mostraram

perto deste número foram os da rede ResNet18 e da ResNet34, com 88.4% e 90%, respectivamente. Assim sendo, é crucial manter a cautela e a prudência ao considerar a utilização desses modelos na prática, especialmente considerando o contexto do alto risco à saúde humana inferida na predição desses modelos. Embora uma taxa de acurácia de 90% possa parecer satisfatória em certos casos, é de suma importância analisar o caso de uso em questão.

Nesse caso, altas taxas de precisão e recall são imprescindíveis para minimizar os falsos positivos e os falsos negativos, respectivamente. Uma alta taxa de recall é crucial em cenários onde não detectar uma espécie perigosa pode levar a consequências graves, como a falta de um aviso ou tratamento adequado para uma picada venenosa. Portanto, garantir que o modelo detecte todas as instâncias de escorpiões perigosos é vital para a segurança pública. Já falsos positivos podem levar a alarmes desnecessários, pânico e possivelmente ao uso de recursos médicos de forma inadequada. Assim, alta precisão é desejável para evitar tais situações e garantir que as ações corretivas sejam tomadas apenas quando necessário.

A matriz de confusão dos modelos também oferece informações valiosas sobre como eles estão performando em termos de recall e precisão. Observa-se que, frequentemente, o modelo se confunde entre espécies de escorpiões perigosos, resultando em falsos positivos. No entanto, neste caso específico, mesmo que o modelo confunda duas espécies perigosas, o tratamento e o resultado final seriam os mesmos, uma vez que ambas as espécies exigem precauções semelhantes. Isso conclui que, embora a minimização de falsos positivos seja importante, no contexto de espécies perigosas de escorpiões, esses erros não têm um impacto crítico sobre os cuidados e tratamentos subsequentes.

5 DESENVOLVIMENTO DO APLICATIVO MÓVEL

Neste capítulo, é apresentado o desenvolvimento do aplicativo móvel, detalhando as etapas desde a concepção até a implementação inicial. O aplicativo tem como principal objetivo facilitar a identificação de escorpiões pelas pessoas, utilizando o modelo treinado usando a ferramenta *Google Teachable Machine* e incorporados na plataforma *App Inventor*. Além disso, o aplicativo fornecerá

informações essenciais sobre as espécies identificadas, orientações de segurança e primeiros socorros, contribuindo para a prevenção de acidentes.

5.1 Requisitos do Aplicativo

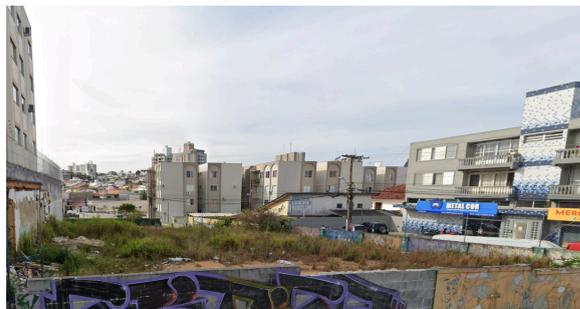
Para proporcionar uma visão abrangente das expectativas e especificações que acompanham o aplicativo, a Tabela 28 apresenta a necessidade identificada do aplicativo.

Tabela 28: Necessidades identificadas

Nome do aplicativo	ScorplD SC
Objetivo geral do aplicativo	<p>Ajudar o cidadão a identificar e classificar através da câmera do celular espécies de escorpiões por meio de Machine Learning para informar os possíveis perigos. Existem 3 espécies com peçonha capaz de matar um humano em Santa Catarina:</p> <ul style="list-style-type: none"> - <i>Tityus serrulatus</i> - <i>Tityus costatus</i> - <i>Tityus bahiensis</i> <p>O modelo também é capaz classificar o gênero <i>Bothriurus</i>, cuja peçonha não é capaz de matar um humano. É considerado também a classe ObjGerais, para identificar o usuário de que a imagem não se trata de um escorpião.</p>
História do usuário	COMO cidadão EU QUERO, tirar uma foto de um escorpião PARA saber se é uma espécie perigosa
Há aplicativo que já tem as mesmas funcionalidades?	Há aplicativos capazes de classificar animais de maneira geral, porém o aplicativo ScorplD SC é único no que se diz respeito ao seu escopo. Como um aplicativo feito para a população catarinense, ele utiliza da inteligência artificial para obter resultados de acordo com a espécie de escorpião encontrada.
Requisitos funcionais	
História de usuário	COMO cidadão EU QUERO, tirar uma foto de um escorpião PARA saber se é uma espécie perigosa.
Funcionalidade (Requisito funcional)	<p>Capturar imagem: O aplicativo permite que o usuário capture uma imagem de um escorpião utilizando a câmera do celular.</p> <p>Classificação de espécie: O aplicativo utiliza Machine Learning para a classificação de espécie de escorpião, exibindo um resultado de forma clara e compreensível, indicando se a espécie é perigosa para humanos ou não.</p> <p>Informações: O aplicativo permite que o usuário se informe sobre precauções a serem tomadas e procedimentos em caso de acidentes escorpiônicos.</p>
Frequência de uso da tarefa	Mensal, anual.
Dados de entrada/saída	<p>Entrada: Imagem capturada.</p> <p>Saída: Texto informativo com o resultado da classificação do escorpião identificado pelo modelo.</p>

Dependência da tarefa	Um celular com acesso à internet e a loja de aplicativos disponível no Android, assim como a própria câmera do celular, de preferência com qualidade decente, para um bom resultado.
Resultado da tarefa	Texto informativo com o resultado da classificação do escorpião identificado pelo modelo.
Risco resultante de erro	Risco à vida humana
Demandas críticas de segurança	Informação errada pode levar riscos à saúde, incluindo morte.

Tabela 29 - Caracterização do ambiente de uso

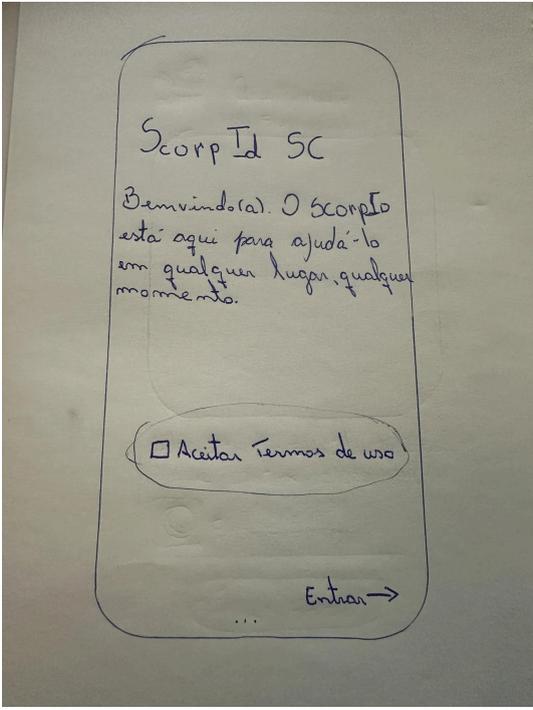
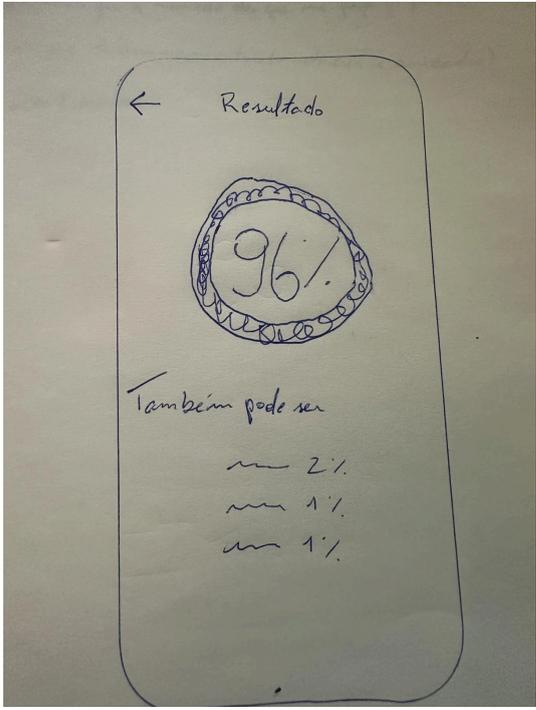
Ambiente	<p>Na rua / em casa (escorpiões têm tendência a aparecer perto de terrenos baldios, construções civis e/ou casas próximas a esses endereços)</p>  <p>Fonte: (Google, 2022)</p>
Horários de uso	Em qualquer momento do dia
Modo de interação	Individual
Disponibilidade de assistência	Não
Interrupções	Não
Política de uso de dispositivos móveis	Restrito
Acesso wi-fi	Talvez não
Conformidade com guia(s) de estilo	Sim, material design 3
Ambiente visual	Luz do dia, iluminação artificial
Ambiente auditivo	Pode ter muito barulho, possível distração auditiva
Postura do usuário	Em pé, mãos livres
Uso de roupas protetoras	Luvas protetoras, óculos de sol

5.2 Design de Interface

5.2.1 Sketch

Em um primeiro passo foram projetadas as telas em forma de *sketches*, que são desenhos à mão livre em um pedaço de papel ou em uma ferramenta digital que proporcionam uma representação básica do seu conceito (Babich, 2020). A Tabela 30 apresenta os *sketches* do app conceitual antes do desenvolvimento do mesmo.

Tabela 30: *Sketches* do aplicativo ScorpID SC

Sketch Tela Inicio	Sketch Tela Resultado
	

5.2.2 Wireframe

A partir dos *sketches* foram criados *wireframes*, que são representações de baixa fidelidade que determinam a estrutura e os elementos essenciais da interface do usuário. Os *wireframes* utilizados neste projeto podem ser visualizados na Figura 32.

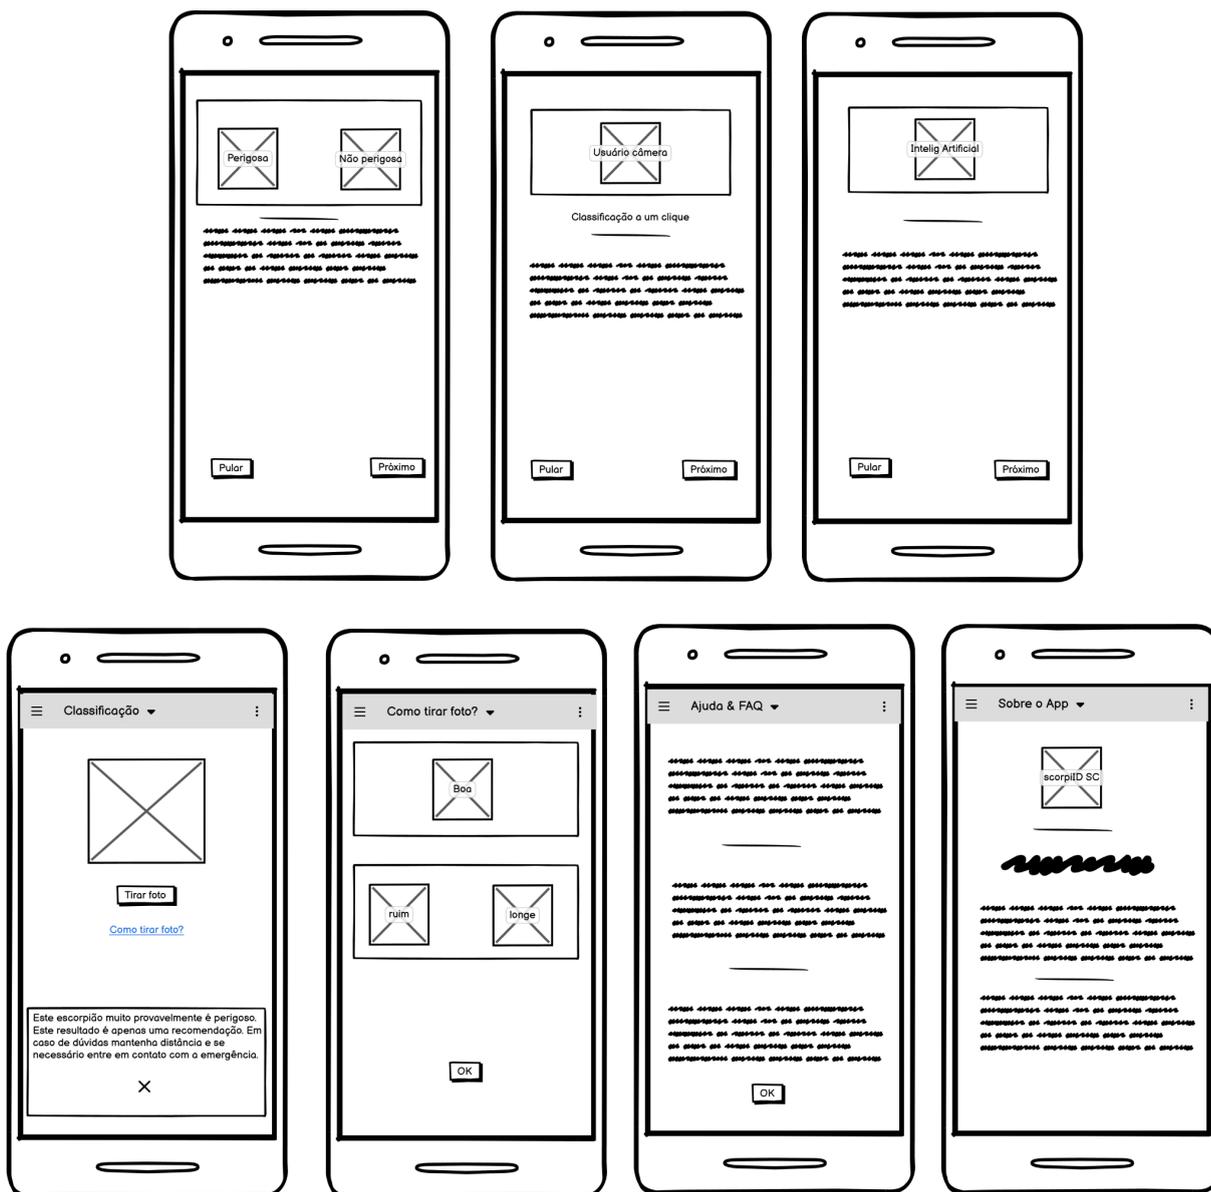


Figura 36: Wireframes do App

5.2.3 Design visual

O design visual foi feito com o intuito de gerar uma simulação interativa que permite testar a funcionalidade e a usabilidade do aplicativo antes da implementação completa.

Tabela 31: Design do aplicativo ScorpID SC

Design da tela inicial do app	Design do Onboarding sobre perigos
-------------------------------	------------------------------------



**COMPUTAÇÃO
NA ESCOLA**

GQS INCoD UNIPES UNIVERSIDADE FEDERAL DE SANTA CATARINA

Bem vindo ao
ScorpiD SC

Este é um aplicativo desenvolvido para classificar diferentes espécies de escorpiões a partir de imagens capturadas pelos usuários.

Próximo

Design do Onboarding de dicas

Com espinho Sem espinho




Perigosa X Não perigosa V

Este aplicativo simplifica a identificação de escorpiões, distinguindo entre espécies perigosas e não perigosas

Pular Próximo

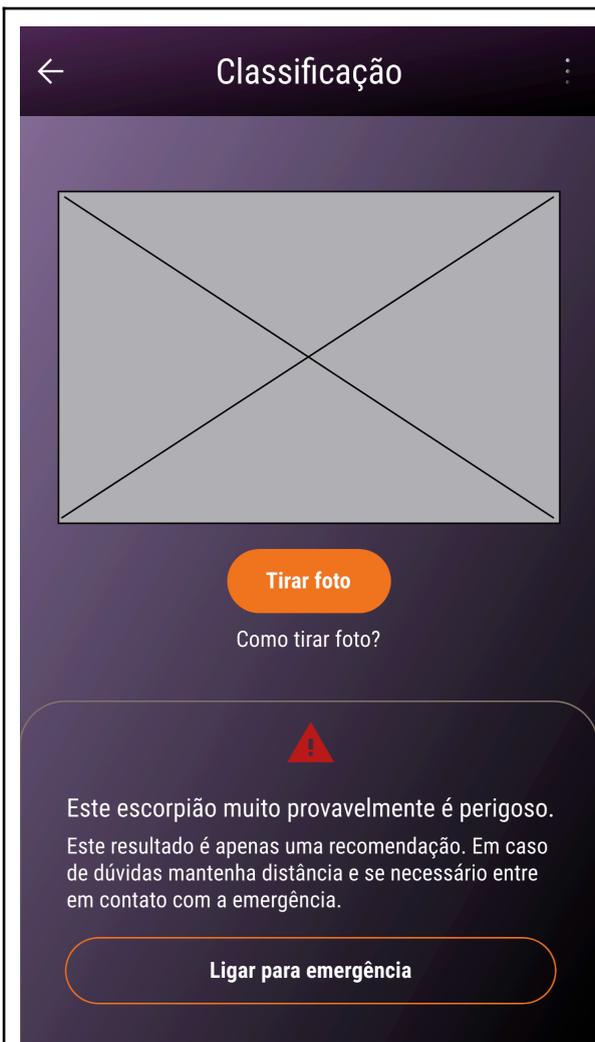
Design do Onboarding sobre IA



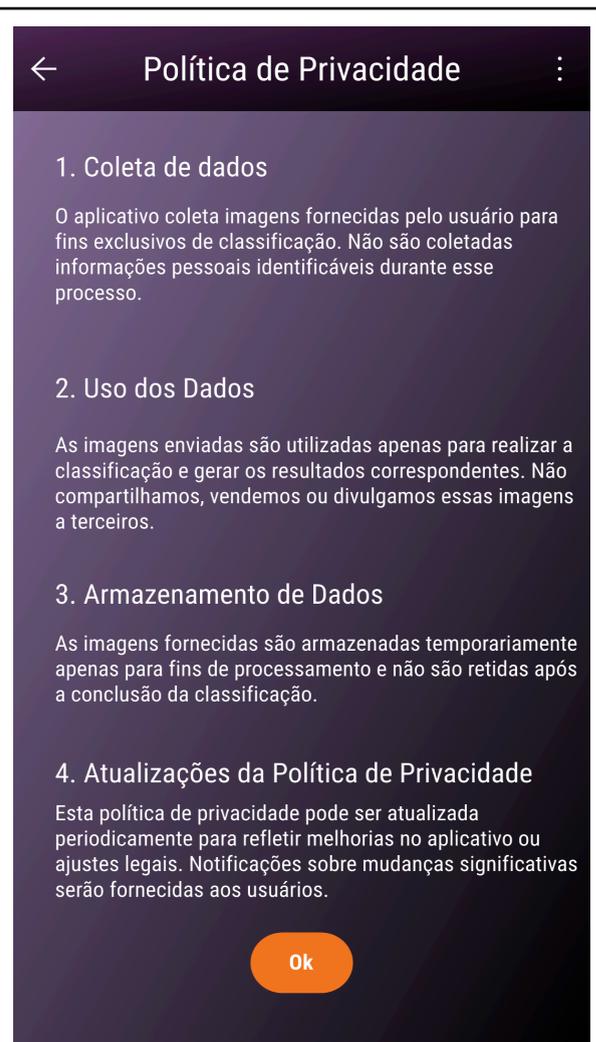
Design da tela principal com classificação positiva de escorpiões letais



Design da tela de política de privacidade



Design da tela de dicas e instruções



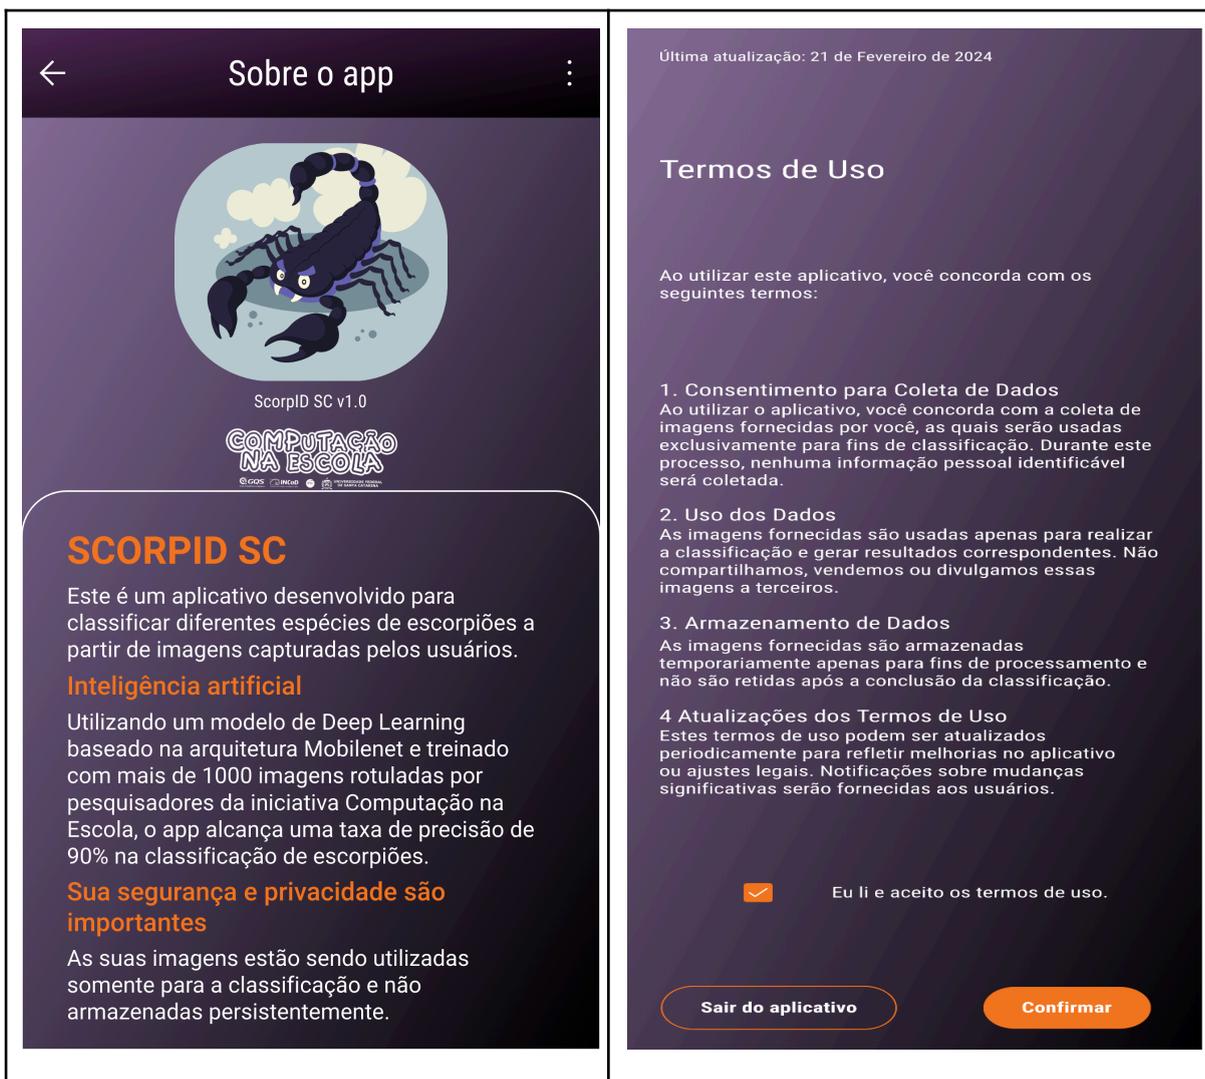
Design da tela de ajuda e suporte



Design da tela sobre o aplicativo



Design da tela de termos de uso



Todas as imagens que compõem o aplicativo são sem direitos autorais, sendo adaptadas para o contexto que o aplicativo se dispõe (Tabela 32).

Tabela 32: Imagens utilizadas no aplicativo ScorpID SC

	<p>Imagem de upklyak no Freepik (Adaptada pelo autor, 2024)</p>
---	---

	<p>Imagem de Freepik (Adaptada pelo autor)</p>
	<p>Imagem de vectorjuice no Freepik (Adaptada pelo autor)</p>

5.3 Desenvolvimento do Aplicativo

A implementação do aplicativo *ScorpiD SC* por meio do *App Inventor* (appinventor.mit.edu), uma plataforma que permite a criação de aplicativos por meio de uma interface com elementos visuais e blocos lógicos sequenciais que representam comandos, conforme vistos na Figura 37. Foi escolhido este ambiente com o âmbito de servir como um exemplo para o incentivo do estudo de computação e programação desde as etapas do ensino fundamental e médio. O *ScorpiD SC* fornece aos alunos a oportunidade de desenvolver habilidades em programação e design de interface de usuário de uma maneira acessível e intuitiva. Ao utilizar o *App Inventor*, os estudantes podem criar seus próprios aplicativos, o que os capacita a serem criadores de soluções de tecnologia da informação desde cedo. Essa abordagem não apenas os familiariza com os conceitos fundamentais da computação, mas também os prepara para explorar áreas avançadas, como *Machine Learning*, à medida que avançam em sua jornada educacional. O modelo treinado utilizando o GTM foi implantado no aplicativo usando a extensão TMIC (*Teachable Machine Image Classifier*) (Oliveira, 2022).

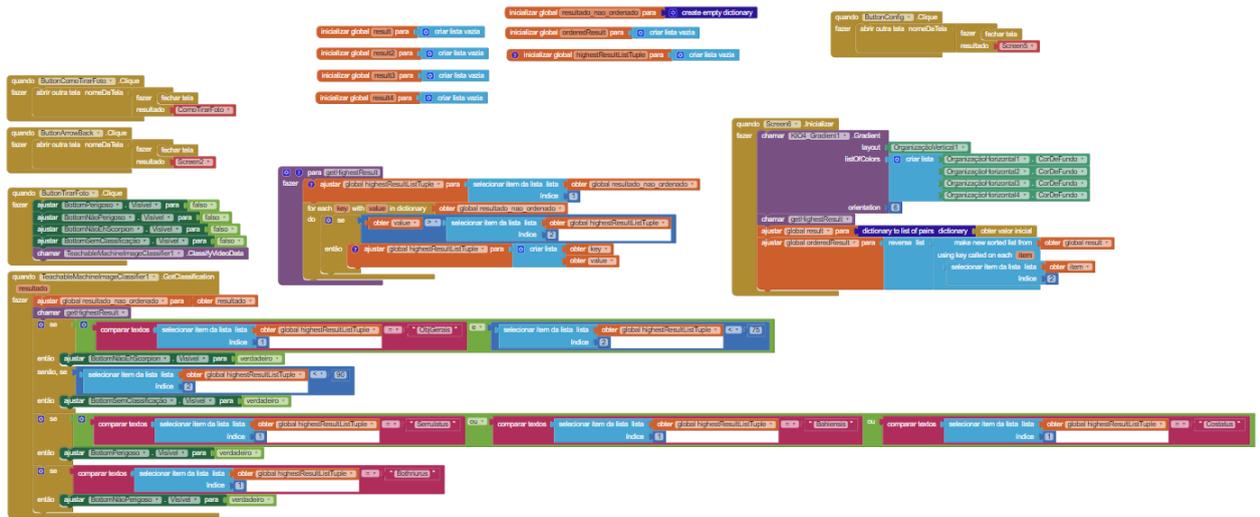


Figura 37: Blocos lógicos do ScorpID SC no App Inventor

Com base no design de interface projetado foram desenvolvidas as telas no *App Inventor*.

Tabela 33: Capturas de tela do aplicativo ScorpID SC implementado no *App Inventor*

Tela Inicial	Onboarding sobre perigos
--------------	--------------------------



Onboarding de dicas



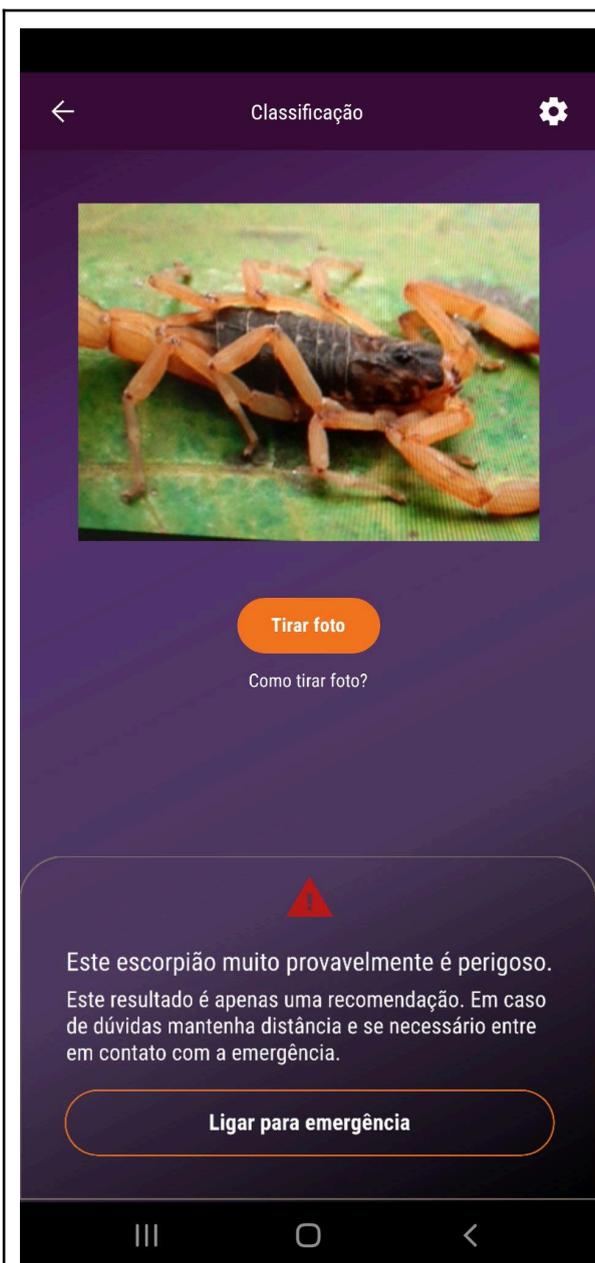
Onboarding sobre IA



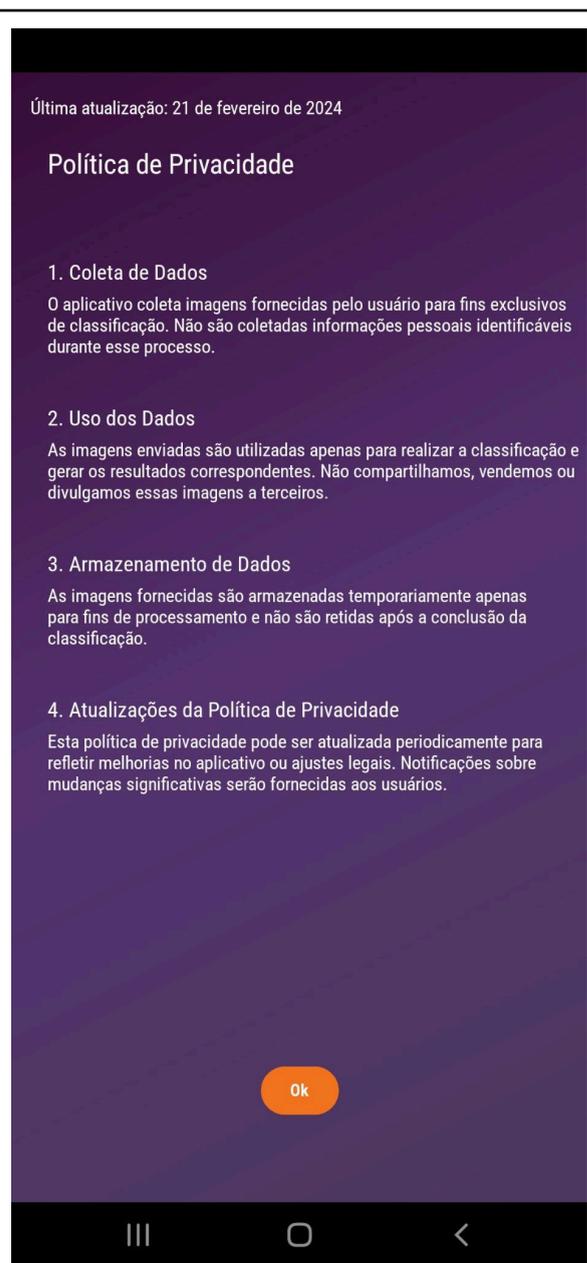
Tela principal com classificação positiva de escorpiões letais



Tela de política de privacidade



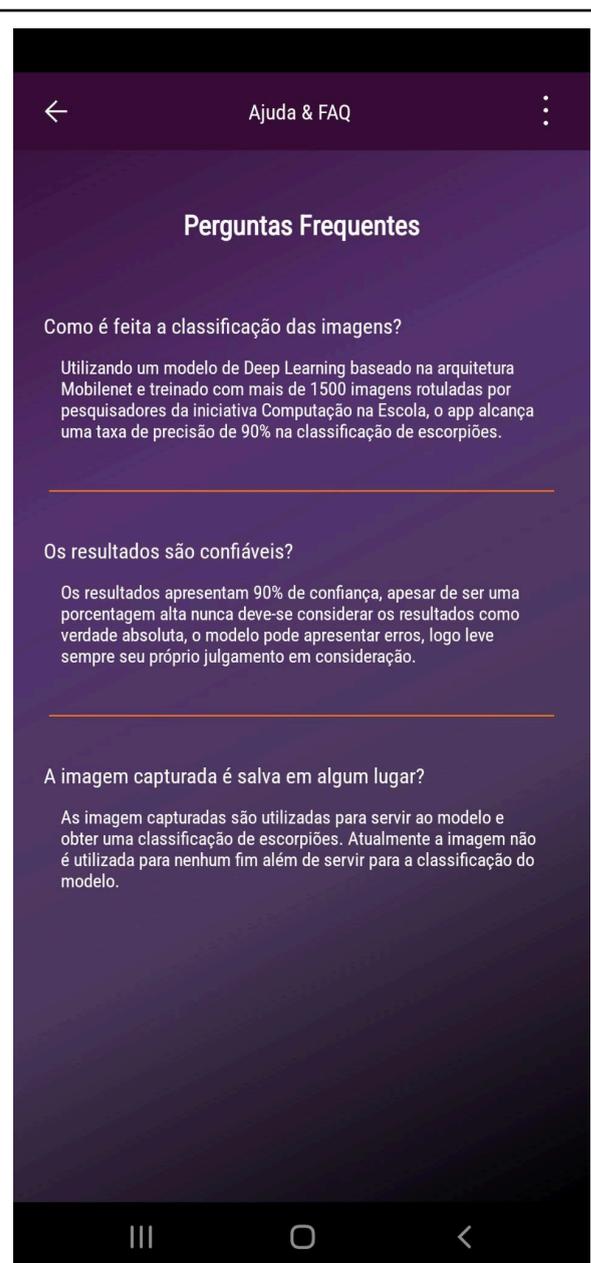
Tela de dicas e instruções



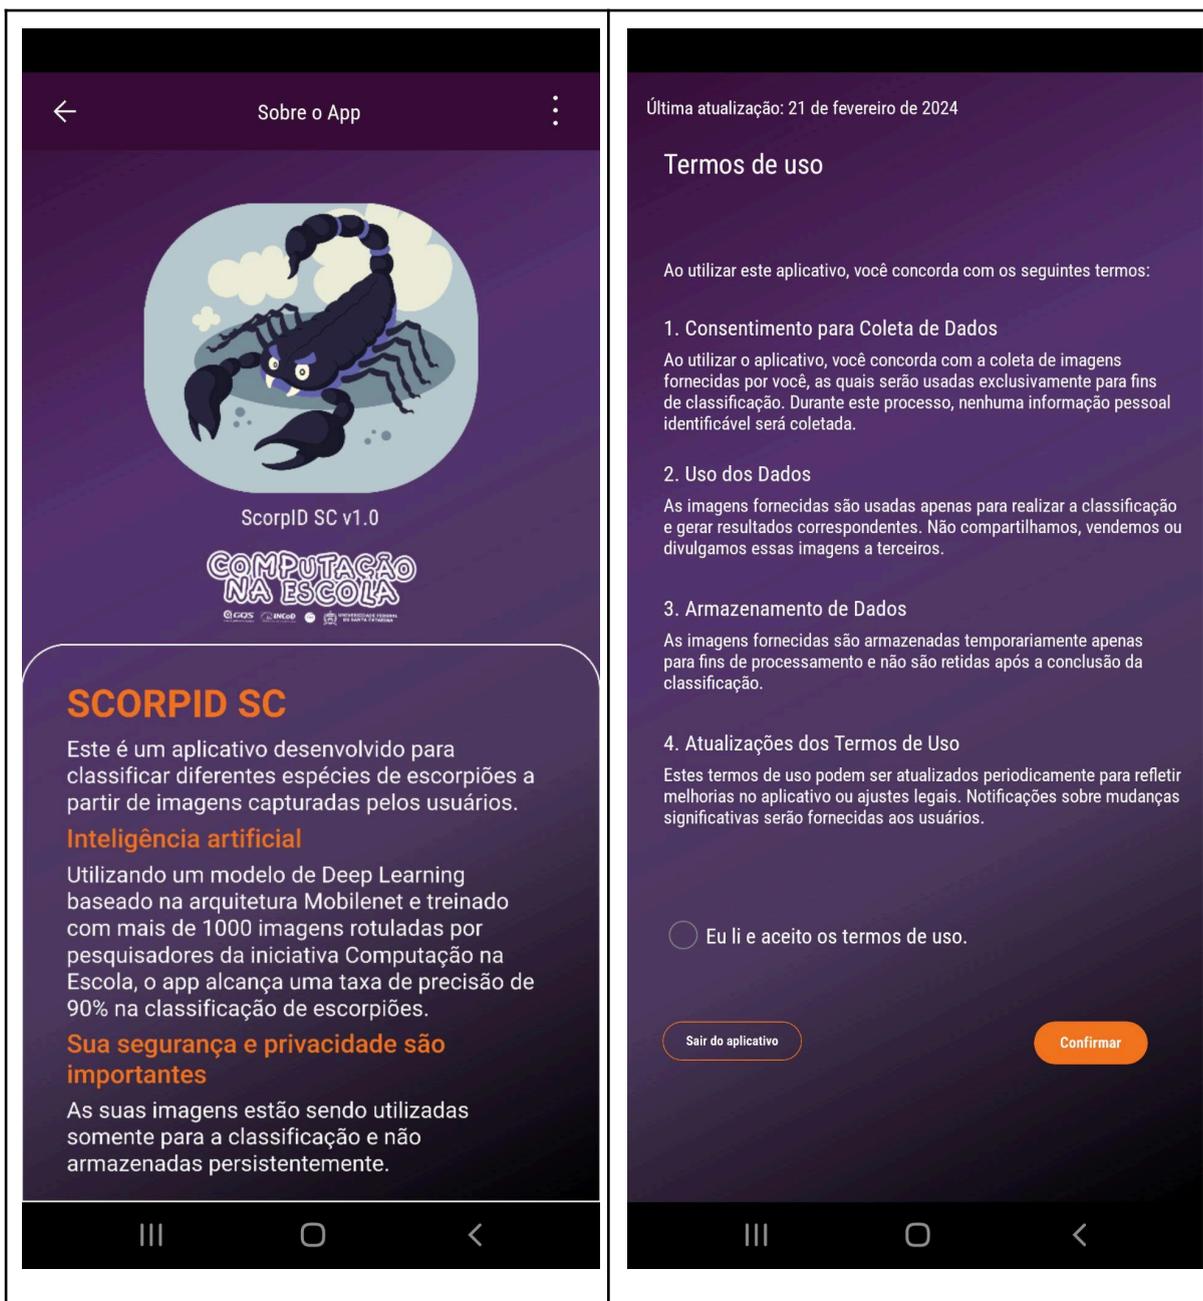
Tela de ajuda e suporte



Tela sobre o aplicativo



Tela de termos de uso



Após o desenvolvimento do aplicativo, o mesmo foi exportado, gerando assim um arquivo de extensão (.aia). O arquivo pode ser conferido no link [Google Drive](#) e está sob a licença CC BY-NC-SA 4.1 Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International. Lá também pode ser conferido o código feito para o treinamento e teste das redes e outros arquivos úteis.

6 CONCLUSÃO

Por uma análise relacionada aos escorpiões e à aplicação de *deep learning* (O1), juntamente com uma revisão detalhada do estado atual da classificação de escorpiões utilizando *deep learning* (O2), foram estabelecidas as bases para este estudo. Em relação ao OE3, foi realizado o desenvolvimento e teste de diversos modelos de classificação utilizando técnicas de *deep learning*, com foco na identificação de escorpiões letais presentes em Santa Catarina. Apesar de muitos dos modelos terem alcançado resultados satisfatórios durante o treinamento, os testes mostraram que o modelo ResNet34 obteve a melhor acurácia de apenas 90%, abaixo da meta de 95% estabelecida. Isso indica a necessidade de melhorias para aumentar a precisão dos modelos. No entanto, mesmo sem atingir o objetivo estabelecido, os modelos ainda mostram um desempenho promissor, com capacidade de classificar escorpiões com uma acurácia de pelo menos 90%. Os resultados deste estudo são relevantes, pois o modelo desenvolvido consegue identificar escorpiões de dois gêneros e três espécies diferentes: *Tityus* (*costatus*, *serrulatus* e *bahiensis*) e *Bothriurus*. Essa abordagem vai além de estudos anteriores que focaram apenas na distinção entre *Tityus* e *Bothriurus*, permitindo uma classificação mais precisa das espécies, o que é importante para estratégias de controle mais eficazes.

Comparado a trabalhos anteriores que também classificavam espécies de escorpiões, este estudo apresenta resultados mais abrangentes. Em uma pesquisa similar que analisava *Tityus confluens* e *T. trivittatus*, os resultados foram significativamente menores (72%). É importante destacar que o estudo deste trabalho também priorizou o uso de redes neurais mais leves, visando à viabilidade de implementação em aplicativos móveis e à captura de imagens diretamente com a câmera do celular. Essa abordagem tem o potencial de beneficiar a população, tornando mais acessível um classificador eficaz de escorpiões. Além disso, oferece uma ferramenta valiosa para profissionais de saúde pública e outros envolvidos no controle de ataques de escorpiões.

Posteriormente, o modelo treinado pelo *Google Teachable Machine* foi implantado em um aplicativo para dispositivos Android, usando através da plataforma *App*

Inventor, com o objetivo de disponibilizar este App de classificação de escorpiões com o intuito de auxiliar no ensino a propagação da computação no ambiente escolar brasileiro.

Mesmo assim, existem melhorias significativas para pesquisas futuras no campo da classificação de escorpiões utilizando *deep learning*. Uma maneira de melhorar a acurácia do modelo seria por meio de um conjunto de dados maior, com mais exemplos das espécies presentes no estado, seja por meio de *data augmentation* ou por coletas de novas imagens, para que os modelos sejam mais precisos na identificação das espécies de escorpiões. Com melhorias contínuas e avanços nesta área, é esperado que o uso de *deep learning* na identificação de escorpiões continue a evoluir, oferecendo contribuições significativas para a prevenção de acidentes e o manejo adequado desses aracnídeos em diferentes contextos.

REFERÊNCIAS

- AHMED, T.; SABAB, N. H. N. **Classification and understanding of cloud structures via satellite images with EfficientUNet**. Disponível em: <<https://arxiv.org/abs/2009.12931>>. Acesso em: 14 mai. 2024.
- ALBUQUERQUE, I. C. S.; ALBUQUERQUE, H. N.; ALBUQUERQUE, E. F. Escorpionismo em Campina Grande - PB. *Revista de Biologia e Ciências da Terra*. v. 4. n. 1. 2004.
- ALVES, G. **Entendendo Redes Convolucionais (CNNs)**. 8 out. 2018. Disponível em: <<https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>>. Acesso em: 10 mai. 2024.
- BABICH, N. Sketch, Wireframe, Mockup, and Prototype: Why, When and How. 17 ago. 2020. Disponível em: <<https://uxplanet.org/sketch-wireframe-mockup-and-prototype-why-when-and-how-29a25b3157c4>>. Acesso em: 3 ago. 2023.
- BRAZIL, T; PORTO, T. **Os escorpiões**. Salvador: EDUFBA, 2011. E-book (90 p.). ISBN 978-8523207526. Disponível em: <[http://www.noap.ufba.br/biotabahia/brazil_porto_os_escorpiões\(livro\)_2011.pdf](http://www.noap.ufba.br/biotabahia/brazil_porto_os_escorpiões(livro)_2011.pdf)>. Acesso em: 19 mai. 2023.
- BROWNELL, P.; POLIS, G. A. **Scorpion biology and research**. Oxford, England; New York: Oxford University Press, 2001. 431 p. ISBN 0195084349.
- BRUNA, M. H. V. **Picada de escorpião**. 11 ago. 2020. Disponível em: <<https://drauziovarella.uol.com.br/doencas-e-sintomas/picada-de-escorpio/>>. Acesso em: 4 abr. 2023.
- BUTANTAN, 2021. **Escorpiões: entenda por que eles estão cada vez mais próximos dos homens**. Disponível em: <<https://butantan.gov.br/noticias/escorpioes-entenda-por-que-eles-estao-cada-vez-mais-proximos-dos-homens#:~:text=De%20acordo%20com%20Denise%20Candido>>. Acesso em: 25 mai. 2023.
- CANDIDO, M. D.; FAN, W. H. **Controle de escorpiões de importância em saúde**. São Paulo: Fundação Butantan, 2019. 16 p.
- CHIPPAUX, J.-P. GOYFFON, M. Epidemiology of scorpionism: A global appraisal. *Acta Tropica*, v. 107, n. 2, p. 71–79, ago. 2008.
- CHOLLET, F. **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: 16 ago. 2022.

CIATox/SC. **Boletim Epidemiológico - Animais Peçonhentos em 2022**. 2023.

Disponível em:

<<https://ciatox.saude.sc.gov.br/index.php/santa-catarina-lista-dos-hospitais-de-soros-antivenenos.html?view=category&download=71:boletim-epidemiologico-n-ii-ano-2022-acidentes-por-animais-peconhentos&id=8:boletins/>>. Acesso em: 29 abr. 2023.

COLOGNA, C. et al. **Tityus serrulatus Scorpion Venom and Toxins: An Overview**. Protein & Peptide Letters, v. 16, n. 8, p. 920–932, 1 ago. 2009.

CORDEIRO, A. M et al. **Revisão sistemática: uma revisão narrativa**. Rev. Col. Bras. Cir, v. 34, n. 6, p. 428-431, 2007.

DESHPANDE, A. **A Beginner's Guide To Understanding Convolutional Neural Networks**. 20 jul. 2016. Disponível em:

<<https://adeshpande3.github.io/A-Beginner's-Guide-To-Understanding-Convolutional-Neural-Networks/>>. Acesso em: 3 jun. 2024.

DIVE, **Acidentes, Incidências e Óbitos por animais peçonhentos, por tipo de acidente e por regiões de saúde em Santa Catarina**. Disponível em:

<<https://dive.sc.gov.br/phocadownload/doencas-agrivos/Animais%20pe%C3%A7onhetos/Boletins/Acidentes-I-Obitos-Animais-Peconhentos-2011-2022.pdf>>. Acesso em 04 jun. 2023.

DSA, E. Capítulo 3 - **O Que São Redes Neurais Artificiais Profundas ou Deep Learning?** Disponível em:

<<https://www.deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas>>. Acesso em: 14 abr. 2024

DSA. Capítulo 4 - **O Neurônio, Biológico e Matemático**. Disponível em:

<<https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>>. Acesso em: 14 abr. 2024.

DWIVEDI, H. **Comparing MobileNet Models in TensorFlow**. 2019. Disponível em:

<<https://www.kdnuggets.com/2019/03/comparing-mobilenet-models-tensorflow.html>>. Acesso em: 25 mai. 2024.

ESCOVEDO, T. Machine Learning: Conceitos e Modelos — Parte I: Aprendizado Supervisionado. 28 jun. 2020. Disponível em:

<<https://tatianaesc.medium.com/machine-learning-conceitos-e-modelos-f0373bf4f445>>. Acesso em: 2 jun. 2024.

ESPÍNDOLA, B., M. **Desenvolvimento de um Modelo de Classificação de Imagens de Larvas de Mosquitos usando Deep Learning**, Trabalho de Conclusão de Curso. (Graduação em Sistemas de Informação) – Universidade Federal de Santa Catarina, Florianópolis, Brasil, 2023.

GALLAGHER, J. **What is Data Augmentation? The Ultimate Guide**. 23 ago. 2023.

Disponível em: <<https://blog.roboflow.com/data-augmentation/>>. Acesso em: 26 mai.

2024.

GESSONI, L. As diferentes formas de aprendizado de máquina. 14 abr. 2021.

Disponível em:

<<https://www.eldorado.org.br/blog/as-diferentes-formas-de-aprendizado-de-maquina/>

>. Acesso em: 2 jun. 2024.

GOODFELLOW, I J.; B, Y; C, A. **Deep Learning**. Cambridge, MA, USA: MIT Press, 2016.

GRESSE VON WANGENHEIM, C., VON WANGENHEIM, A. (2021). **Visão geral de um processo interativo centrado no ser humano para ensinar aprendizado de máquina no ensino fundamental e médio**. Disponível em

<<http://www.gqs.ufsc.br/files/2020/02/GQSTemplate-RelatorioTecnico-HumanCentricProcess-v10.pdf>>. Acesso em: 12 ago. 2023.

GUO, Y. et al. **SpotTune: Transfer Learning through Adaptive Fine-tuning**.

Disponível em: <<https://arxiv.org/abs/1811.08737>>. Acesso em: 28 abr. 2024.

HADDAWAY, N. R. et al. **The Role of Google Scholar in Evidence Reviews and Its Applicability to Grey Literature Searching**. PLOS ONE, v. 10, n. 9, p. e0138237, 17 set. 2015.

HAYKIN, S. S. **Neural networks and learning machines**. Delhi; Chennai: Pearson, 2016.

HE, K. et al. **Deep Residual Learning for Image Recognition**. arXiv (Cornell University), 10 dez. 2015.

HJELLE, J. T. Anatomy and morphology. In: POLIS, G. A. (Org.). **The biology of scorpions**. Stanford: Stanford University Press, 1990. p. 9-63.

HOWARD, A. G. et al. **MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications**. arXiv (Cornell University), 16 abr. 2017.

IBM CLOUD EDUCATION. **What are Neural Networks?** Disponível em:

<<https://www.ibm.com/cloud/learn/neural-networks>>. Acesso em: 17 ago. 2023.

LECUN, Y; BENGIO, Y; HINTON, G. **Deep learning**. Nature, v. 521, n. 7553, p.

436-444, maio 2015. Disponível em: <<https://doi.org/10.1038/nature14539>>. Acesso em: 8 jun. 2024.

LI, X. et al. **A Novel Method for Ground-Based Cloud Image Classification Using Transformer**. Remote Sensing, v. 14, n. 16, p. 3978–3978, 16 ago. 2023.

LIU, R. **Higher accuracy on vision models with EfficientNet-Lite**. TensorFlow Blog. 16 mar. 2020. Disponível em

<<https://blog.tensorflow.org/2020/03/higher-accuracy-on-vision-models-with-efficientnet-lite.html>>. Acesso em 14 abr 2023.

LOURENÇO, R. W. **Scorpions and life- history strategies: from evolutionary dynamics toward the scorpionism problem**. Journal of Venomous Animals and Toxins including Tropical Diseases, v. 24, n.19, p. 1-12. 2018.

MANIR, M. Por demora em diagnóstico ou falta de antídoto, escorpiões passam a matar mais que cobras no Brasil. 9 jul. 2018. Disponível em: <<https://www.bbc.com/portuguese/brasil-44686829>>. Acesso em: 16 mai. 2024.

MEAZZINI, L. Tutorial — **Transfer Learning aplicado no reconhecimento de flores**. 9 mai. 2019. Disponível em: <<https://medium.com/ensina-ai/tutorial-transfer-learning-3972cac5e9b5>>. Acesso em: 2 jun. 2024.

MINISTÉRIO DA SAÚDE. **Manual de Controle de Escorpiões - 2009** — Ministério da Saúde. Disponível em: <<https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/a/animais-peconhentos/acidentes-por-escorpioes/publicacoes/manual-de-controle-de-escorpioes-2009/view>>. Acesso em: 29 mai. 2023.
MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997.

MUZAMMIL, Z. B. **Unleashing the Power of MobileNet: A Comparison with Simple Convolutional Neural Networks**. Disponível em: <<https://medium.com/@zaidbinmuzammil123/unleashing-the-power-of-mobilenet-a-comparison-with-simple-convolutional-neural-networks-71d49f8c86ef>>. Acesso em: 16 mai. 2024.

NETO, H. F.; PARDAL, P. P. O. **Escorpiões e escorpionismo na área metropolitana de Belém e arredores, estado do Pará, Brasil (Chelicerata Scorpiones)**. Na. Acad. Med. Pará. Belém, v.7. P.31-35, 1996.

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

ORACLE. **Ciclo de vida de modelos de machine learning**. Disponível em: <<https://www.oracle.com/br/a/ocom/docs/data-science-lifecycle-ebook-pt-br.pdf>>. Acesso em: 2 jun. 2024.

Oracle. **O que é Machine Learning?** Disponível em: <<https://www.oracle.com/br/artificial-intelligence/machine-learning/what-is-machine-learning/>>. Acesso em 30 mai. 2024

SRUDEEP, P. A. **An Overview on MobileNet: An Efficient Mobile Vision CNN**. 10 jul. 2020. Disponível em: <<https://medium.com/@godeep48/an-overview-on-mobilenet-an-efficient-mobile-visio>>

[n-cnn-f301141db94d](#)>. Acesso em: 31 mai. 2024.

PACHECO, C. PEREIRA N. S. Deep Learning: Conceitos e utilização nas diversas áreas do conhecimento. Revista Ada Lovelace, [S. l.], v. 2, p. 34–49, 2018.

Disponível em:

<<https://anais.unievangelica.edu.br/index.php/adalovelace/article/view/4132>>.

Acesso em: 17 jun. 2024.

PETERSEN, K. et al. Systematic Mapping Studies in Software Engineering. Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering, v. 17, 26 jun. 2008.

POCHETTI, F. **A visual deep-dive into the building blocks of MobileNetV3.**

Disponível em:

<<https://francescopochetti.com/a-visual-deep-dive-into-the-building-blocks-of-mobilenetv3/>>. Acesso em: 13 mai. 2024.

POTRIMBA, P. **What is EfficientNet? The Ultimate Guide.** 9 ago. 2023. Disponível em: <<https://blog.roboflow.com/what-is-efficientnet/>>. Acesso em: 19 mai. 2024.

PRESSMAN, R. S. Engenharia de Software - uma Abordagem Profissional. [S. l.]: Mc Graw Hill, 2011. ISBN 9788563308337.

PUCCA, B., M et al. **Scorpionism and Dangerous Species of Brazil.** Springer eBooks, p. 299–324, 24 dez. 2014.

RAGHUVANSHI, A. **What are ResNets ?** 27 mar. 2024. Disponível em: <<https://medium.com/@tanalpha-aditya/what-are-resnets-dfd7d1ab7327>>. Acesso em: 19 mai. 2024.

Russel, S.; Norvig, P. **Artificial intelligence: a Modern approach.** 4. ed. [s.l.] Prentice Hall, 2021.

SARKAR, A. **Understanding EfficientNet — The most powerful CNN architecture** 08 mai. 2021. Disponível em: <[Understanding EfficientNet — The most powerful CNN architecture | by Arjun Sarkar | Medium](#)>. Acesso em: 19 mai. 2024.

SCHOLTE, R. G. C. et al. **Inter- and intrapopulational genetic variability of Tityus serrulatus (Scorpiones, Buthidae).** Acta Tropica, v. 112, n. 2, p. 97–100, nov. 2009.

SCUDILIO, J. **Qual a melhor métrica para avaliar os modelos de Machine Learning?** 26 jul. 2020. Disponível em:

<<https://www.flai.com.br/juscudilio/qual-a-melhor-metrica-para-avaliar-os-modelos-de-machine-learning/>>. Acesso em: 8 jun. 2023.

SILVA, R. M.; AMORIM, A. M.; BRAZIL, T. K. **Envenenamento por Tityus stigmurus (Scorpiones; Buthidae) no Estado da Bahia, Brasil.** Revista da Sociedade Brasileira de Medicina Tropical. v. 33. n. 3. p. 239-245. 2000.

TAN, M.; LE, Q. V. **EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks**. 2020. Disponível em: <<http://arxiv.org/abs/1905.11946>>.

UFMG, Faculdade de Medicina. 31 jan. 2023. Disponível em: <<https://www.medicina.ufmg.br/especialista-explica-o-que-fazer-em-caso-de-acidente-s-com-animais-peconhentos/>>. Acesso em: 13 mai. 2023.

VAN VEEN, F. The Neural Network Zoo - The Asimov Institute. 14 set. 2016. Disponível em: <<https://www.asimovinstitute.org/neural-network-zoo/>>. Acesso em: 19 mai. 2024.

WARD, M. J.; ELLSWORTH, S. A.; NYSTROM, G. S. **A global accounting of medically significant scorpions: Epidemiology, major toxins, and comparative resources in harmless counterparts**. *Toxicon*, v. 151, p. 137–155, set. 2018.

WENDRUFF, A. J. et al. **A Silurian ancestral scorpion with fossilised internal anatomy illustrating a pathway to arachnid terrestrialisation**. *Scientific Reports*, v. 10, n. 1, p. 1–6, 16 jan. 2020.

APÊNDICE A - ARTIGO NO FORMATO SBC

Desenvolvimento de um Modelo de Classificação de Imagens de Escorpiões usando Deep Learning

Artur Carmezini Cardoso¹, Christiane Gresse von Wangenheim¹

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

carmezini.artur@grad.ufsc.br, c.wangenheim@ufsc.br

Abstract. *Scorpion-related incidents are a public health issue in Santa Catarina, Brazil, causing symptoms from severe pain and nausea to respiratory failure and death. This work proposes a mobile application using deep learning to identify scorpion species from photos, aiming at awareness and prevention. The goal is to develop a classification model to identify *Tityus serrulatus*, *Tityus costatus*, *Tityus bahiensis*, and *Bothriurus*, common in Santa Catarina. We created an image dataset and conducted neural network experiments. The final model will be deployed in an App Inventor mobile application, contributing to the prevention of scorpion attacks and public awareness.*

Resumo. *Acidentes causados por escorpiões são um problema de saúde pública em Santa Catarina, causando desde dor intensa e náuseas até insuficiência respiratória e óbito. Este trabalho propõe um aplicativo móvel com deep learning para identificar espécies de escorpiões a partir de fotos, visando conscientização e prevenção. O objetivo é desenvolver um modelo de classificação que identifique *Tityus serrulatus*, *Tityus costatus*, *Tityus bahiensis* e *Bothriurus*, comuns em Santa Catarina. Foi criado um conjunto de imagens e realizado experimentos com redes neurais. O modelo final será implantado em um aplicativo usando App Inventor, contribuindo para a prevenção de ataques e conscientização da população.*

1. Introdução

Os escorpiões são animais invertebrados, que podem medir, quando adultos, de 5 a 9 centímetros e pertencem a classe de aracnídeos. Os aracnídeos destacam-se para os seres humanos como animais perigosos e de importância médica pela capacidade de transmitir doenças, [...] e/ou pela ação do veneno de algumas espécies (aranhas e escorpiões) (Brazil; Porto, 2011, p. 15).

Todas as espécies de escorpiões possuem veneno, mas apenas algumas trazem consequências sérias em humanos. Com o avanço das áreas urbanas, o escorpião começou a dividir espaços com os humanos e as ocorrências se tornaram mais comuns com o avançar das últimas décadas. Os escorpiões são encontrados com mais frequência em terrenos baldios, em construções civis e fossos de lixo, podendo ser encontrados em residências adjacentes a estes ambientes (Butantan, 2021).

O escorpionismo é um desafio de saúde pública em várias partes do mundo devido a sua alta frequência e severidade dos acidentes, especialmente em crianças e idosos. Milhões de casos são relatados a cada ano globalmente (Chippaux; Goyffon, 2008; Lourenço, 2018; Ward et al., 2018).

Em Santa Catarina, sofremos com infestações principalmente de três espécies, todas contendo peçonhas letais: o *Tityus bahiensis* (escorpião-marrom), o *Tityus costatus*, e o *Tityus serrulatus* (escorpião-amarelo). Há também a presença do gênero *Bothriurus*, que não possui peçonha letal para seres humanos.

O envenenamento pela picada pode causar dores locais, inchaço, inflamação e sintomas sistêmicos como náusea, vômito, sudorese, hipertensão e arritmias cardíacas. É importante para o cidadão que foi picado por um escorpião procurar atendimento para a classificação da espécie para direcionar de forma correta o seu atendimento médico (Bruna, 2020).

Um dos fatores de complicações em caso de escorpionismo é o da conscientização da população de que é um risco real e hoje há uma falta de conhecimento sobre o assunto. Como nem todos os escorpiões encontrados pela população são de risco à saúde humana, a classificação taxonômica dos escorpiões pode ajudar na prevenção e combate nesses casos.

Geralmente é necessário a consulta de um especialista para determinar se o animal encontrado é realmente um escorpião com peçonha letal com base numa análise aprofundada. A identificação da espécie ou de suas características após o acidente, auxilia no atendimento ao paciente, facilitando aos profissionais de saúde na diferenciação de um animal peçonhento ou não, assim, escolhendo a melhor forma de tratamento (UFMG, 2023).

Segundo o CIATox/SC (2023), a maneira mais assertiva de se diferenciar escorpiões com e sem importância médica no estado, é a de que escorpiões sem peçonha letal não possuem um espinho logo abaixo do ferrão (agulhão). Além disso, sua coloração é mais opaca, diferente dos escorpiões sem importância médica, que aparentam serem naturalmente envernizados, pois sua coloração é mais “brilhante”.

Normalmente, a pessoa que se envolveu em um acidente escorpiônico tenta visualizar algumas características do animal e às vezes até manusear o animal ainda vivo e levá-lo ao hospital, fazendo com que a pessoa que se envolveu em um acidente escorpiônico sofra um risco desnecessário para coletar as informações necessárias para a identificação.

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

Hoje, já existem aplicativos que classificam a fauna e a flora utilizando modelos de Machine Learning (ML), como o iNaturalist, que são capazes de realizar esse tipo de classificação de animais. Alguns destes aplicativos também podem classificar

escorpiões. Também há aplicativos que fornecem somente informações sobre as espécies de escorpiões, que pode-se usar para tentar classificar o animal manualmente.

Portanto, como ainda não há um aplicativo voltado especificamente para a classificação de espécies peçonhentas de escorpiões no estado de Santa Catarina que utilize de ML, foi feita a proposta de um aplicativo capaz de classificar espécies letais de escorpiões presentes em Santa Catarina, que seja capaz de obter essa classificação a partir de uma foto tirada com a câmera de celular, propondo assistir um cidadão que se acidentou ou que quer se informar sobre um possível perigo.

Assim, o objetivo do presente estudo é identificar se é possível o desenvolvimento de um aplicativo móvel inteligente que consegue de forma fácil classificar escorpiões letais vs. não letais por meio de fotos capturadas pela câmera do celular com um grau de precisão de, no mínimo, 95%.

2. Trabalhos Correlatos

Analisando as pesquisas referentes aos últimos 5 anos, revelou-se uma escassez de trabalhos disponíveis sobre o tema em questão. Além disso, dos poucos modelos treinados, praticamente todos se concentraram em uma classificação *Tityus* e *Bothriurus*, não levando em consideração suas espécies. O único modelo treinado que classificou duas espécies distintas do gênero *Tityus* obteve um desempenho insatisfatório, com uma acurácia baixa (72%).

Observa-se também que as redes neurais utilizadas não levavam em consideração a performance, como a VGG16 e a YOLOv4, que são redes que hoje, demonstram um desempenho abaixo de outras redes mais atuais, como a MobileNet, ResNet ou EfficientNet.

Outro empecilho é que os modelos desenvolvidos apenas abordam espécies originárias da região do estudo, não podendo ser adaptado para Santa Catarina.

Desta forma, os resultados deste levantamento indicam a falta de um modelo de classificação incluindo todas as espécies relevantes de escorpiões presentes em Santa Catarina com um desempenho satisfatório para minimizar o risco de resultados errados.

3. Solução

3.1 Requisitos

O objetivo deste trabalho é, portanto, o de desenvolver um modelo de classificação de escorpiões que seja portátil a um aplicativo inteligente que, por meio de imagens obtidas de uma câmera de celular Android, possibilite que usuários sem a expertise na classificação de escorpiões identifiquem sua espécie, e logo, seus perigos, tornando possível que haja prevenção de ataques escorpiônicos e que ajude nos primeiros socorros de interações humano-escorpião.

O modelo utilizará *deep learning* para aprender a partir de um conjunto de imagens rotuladas de escorpiões dos gêneros *Tityus* e *Bothriurus*, incluindo as espécies *Tityus serrulatus*, *Tityus costatus* e *Tityus bahiensis*. A meta é alcançar uma acurácia

superior a 95%, dado o alto risco de classificações incorretas, que podem ter sérias consequências para a saúde.

3.2 Preparação dos dados

O conjunto de dados contém no total 1.587 imagens de escorpiões e objetos gerais. Inicialmente, foram coletado 1.097 imagens, porém, com a ajuda de *data augmentation*, utilizando as técnicas de rotação de 90 graus e espelhamento vertical e horizontal, foram geradas quase 500 novas imagens, que ajudaram a manter o conjunto de dados equilibrado.

Tabela 1: Exemplos de imagens que compõem o conjunto de dados separadas por categoria

Exemplo de imagem da categoria <i>Tityus bahiensis</i>	
Exemplo de imagem da categoria <i>Tityus costatus</i>	
Exemplo de imagem da categoria <i>Tityus serrulatus</i>	

Exemplo de imagem da categoria <i>Bothriurus</i>	
Exemplo de imagem da categoria <i>Non-Scorpio</i>	

Para cada categoria, foram separadas 50 imagens para compor o conjunto de testes. Essas imagens não foram utilizadas em nenhum dos treinamentos. Importante ressaltar também que nenhuma imagem de teste foi resultado de alguma técnica de data augmentation, evitando a possibilidade de algum viés do modelo.

3.3. Treinamento

Os treinamentos foram realizados entre diferentes redes neurais que são portáteis para dispositivos móveis: ResNet-18, ResNet-34, EfficientNet-Lite, EfficientNet-B0 e MobileNetV3. Os modelos foram treinados utilizando transfer learning, utilizando modelos pré-treinados no ImageNet, aproveitando os pesos já treinados para inicializar o modelo. O modelo foi configurado para a nova tarefa com 5 classes, substituindo a camada final original, sem adicionar camadas adicionais.

Todos os modelos foram desenvolvidos e treinados utilizando o ambiente *Jupyter Notebook*, por meio da plataforma *Google Colab*. A escolha dessas redes neurais foi baseada na performance de cada rede levando em conta a possibilidade de ser transportada para um aplicativo móvel. Os resultados dos treinamentos podem ser analisados na Tabela 2.

Tabela 2: Desempenho dos modelos na classificação de escorpiões por modelo durante o treinamento

	<i>Acurácia Total</i>	<i>Tityus Bahiensis</i>	<i>Tityus Costatus</i>	<i>Tityus Serrulatus</i>	<i>Bothriurus</i>	<i>Non-Scorpio</i>
ResNets 18	97.80%	95.30%	96.30%	95%	97.70%	99%
ResNets 34	96.50%	90.70%	96.30%	88.70%	97.70%	97.80%
EfficientNet - Lite	95.90%	97%	98%	90.30%	93%	100%

EfficientNet - B0	98%	93.80%	96.30%	96.80%	97.70%	99%
MobileNet V3	94.20%	92.30%	96.30%	87%	95.50%	94.50%
MobileNet V2 (GTM)	93%	83%	100%	85%	100%	97%

Observa-se que todos os modelos apresentaram resultados promissores, com acurácias totais variando de 93% a 98%, onde 4 dos 6 modelos registraram uma acurácia total superior ao requisito mínimo de 95%. As acurácias por categoria também foram satisfatórias, demonstrando a capacidade dos modelos em distinguir eficazmente entre as diferentes espécies de escorpiões letais e não letais, além de objetos não relacionados.

Em geral, os modelos treinados mostraram resultados que são promissores para o desenvolvimento de um modelo eficiente de classificação de escorpiões, auxiliando a população de Santa Catarina na prevenção de acidentes escorpiônicos.

3.4 Testes de desempenho

Para dar início aos testes, foram separadas 50 imagens de cada categoria. Essas imagens não foram utilizadas em nenhum dos treinamentos. O conjunto de testes também não contém nenhuma imagem de teste foi resultado de alguma técnica de *data augmentation*, evitando a possibilidade de algum viés do modelo. As imagens foram rotuladas por um estudante de graduação em biologia da UFSC e coletadas em sua maioria do site iNaturalist, das quais não tinham direitos autorais vinculados às imagens.

3.5 Resultados dos testes

Os resultados dos testes com diferentes modelos de rede neural foram avaliados em termos de acurácia total e acurácia por categoria e podem ser analisados na Tabela 3.

Tabela 3: Desempenho dos modelos na classificação de escorpiões por modelo durante o teste

	Acurácia Total	Tityus Bahiensis	Tityus Costatus	Tityus Serrulatus	Bothriurus	Non-Scorpio
ResNets 18	88.40%	72%	88%	94%	90%	98%
ResNets 34	90%	78%	86%	94%	94%	98%
EfficientNet - Lite	84.80%	74%	84%	88%	80%	96%
EfficientNet - B0	83.60%	78%	84%	88%	76%	92%
MobileNet V3	83.60%	74%	82%	84%	82%	96%

MobileNet V2 (GTM)	85%	85%	80%	80%	80%	100%
--------------------	-----	-----	-----	-----	-----	------

3.5 Discussão

Mesmo com resultados expressivos e promissores durante o treinamento, os testes não conseguiram manter a alta acurácia, fazendo com que não atingissem um dos requisitos, o de acurácia maior que 95%. Os resultados que mais se mostraram perto deste número foram os da rede ResNet18 e da ResNet34, com 88.4% e 90%, respectivamente.

Assim sendo, é crucial manter a cautela e a prudência ao considerar a utilização desses modelos na prática, especialmente considerando o contexto do alto risco à saúde humana inferida na predição desses modelos. Embora uma taxa de acurácia de 90% possa parecer satisfatória em certos casos, é de suma importância analisar o caso de uso em questão.

3.6 Desenvolvimento do aplicativo móvel

Após o treinamento dos modelos, foi realizada a implementação do aplicativo ScorpID SC por meio do App Inventor (appinventor.mit.edu), uma plataforma que permite a criação de aplicativos por meio de uma interface com elementos visuais e blocos lógicos sequenciais que representam comandos. Foi escolhido este ambiente com o âmbito de servir como um exemplo para o incentivo do estudo de computação e programação desde as etapas do ensino fundamental e médio. O ScorpID SC fornece aos alunos a oportunidade de desenvolver habilidades em programação e design de interface de usuário de uma maneira acessível e intuitiva.

O modelo treinado utilizando o GTM foi implantado no aplicativo usando a extensão TMIC (Teachable Machine Image Classifier) (Oliveira, 2022). Após o desenvolvimento do aplicativo, o mesmo foi exportado, gerando assim um arquivo de extensão (.aia). O arquivo pode ser conferido no link [Google Drive](#) e está sob a licença CC BY-NC-SA 4.1 Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International.

4. Conclusão

Neste estudo, foram desenvolvidos modelos de classificação de escorpiões utilizando deep learning, com base em uma análise teórica e revisão do estado da arte. Diversos modelos foram testados, com foco na identificação de escorpiões letais em Santa Catarina. Embora muitos modelos tenham apresentado resultados satisfatórios, o melhor desempenho foi do modelo ResNet34, com uma acurácia de 90%, abaixo da meta de 95%. No entanto, os modelos demonstraram capacidade promissora de classificar escorpiões dos gêneros *Tityus* e *Bothriurus*, incluindo as espécies *Tityus costatus*, *Tityus serrulatus* e *Tityus bahiensis*. A abordagem utilizada priorizou redes neurais leves, visando a implementação em aplicativos móveis e uso de imagens captadas por celular. O modelo desenvolvido foi implantado em um aplicativo Android, usando o App Inventor, para auxiliar no ensino e na propagação da computação no ambiente escolar brasileiro. Futuras pesquisas podem melhorar a acurácia aumentando o conjunto de dados e aprimorando técnicas de pré-processamento. Com avanços

contínuos, espera-se que o deep learning contribua significativamente para a prevenção de acidentes e o manejo adequado de escorpiões.

5. Referências

BRAZIL, T; PORTO, T. Os escorpiões. Salvador: EDUFBA, 2011. E-book (90 p.). ISBN 978-8523207526. Disponível em:

<[http://www.noap.ufba.br/biotabahia/brazil_porto_os_escorpiões\(livro\)_2011.pdf](http://www.noap.ufba.br/biotabahia/brazil_porto_os_escorpiões(livro)_2011.pdf)>.

Acesso em: 19 mai. 2023.

BRUNA, M. H. V. Picada de escorpião. 11 ago. 2020. Disponível em:

<<https://drauziovarella.uol.com.br/doencas-e-sintomas/picada-de-escorpiao/>>. Acesso

em: 4 abr. 2023.

BUTANTAN, 2021. Escorpiões: entenda por que eles estão cada vez mais próximos dos homens. Disponível em:

<<https://butantan.gov.br/noticias/escorpioes-entenda-por-que-eles-estao-cada-vez-mais-proximos-dos-homens#:~:text=De%20acordo%20com%20Denise%20Candido>>. Acesso

em: 25 mai. 2023.

CHIPPAUX, J.-P. GOYFFON, M. Epidemiology of scorpionism: A global appraisal.

Acta Tropica, v. 107, n. 2, p. 71–79, ago. 2008.

CIATox/SC. Boletim Epidemiológico - Animais Peçonhentos em 2022. Disponível em:

<<https://ciatox.saude.sc.gov.br/index.php/santa-catarina-lista-dos-hospitais-de-soros-anti-venenos.html?view=category&download=71:boletim-epidemiologico-n-ii-ano-2022-acidentes-por-animais-peconhentos&id=8:boletins/>>. Acesso em: 29 abr. 2023.

LOURENÇO, R. W. Scorpions and life- history strategies: from evolutionary dynamics toward the scorpionism problem. Journal of Venomous Animals and Toxins including Tropical Diseases, v. 24, n.19, p. 1-12. 2018.

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

UFMG, Faculdade de Medicina. 31 jan. 2023. Disponível em:

<<https://www.medicina.ufmg.br/especialista-explica-o-que-fazer-em-caso-de-acidentes-com-animais-peconhentos/>>. Acesso em: 13 mai. 2023.

WARD, M. J.; ELLSWORTH, S. A.; NYSTROM, G. S. A global accounting of medically significant scorpions: Epidemiology, major toxins, and comparative resources in harmless counterparts. Toxicon, v. 151, p. 137–155, set. 2018.