

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**RODRIGO DE MORAIS**

**USO DE REDE NEURAL CONVOLUCIONAL NO RECONHECIMENTO DE  
ARTRÓPODES DA CLASSE INSECTA**

**FRANCISCO BELTRÃO**

**2022**

**RODRIGO DE MORAIS**

**USO DE REDE NEURAL CONVOLUCIONAL NO RECONHECIMENTO DE  
ARTRÓPODES DA CLASSE INSECTA**

**Use of Convolutional Neural Network in the Recognition of Insecta Class  
Arthropods**

Dissertação apresentado como requisito para obtenção do título de Mestre em Análise e Tecnologia Ambiental do Programa de Pós-Graduação em Engenharia Ambiental da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Francisco Antonio Fernandes Reinaldo

Coorientador: Prof<sup>a</sup>. Dr<sup>a</sup>. Thalita Grandó Rauen

**FRANCISCO BELTRÃO**

**2022**



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



Ministério da Educação  
Universidade Tecnológica Federal do Paraná  
Campus Francisco Beltrão



RODRIGO DE MORAIS

**USO DE REDE NEURAL CONVOLUCIONAL NO RECONHECIMENTO DE ARTRÓPODES DA CLASSE INSECTA**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Ambiental: Análise E Tecnologia Ambiental da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Meio Ambiente.

Data de aprovação: 24 de Agosto de 2022

Dr. Francisco Antonio Fernandes Reinaldo, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Davi Zacarias De Souza, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Julio Cesar Paisani, Doutorado - Universidade Estadual do Oeste do Paraná (Unioeste)

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 31/08/2022.

Dedico este trabalho aos que não se deixam  
acomodar, aos que buscam sempre novos  
conhecimentos, aos que não se deixam cair na  
rotina do conformismo.

## **AGRADECIMENTOS**

Este trabalho não poderia ser terminado sem a ajuda de diversas pessoas, as quais merecem uma palavra de carinho. Agradeço imensamente em primeiro lugar ao meu filho Yan falecido com 45 dias, em 2012 e que de lá para cá se tornou minha maior motivação para seguir e buscar meu melhor sempre, agradeço a minha família por me proporcionar condições que me fizeram chegar até aqui, ao meu orientador professor Dr. Francisco Antonio Fernandes Reinaldo, pela parceria e ensinamentos sempre, ele sabe a admiração e respeito que possuo por ele, agradeço a minha coorientadora professora Dr. Thalita Grando Rauen, por aceitar esse desafio conosco, tive o imenso prazer de conhecê-la e poder desfrutar um pouco dos seus conselhos e sugestões, agradeço aos meus amigos por estarem sempre do meu lado e não podia deixar de agradecer ao amor da minha vida Gabrielly por me aturar ao longo desses anos, onde apesar de todas as dificuldades e pensamentos de desistência da minha parte não me deixou desistir, sempre me apoiou e me ajudou em tudo, seu sorriso ilumina minha vida.

Enfim, agradeço a todos os que de alguma forma contribuíram para a realização deste trabalho.

## RESUMO

O presente trabalho objetiva amparar pesquisadores e especialistas ao reconhecer imagens de animais pertencentes ao filo *Arthropoda* da classe *Insecta* por computação científica. Por ser a maior e mais diversa, reconhecer as nuances destes animais por referência e a olho nu para os distinguir então torna-se uma tarefa fatigante para especialistas humanos, complexa e muito propensa a erros. Embora especialistas humanos tenham o *knowhow* e mesmo amparados por literatura digital, a inteligência computacional na automatização e reconhecimento de imagens pode efetivamente ampliar o horizonte até mesmo para detectar novas espécies não categorizadas, preservando o especialista para novas descobertas neste fabuloso reino de únicos animais invertebrados com capacidade de voo.

**Palavras-chave:** insetos; computação científica; redes neurais artificiais; diversidade biológica; aprendizagem profunda.

## ABSTRACT

The work aims to support research and specialists by recognizing images of animals belonging to the phylum Arthropoda of the class Insecta by computation scientific. As it is the largest and most diverse, we recognize the nuances of these animals by reference and with the naked eye to distinguish them then it becomes a tiring task for human experts, complex and very error-prone. Although experts humans had the know-how and even supported by digital literature, the intelligence Automation and image recognition can compute on the expand the horizon even to detect new uncategorized species preserving the expert for new discoveries in this fabulous realm of unique invertebrate animals capable of flight.

**Keywords:** insects; scientific computing; artificial neural networks; biological diversity; deep learning.

## LISTA DE FIGURAS

Figura 1 – Traças - Ordem Apterá. . . . .	18
Figura 2 – Joaninha - Ordem Coleoptera. . . . .	18
Figura 3 – Cigarra - Ordem Hemiptera. . . . .	19
Figura 4 – Borboleta - Ordem Lepidoptera. . . . .	20
Figura 5 – Bixo Lixeiro - Ordem Neuroptera. . . . .	21
Figura 6 – Abelha - Ordem Hymenoptera. . . . .	21
Figura 7 – Mosca - Ordem Diptera. . . . .	22
Figura 8 – Pulgões - Ordem Homoptera. . . . .	23
Figura 9 – Gafanhoto - Ordem Orthoptera. . . . .	23
Figura 10 – Libelula - Ordem Odonata. . . . .	24
Figura 11 – Representação de um pixel. . . . .	25
Figura 12 – Cronograma da Inteligência Artificial Moderna. . . . .	26
Figura 13 – Modelo de Camadas da RNA. . . . .	29
Figura 14 – Modelo de Camadas Rede Neural Convolutiva. . . . .	30
Figura 15 – Esquema ilustrativo do processo de Convolução. . . . .	31
Figura 16 – Modelo de Equação de Convolução Discreta. . . . .	32
Figura 17 – Esquema ilustrativo do processo de <i>pooling</i> . . . . .	33
Figura 18 – Agrupamento de algumas imagens utilizadas na validação da função . . . . .	35
Figura 19 – Função Queinsetoé. . . . .	38
Figura 20 – Wolfram Alpha. . . . .	39
Figura 21 – Taxonomia. . . . .	40
Figura 22 – Probability. . . . .	40
Figura 23 – Categorização. . . . .	41
Figura 24 – Correlação. . . . .	42
Figura 25 – Gráfico Dendrograma. . . . .	43



## LISTA DE TABELAS

Tabela 1 – Tabela com os dados de estudo . . . . .	42
--	----

## LISTA DE ABREVIATURAS E SIGLAS

### Siglas

API	Interface de Programação de Aplicação
CNN	Rede Neural Convolucional
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
IA	Inteligência Artificial
ID	Identidade do Usuário
PPGEA	Programa de Pós Graduação em Engenharia Ambiental
RNA	Rede Neural Artificial
SVM	Máquina de Suporte Vetorial
UTFPR	Universidade Tecnológica Federal do Paraná

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
<b>1.1</b>	<b>Objetivos</b>	<b>14</b>
1.1.1	Objetivo geral	14
1.1.2	Objetivos específicos	14
<b>1.2</b>	<b>Justificativa</b>	<b>14</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>16</b>
<b>2.1</b>	<b>Insetos e o Meio Ambiente</b>	<b>16</b>
2.1.1	Principais Táxons	17
<b>2.2</b>	<b>Visão Computacional</b>	<b>24</b>
<b>2.3</b>	<b>Inteligência Artificial</b>	<b>25</b>
2.3.1	Máquina de Suporte Vetorial - SVM	26
2.3.2	Redes Neurais Artificiais - RNA	27
<b>2.4</b>	<b>Rede Neural Convolutacional - CNN</b>	<b>29</b>
2.4.1	Convolução	31
2.4.2	<i>Pooling</i>	32
2.4.3	Totalmente Conectada	33
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>34</b>
<b>3.1</b>	<b>Materiais</b>	<b>34</b>
<b>3.2</b>	<b>Método</b>	<b>35</b>
<b>4</b>	<b>RESULTADOS</b>	<b>37</b>
<b>4.1</b>	<b><i>Sprint 1</i> - Reconhecimento</b>	<b>37</b>
<b>4.2</b>	<b><i>Sprint 2</i> - Descrição</b>	<b>37</b>
<b>4.3</b>	<b><i>Sprint 3</i> - Tradução da Descrição</b>	<b>38</b>
<b>4.4</b>	<b><i>Sprint 4</i> - Busca de Imagens do Google</b>	<b>38</b>
<b>4.5</b>	<b><i>Sprint 5</i> - Taxonomia e Dados Relevantes</b>	<b>39</b>
<b>4.6</b>	<b><i>Sprint 6</i> - Categorização de insetos similares</b>	<b>41</b>
<b>4.7</b>	<b><i>Sprint 7</i> - Reconhecimento por contorno de imagens</b>	<b>41</b>
<b>4.8</b>	<b><i>Sprint 8</i> - Taxas de Reconhecimento da Rede Neural Convolutacional</b>	<b>42</b>
<b>5</b>	<b>CONCLUSÃO</b>	<b>45</b>

<b>6</b>	<b>TRABALHOS FUTUROS . . . . .</b>	<b>46</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>47</b>
	<b>ANEXO A AGRUPAMENTO DE IMAGENS COLORIDAS APLICADAS EM TESTE DA REDE NEURAL CONVOLUCIONAL . . . . .</b>	<b>51</b>
	<b>ANEXO B AGRUPAMENTO DE CONTORNOS APLICADAS EM TESTE DA REDE NEURAL CONVOLUCIONAL . . . . .</b>	<b>53</b>

## 1 INTRODUÇÃO

Os insetos, pertencentes à classe de animais tipo insecta, possuem importância significativa para o correto funcionamento do ecossistema. Servem como base na cadeia alimentar de espécies insetívoras, trabalham como agente polinizador na propagação de plantas, fortalecem o solo na reciclagem de nutrientes através da decomposição. Esta classe possui também importância econômica, atuando, por exemplo, na produção de mel e seda (RUPPERT; FOX; BARNES, 2005).

A classificação e documentação de animais, inclusive insetos, depende da taxonomia. Estimativas revelam que cerca de 8,7 milhões de espécies existentes de fauna e flora em nosso ecossistema, onde aproximadamente 1 milhão de espécies de insetos são descritas em documentos científicos (VILANI; BIANCHI; HOUSSAINI, 2015). Especificamente para insetos, a taxonomia é uma profissão que se encontra em escassez, sendo necessário que a identificação de insetos seja feita por não especialistas (LAMAS, 2006).

Das dificuldades encontradas pelos taxonomistas no reconhecimento de insetos, tem-se a falta de consenso de quantas espécies possam existir na classe insecta e a identificação incorreta das espécies de insetos pode gerar um desbalanceamento no controle de pragas no meio agrícola (CHAPMAN; STUDY, 2009). Ao observar essas dificuldades básicas, identificou-se uma demanda de pesquisa na área de reconhecimento computacional voltado à espécies de insetos. Surge então a possibilidade de aplicar inteligência computacional, em específico, o uso de redes neurais computacionais, para dar suporte ao processo de identificação de imagens, conseqüentemente reconhecimento de insetos.

Redes neurais computacionais, pertencentes ao âmbito da inteligência computacional, com recurso de aprendizagem de máquina oferece uma precisão ímpar no reconhecimento de imagens pois seu algoritmo computacional consegue imitar a cognição humana ao "aprender" e classificar insetos com base nos exemplos de espécies já catálogos pelos taxonomistas.

O modelo de rede neural computacional determina a precisão no reconhecimento das imagens dos insetos. Buscando por uma precisão acurada, similar a de um taxonomista, optou-se pela classe das redes neurais convolucionais, pois reconhecem o detalhe das imagens de insetos.

O presente trabalho faz o uso de rede neural convolucional, para identificar imagens de insetos sem a imposição de um pré-processamento, vantagem única se comparado aos métodos tradicionais de aprendizagem de máquina.

## 1.1 Objetivos

### 1.1.1 Objetivo geral

A identificação de artrópodes por meio da modelagem de uma Rede Neural Convolutiva capaz de auxiliar taxonomistas, pesquisadores e não especialistas a identificar artrópodes da classe Insecta por inteligência computacional.

### 1.1.2 Objetivos específicos

- Povoar dois *datasets* de teste, um de fotografias e o outro de contornos de insetos;
- Implementar por inteligência computacional um algoritmo de aprendizagem de máquina capaz da identificação entomológica.
- Validar o algoritmo de aprendizagem de máquina por meio dos *datasets* povoados.
- Prognosticar a classe e demais características conforme o reconhecimento de insetos;

## 1.2 Justificativa

A taxonomia é uma profissão escassa (LAMAS, 2006) tendo em vista as dificuldades no reconhecimento do enorme número de espécies e isto gera uma escassez de informação biológica. Fatores como complexidade das chaves de identificação disponíveis na literatura e a dificuldade na interpretação dos termos técnicos pela ausência de ilustrações confunde os mais aptos a diferenciar tais insetos apenas por sua mandíbula - característica presente principalmente em pragas (CHAPMAN; STUDY, 2009).

Apesar das dificuldades elencadas, é primária a identificação correta das espécies de insetos. Para definir a área de atuação de cada espécie de inseto, é necessária uma correta identificação. A classe Insecta é fundamental para contribuir para o equilíbrio funcional do ecossistema. Os insetos são a base da cadeia alimentar de muitas espécies. Também são agentes polinizadores que agem na expansão e preservação da flora (GULLAN; CRANSTON, 2012).

Como medida de auxílio ao reconhecimento de insetos para estudos entomológicos, torna-se imprescindível a implementação e o uso de inteligência computacional capaz de identificar insetos por meio do processamento de imagens e suas chaves de identificação como seu exoesqueleto e sua metamorfose. Isto estabelece prioridades para conservação, viabiliza a correta identificação de agentes de controle biológico, polinizadores, dispersores e pragas agrícolas, além da identificação de material entomológico de risco cuja interceptação e quarentena seja necessária.

O alto nível de perícia necessário para a classificação visual dos insetos, no entanto, pode ser subvertido a partir da aplicação de técnicas de visão computacional e reconhecimento de padrões com base em imagens reais de insetos. Apesar das peculiaridades próprias presentes em técnicas de aprendizagem de máquina, é possível identificar se existe um inseto na imagem e havendo, especificar sua classificação. As estimativas de que existem cerca de 2 milhões de espécies de insetos, onde apenas uma pequena parte foi catalogada, tornam a taxonomia uma área de estudo contínuo. A tarefa de reconhecimento de insetos por métodos computacionais enfrenta algumas incertezas, dentre os principais aspectos causadores estão: a variabilidade de cor, variações de fundos nas imagens, a textura, a pose e outras deformações (LECUN; BENGIO; HINTON, 2015).

## 2 REFERENCIAL TEÓRICO

### 2.1 Insetos e o Meio Ambiente

A aplicação de um modelo de classificação para a catalogação de seres vivos, iniciou no ano de 1735, com a publicação da primeira versão da obra *Systema Naturae*, de Carl Von Linné, que apresentou as bases de um sistema estruturado de classificação dos seres vivos. Em seu sistema, Linné propôs uma classificação que usa as seguintes chaves de identificação: órgãos, estruturas morfológicas e estruturas reprodutivas de animais e plantas. O sistema de classificação proposto por Linné ramifica os seres vivos em três reinos, sendo: animal, vegetal e mineral (HEYNEMANN, 2003).

Na cadeia de classificação dos seres vivos, o reino animal compreende todos os animais. Na sequência, tem-se nove filos e dentre esses filos temos o filo dos Artrópodes, onde se encontra o subfilo dos Hexápodes que se divide em duas classes: Entognatha e Insecta, possuindo entre 4 e 30 táxons, respectivamente. Os insetos são seres vivos presentes na classe Insecta e formam a maior classe do reino animal (RUPPERT; FOX; BARNES, 2005).

Devido sua abundância, os insetos se caracterizam como um grupo importante na manutenção do ecossistema, sendo parte ativa inclusive do ambiente agrícola, onde podem ser encontrados e categorizados como: pragas, inimigos naturais, polinizadores e recicladores de matéria orgânica. Estimativas apontam 2 milhões de espécies de insetos, onde somente 900 mil já foram catalogadas. O Brasil, no que lhe concerne, merece destaque, já que possui cerca de 120 mil espécies conhecidas e catalogadas por meio da parceria entre Ministério do Meio Ambiente, EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária) e instituições de ensino superior (LEWINSOHN; PRADO, 2005).

Por meio do seu extenso número de espécies, os insetos desenvolveram uma grande adaptabilidade, tal como a habilidade de voar, o acesso a diferentes *habitats* e a fuga de predadores (LEITE, 2011). Estas características ímpares contemplam os índices de sobrevivência para se estabelecerem em todos os nichos ambientais do planeta. Por serem animais ectotérmicos<sup>1</sup> e a maioria das espécies ter seu desenvolvimento ligado a temperatura e umidade correntes, desenvolvem-se melhor em um ambiente com temperatura em torno de 25°C. Assim como os seres humanos, os insetos têm uma porcentagem alta de água no corpo, superior a 50%. A obtenção da água se dá especialmente pela alimentação variada abrangendo exemplares carnívoros, herbívoros, hematófagos e predadores (CARDOSO; CARVALHO; TEIXEIRA, 2008).

A variedade alimentar de insetos permite o controle natural no combate a surtos de pragas. Esse controle um processo natural e o uso proposital dessa finalidade teve início durante o século XVIII. Na Europa, joaninhas (*Coccinellidae*) fizeram o papel de controle de pragas e pos-

---

<sup>1</sup> Não praticam termorregulação, possuindo a necessidade de regular sua temperatura com base no ambiente em que vivem



teriormente outras transferências propositais de insetos ocorreram. Insetos trazidos da Austrália praticaram o controle do pulgão-branco (*Icerya purchasi*) dos citros no estado da Califórnia nos Estados Unidos, desde então esse processo se expandiu (OLIVEIRA *et al.*, 2006).

Outros controles de pragas, envolvendo os insetos parasitóides, também são considerados úteis no controle biológico. São insetos que passam parte de sua vida dentro de um hospedeiro. Este hospedeiro acaba morrendo devido ao parasitismo, parte do processo de invasão dos insetos parasitóides é o depósito de seus ovos em ovos de outras espécies, impedindo o desenvolvimento de novos indivíduos da espécie invadida. A presença dos insetos como reguladores ecológicos não se limita a controle biológico, pois insetos polinizadores são essenciais para a manutenção da biodiversidade, já que a polinização é imprescindível para a propagação de espécies de plantas (STORER *et al.*, 2003).

Dentre os insetos polinizadores destacam-se as abelhas - bioindicadores de qualidade ambiental. As abelhas possuem pelos que durante seus voos fazem o papel de coletores de partículas. Essas partículas presentes no ar e no pólen que coletam permitem identificar a qualidade do ar presente no habitat em que circulam (WOLF; REIS; SANTOS, 2008). O uso e manejo de agentes polinizadores como as abelhas permite também potencializar a produtividade de plantios sem a necessidade de desmatamento.


A potencialização da produtividade causada por insetos têm atribuições consideráveis no plantio. Apesar da quantidade numerosa de insetos benéficos, pragas biológicas possuem maior destaque quando acarretam perdas quantificadas, gerando valores elevados de prejuízo aos produtores (SILVA, 2013). A identificação correta de espécies de insetos tende a reduzir o dano causado, permitindo o adequado tratamento para cada espécie.

### 2.1.1 Principais Táxons

A classe Insecta possui 10 táxons principais, cada um abrange insetos com diferentes características, abaixo descritas.

**Aptera** representa a ordem dos insetos que não possuem asas, alguns insetos das ordens Zygentoma e Diplura se encaixam como sendo Apterose, por outro lado, insetos que perdem suas asas durante o processo evolutivo, não são considerados para a ordem (PEREIRA *et al.*, 2006). As traças de livros vistas na Figura 1 são um exemplo de insetos Apterose.

**Figura 1 – Traças - Ordem Aptera.**



Fonte: (COMMONS, 2022).

**Coleoptera** representa a ordem dos insetos mais abundantes, presentes em praticamente todos os ambientes, os insetos da ordem Coleoptera se destacam por serem em sua maioria prejudiciais para manter a ordem ambiental, pela dificuldade de controle, e pelas espécies transmissoras de doenças. Os insetos que fazem parte da ordem Coleoptera são predominantemente mastigadores, seu primeiro par de asas é enrijecido, servindo de proteção para o segundo par de asas, essas sendo membranosas. A maioria dos integrantes da ordem Coleoptera são fitófagos, se alimentam de todas as partes da planta, raiz, folhas, flores, frutos, e pólen, em alguns casos, podem ainda infestar produtos armazenados de origem animal ou vegetal, causando perdas consideráveis na produção agrícola (COSTA *et al.*, 2014).

Os insetos fitófagos, ao consumir plantas presentes na produção agrícola, podem causar danos variados, dentre os danos mais recorrentes, estão a redução da fotossíntese, a interrupção da translocação da seiva, e a transmissão de doenças. A ordem Coleoptera é composta de aproximadamente 40% de todos os insetos conhecidos, cerca de 350 mil espécies, formando assim o maior grupo de organismos do planeta Terra (NETO *et al.*, 2017). Insetos presentes, e facilmente encontrados em nosso dia a dia, são representantes da ordem Coleoptera, como o besouro, e a joaninha vista na Figura 2.

**Figura 2 – Joaninha - Ordem Coleoptera.**



Fonte: (COMMONS, 2022).

**Hemiptera** representa a ordem dos insetos que se caracterizam pela formação do aparelho bucal, possuindo um rosto, um lábio segmentado, em que se encontram as demais peças bucais. Pertencem à ordem Hemiptera os insetos que podem ser chamados de percevejos, da antiga subordem Heteroptera, portadores de um rosto reclinado e alongado, podendo ser retilíneo ou curvilíneo, sempre com a cabeça antecedendo os olhos (SCHWERTNER; GRAZIA, 2007).

Os padrões de características físicas presentes nos rostos de insetos pertencentes a classe Hemiptera, se estendem na formação de suas antenas, que apresentam, em sua maioria, de três a cinco segmentos. Podemos observar também a estrutura das asas, chamadas de hemiélitros, que caracteriza asas com base dura e membrana flexível. Os insetos representantes da ordem Hemiptera são em sua maioria pequenos, porém, podendo haver espécies maiores como as baratas d'água, que chegam a ter mais de 10 centímetros (SCHWERTNER; GRAZIA, 2007).

As baratas d'água, apesar do nome, representam as espécies aquáticas dos grandes percevejos da ordem Hemiptera. Atualmente a ordem Hemiptera está subdividida em quatro subordens, sendo elas, Sternorrhyncha, Auchenorrhyncha, Heteroptera e Coleorrhyncha, no Brasil, conseguimos observar representantes das três primeiras subordens. Em seu estado de ninfas algumas espécies têm hábitos subterrâneos se alojando em pequenos buracos no solo, e se alimentando apenas das seivas das raízes de plantas. Existem cerca de 89 mil espécies conhecidas, representantes da ordem Hemiptera, no Brasil podemos encontrar cerca de 30 mil espécies, dentre os insetos que fazem parte da ordem Hemiptera um dos mais conhecidos é a cigarra que pode ser vista na Figura 3.

**Figura 3 – Cigarra - Ordem Hemiptera.**



**Fonte: (COMMONS, 2022).**

**Lepidoptera** representa a ordem dos insetos em que as asas são membranosas, e apresentam como características escamas, essas espécies apresentam uma metamorfose completa, possuindo os estágios, larval, casulo e adulto. Em seu estágio larval, possuem a capacidade de mastigação sendo herbívoros, o corpo assim como as asas é cobertos por escamas (CZEPAK *et al.*, 2013).

Por apresentarem características herbívoras em seu estágio larval, os insetos da ordem Lepidoptera, apenas nesse estágio de sua metamorfose, também podem ser considerados prejudiciais às plantações agrícolas. Em seu estágio adulto, apesar de algumas espécies consumirem apenas reservas nutritivas, acumuladas desde seu estágio larval, outras ganham características de sugadores, formando sua base alimentar por meio de néctar, pólen, resinas vegetais e suco de frutos, em alguns casos ainda podem ser hematófagas, se alimentando de sangue (CZEPAK *et al.*, 2013). Mariposas e borboletas são representantes da ordem Lepidoptera na Figura 4 podemos ver uma borboleta, representando a ordem.

**Figura 4 – Borboleta - Ordem Lepidoptera.**



**Fonte: (COMMONS, 2022).**

**Neuroptera** representa a ordem dos insetos que possuem muitas nervuras nas asas, além da nervura principal, em algumas espécies são encontrados um segundo par de asas, com nervuras acessórias, os insetos da ordem Neuroptera são mastigadores, com olhos grandes e compostos, e antenas Moniliforme, filiformes, setáceas ou clavadas. Sua dieta tanto no estágio larval quanto adulto é onívora, se alimentando de insetos de corpo mole como larvas, pulgões, ovos, algumas espécies adotam pólen, e néctares açucarados como base da alimentação (SNYMAN *et al.*, 2020).

Os insetos da Ordem Neuroptera tem um papel importante na manutenção de ambientes naturais, ou modificados pelo homem, por serem onívoros, e em sua maioria predadores naturais. Essa característica permite que sejam usados no controle das pragas agrícolas. Os Crisopídeos, uma família derivada da ordem Neuroptera, são um exemplo de predadores, representados pelo bicho lixeiro, visto na Figura 5. A alimentação em estágio adulto de espécies pertencentes a família dos Crisopídeos, pode apresentar uma variação significativa, enquanto algumas espécies consomem aproximadamente 150 presas durante toda sua vida, outras conseguem atingir 100 presas em uma única semana (SNYMAN *et al.*, 2020). Assim, crisopídeos são criados em cativeiro e comercializados como agentes reguladores ambientais. Os insetos da ordem Neuroptera se comunicam por meio de vibração, os sinais são feitos para alertar sobre presas ou para a corte, já que sua reprodução é sexuada.

**Figura 5 – Bixo Lixeiro - Ordem Neuroptera.**



Fonte: (COMMONS, 2022).

**Hymenoptera** é a ordem de insetos de contempla as vespas, formigas e abelhas, possui mais de 153 mil espécies catalogadas. Os insetos da ordem Hymenoptera possuem asas membranosas, algumas espécies como a formiga operária perdem suas asas ao longo do seu desenvolvimento (RASPLUS *et al.*, 2010).

Mesmo em espécies que perdem suas asas, as características de sobrevivência pertencentes a insetos da ordem Hymenoptera continuam presentes, uma delas é o modo de organização estrutural das colônias, os ninhos são construídos com o uso de cera, terra, e outros substratos encontrados na natureza (RASPLUS *et al.*, 2010). No meio ambiente, agem na polinização, auxiliam no controle de pragas, e produzem materiais utilizados pelo ser humano como cera, e mel, na Figura 6 podemos ver uma abelha como representante da ordem. Seu impacto negativo pode ser sentido em decorrência de famílias pertencentes ao grupo Hymenoptera que agem como pragas agrícolas, causando danos às plantações, tendo a formiga como principal exemplo.

**Figura 6 – Abelha - Ordem Hymenoptera.**



Fonte: (COMMONS, 2022).

**Diptera** representa a ordem de insetos cuja característica é possuir apenas um par de asas principais, as espécies que possuem também asas auxiliares, porém essas com a função de serem apenas estabilizadores para o voo, também fazem parte da ordem Díptera. As espécies de insetos dessa ordem possuem em sua fase de desenvolvimento

uma metamorfose completa, saem de ovos, como larvas, virando posteriormente pupa, e então chegando a fase adulta. A ordem Díptera apresenta espécies que possuem uma alimentação variada, possuindo exemplares que se alimentam de folhas e frutos, enquanto outros agem como predadores ou parasitas, uma porcentagem das espécies também possuem hábitos hematófagos, se alimentando de sangue (SILVA *et al.*, 2004).

Algumas espécies da ordem Díptera, por apresentarem uma alimentação predatória se destacam por desempenhar um importante papel como inimigos naturais de várias pragas. Algumas espécies, e famílias de moscas podem ainda ser utilizadas no estudo de genética. As espécies de moscas como a representada na Figura 7, são escolhidas para pesquisas preferencialmente por terem um baixo custo de criação, possuem um genoma de fácil manipulação, e geram grande número de descendentes.

**Figura 7 – Mosca - Ordem Diptera.**



Fonte: (COMMONS, 2022).

**Homoptera** esta ordem compõe-se de insetos terrestres, numerosos e diversificados, muito semelhante à ordem Hemíptera. A ordem se refere aos dois pares de asas serem semelhantes, a característica que define o grupo é a presença de asas anteriores membranosas (BARROS; FILHO; ARRUDA, 2001). Apresentam características corpóreas variadas, todos seus membros são fitófagos sugando seiva de plantas com uma armadura bucal sugadora, a ordem compreende algumas espécies danosas as plantas por meio da transmissão de doenças, possuindo grande importância econômica, como o pulgão representado na Figura 8, entretanto as espécies úteis podem contribuir como fonte de corantes, cera e goma-laca.

**Figura 8 – Pulgões - Ordem Homoptera.**



Fonte: (COMMONS, 2022).

**Orthoptera** se refere a famílias de insetos que possuem asas anteriores do tipo pergaminosas, alongadas e retas. São amostras dessa ordem os gafanhotos e grilos. Os ortópteros, são mais abundantes nas regiões tropicais, apesar de possuírem exemplares em todo o mundo. Possuem hábitos alimentares variados, apesar da maioria dos indivíduos dessa ordem serem fitófagos, algumas espécies podem ser inclusive predadoras (LIMA *et al.*, 2021). Espécies de gafanhotos como visto na Figura 9 possuem importância econômica, pois conseguem devastar plantações.

**Figura 9 – Gafanhoto - Ordem Orthoptera.**



Fonte: (COMMONS, 2022).

**Odonata** se refere a estrutura das mandíbulas dos insetos adultos, que se assemelha a dentes. São representantes da ordem Odonata as libélulas como o exemplar visto na Figura 10, insetos predadores desde sua fase de ninfa. Essas espécies depositam seus ovos na água ou próximo aos cursos d'água. Na fase aquática são chamadas de náíades, as

quais passam por várias mudanças levando até cinco anos para atingir a maturidade (SOUZA; NETO; JÚNIOR, 2021).

**Figura 10 – Libelula - Ordem Odonata.**



**Fonte: (COMMONS, 2022).**

A separação das espécies por táxons auxilia em sua classificação visto a diversidade de características dos indivíduos da classe Insecta. Sua separação por ordem considera as características de cabeça, tórax, antenas e asas.

## **2.2 Visão Computacional**


A dificuldade no reconhecimento e categorização de imagens é algo que vem sendo trabalhado ao longo dos anos para ser solucionado de maneira prática e eficaz. Até meados dos anos 70 técnicas ópticas de processamentos eram predominantes. Técnicas digitais passaram a ser empregadas a partir dos anos 80 com os avanços obtidos em arquiteturas de processamento de dados e microeletrônica. Atualmente a aplicação de métodos de visão computacional com inteligência artificial (IA), por meio de sistemas especialistas e redes neurais artificiais (RNA), vem, então apresentando resultados satisfatórios.

Define-se visão computacional como a captura visual do mundo exterior por meio de sensores, o processamento e a análise destas imagens capturadas com o auxílio de métodos algorítmicos, analíticos e estatísticos. Por meio de mapeamento de padrões e extração de atributos de imagens é possível classificar a imagem com base na expertise adquirida dentre uma base complexa de chaves. Assim, o classificador de imagem gera um rótulo de classe a qualquer nova imagem inserida no sistema (MARENGONI; STRINGHINI, 2009).

Para realizar o reconhecimento de padrões por processamento digital em imagens, são utilizadas coordenadas do plano cartesiano para mapear a imagem. Uma estrutura bidimensional do modelo gráfico é formada, contabilizando e atribuindo pesos matemáticos a todos os pixels presentes. O número de pixels é proporcional a quantidade de informação presente na imagem, um pixel pode ser descrito como a menor unidade que compõe a imagem, podendo ser observado como pequenos quadrados, representados na Figura 11.



Figura 11 – Representação de um pixel.



Fonte: Autoria própria (2022).

A conexão entre as unidades de pixels demonstra os limites de objetos e componentes da região analisada da imagem, podendo representar características semelhantes. Mesmo em imagens monocromáticas pixels distintos podem ser detectados.


Imagens monocromáticas permitem um processamento mais ágil, pois cada pixel possui apenas um comprimento de onda. Porém, um modelo de processamento similar ao utilizado em imagens coloridas pode ser considerado se a análise depender de cores com diferentes características.

### 2.3 Inteligência Artificial

A inteligência artificial teve seu reconhecimento como ciência após a Segunda Guerra Mundial. Em 1956, ocorreu a primeira Conferência Internacional de Inteligência Artificial, idealizada por John McCarthy, com o intuito de realizar um estudo de dois meses onde seria possível apresentar as pesquisas desenvolvidas pelos participantes sobre assuntos relacionados a inteligência artificial. Nesta conferência Nathaniel Rochester apresentou um modelo de simulação cognitiva computacional. Nesta vertente, inteligência artificial remete à máquinas implementadas por algoritmos, que as tornam capazes de aprender com o uso de dados, utilizando a expertise adquirida para tomar decisões. As inteligências artificiais atuais permitem uma grande abrangência de subcampos, já que suas características de implementação podem ser aplicadas para sistematizar e automatizar tarefas cognitivas (REINALDO *et al.*, 2006).

Portanto, mesmo com desenvolvimento limitado, o foco dos estudos de aplicação de inteligências artificiais no início dos anos 50, já permitia reproduzir todas as tarefas cognitivas de um ser humano. Com pouco progresso, a aplicação de técnicas de inteligência artificial foi direcionada para resolução de problemas. Esses dois paradigmas seguiram em paralelo até os anos 80, onde o estudo sobre inteligência artificial, ou melhor dizendo, inteligência computacional e aprendizado de máquina (*Machine Learning*) demonstraram ser promissoras, ofertando como

hipótese a capacidade de aprendizado e cognição humana aos computadores. O cronograma dos campos de estudo da inteligência artificial podem ser observados na Figura 12.



**Fonte: Autoria própria (2022).**

Inteligência é a simulação da cognição, ora humana, no reconhecimento de padrões por meio da aprendizagem a priori. Aprendizagem refere-se a aquisição de conhecimento - atingido por proposições lógicas - em um processo de busca de reconhecimento automático de padrões. A aprendizagem de máquina é a união da inteligência com os recursos da computação na implementação efetiva de aprendizagem por meios matemáticos e algorítmicos.

Após estudos com aprendizado de máquina e aumento considerável em suas aplicações, surge o subcampo do aprendizado profundo (*Deep Learning*) em meados dos anos 2000, onde novos métodos de aprendizado e suas topologias puderam ser aplicadas com o uso de redes neurais artificiais multicamadas. A computação cognitiva, subcampo da inteligência artificial, é material de estudo no desenvolvimento de sistemas que possam interagir naturalmente com o ser humano (TOSCANO, 2009).

Os algoritmos de aprendizagem de máquina presentes no processo de classificação automática possuem a capacidade de relacionar um grupo, com as observações pertencentes a ele, por meio da fixação de regras de conhecimento com base em um vetor de variáveis. Os algoritmos de aprendizagem são Máquina de Suporte Vetorial (SVM) e Redes Neurais Artificiais.

### 2.3.1 Máquina de Suporte Vetorial - SVM

O algoritmo original de Máquina de Suporte Vetorial (SVM) foi implementado por Vladimir N. Vapnik e Alexey Ya. Chervonenkis em 1963. Em 1992, Bernhard Boser, Isabelle Guyon e Vladimir Vapnik sugeriram uma maneira de criar classificadores não lineares. O padrão atual foi proposto por Corinna Cortes e Vapnik em 1993 e publicado em 1995.

As SVM são algoritmos de aprendizagem de máquina que podem ser utilizados como métodos de regressão ou classificação, mediante a construção de modelos hiperplanos. Isto permite que SVM seja um candidato para a classificação entomológica. Assim, o algoritmo de Máquina de Suporte Vetorial possui como foco a classificação de indivíduos de grupos distintos. Comumente algoritmos de máquinas de suporte vetoriais são aplicados quando o objetivo é a descoberta de padrões em conjuntos de dados. Essencialmente, em modelos de classificação, uma Máquina de Suporte Vetorial é responsável em identificar as classes de um determinado conjunto de dados, tendo estes, características que permitem a sua separação linear.

O processo de classificação de uma Máquina de Suporte Vetorial se dá por vetores, dependendo apenas de um subconjunto dos dados de treinamento, pois o modelo aplicado considera apenas dados próximos à margem de classificação. Nesse contexto, a definição de aprendizagem de máquina se dá, como sendo um conjunto de métodos que podem, automaticamente, identificar e deduzir padrões em agrupamentos de dados de treinamento (CHENG *et al.*, 2017). Infelizmente devido à variabilidade nas imagens com *ranges* aproximados e a falta de pré-processamento (LIM; KIM; KIM, 2017), inviabilizou o uso de SVM na extração de características como cor, forma, textura e vetores de descrição. Contudo, as redes neurais artificiais tem como característica a fase de pré-processamentos dos dados, anterior a realização de treinamento, assim, atingindo acurácia satisfatória no resultado e altas taxas de desempenho se comparado a SVM.

A aplicação de pré-processamento permite definir pesos a atributos com valores desconhecidos, usando uma média dos valores apresentados no problema, ou de forma arbitrária distribuindo pesos para o preenchimento de campos desconhecidos. No caso de atributos simbólicos, os valores não numéricos devem ser convertidos para valores numéricos, resultado um vetor binário ou inteiro. As codificações de características em binários associa cada elemento desse vetor a uma entrada de unidade da rede neural, já os valores codificados em inteiros se associam a um único elemento de entrada de rede.

### 2.3.2 Redes Neurais Artificiais - RNA

Redes Neurais Artificiais (RNA) são sistemas formados pela interconexão de unidades de processamento chamados neurônios artificiais (perceptrons). As RNA se baseiam em uma estrutura não linear e podem ser apontadas como uma plausibilidade biológica já fundamentada no conceito de simular o cérebro humano, obtendo *expertise* por meio de treinamento e testes. Com o propósito de simular este aprendizado, são definidos pesos sinápticos de uma forma ordenada para as conexões dos neurônios artificiais, que fazem a representação do conhecimento armazenado na RNA. Os pesos sinápticos são ajustados por meio do processo de treinamento, tornando a RNA capaz de "decidir" com maior ou menor eficácia baseada nos valores recebidos. A eficácia no processo de decisão da rede neural artificial está ligada a sua habilidade de aprender, portanto, generalizar. A generalização refere-se a produção de saídas adequadas para entradas que não estavam presentes durante o processo de treinamento (SOARES *et al.*, 2015).

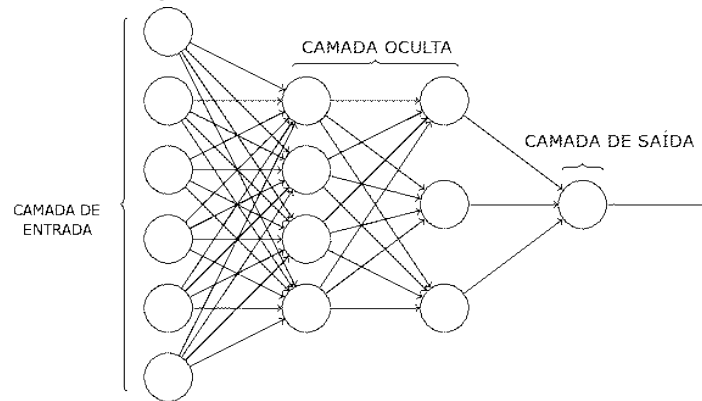
Originária em 1940 pelo matemático Walter Pitts e o neurofisiologista Warren McCulloch, a proposta foi conceber uma analogia entre o processo eletrônico e as funcionalidades do neurônio biológico, por um modelo matemático onde apresentavam a primeira ideia de neurônio computacional como uma unidade de processamento binária, o neurônio McCulloch-Pitts, que possuía "n" valores de entradas, esses valores eram multiplicados por pesos pré determinados, em seguida, os valores de saída são somados e comparados a um valor discriminante. Já em

1949, Donald Hebb, biólogo e psicólogo, reforçava a teoria que o condicionamento em neurônios individuais, contribuindo para processos como memória e aprendizagem (PARK; PARK, 2018). Assim, Donald Hebb propôs então uma hipótese de modelo de aprendizado e as interações entre os neurônios - sinapses no processo de treinamento de sistemas nervosos - alterava a resposta da experiência adquirida. Em 1951, Marvin Minsky, construiu o SNARC, o primeiro simulador de cadeia neural que ajustava seus pesos sinápticos automaticamente. Já em 1956, Nathaniel Rochester apresentou um modelo de rede neural artificial com neurônios interconectados e alterações baseadas em estímulos do ambiente. Em 1959, Frank Rosenblatt introduziu a abordagem com múltiplos neurônios por camadas. Também propôs um algoritmo para o ajuste dos pesos sinápticos matemáticos de cada neurônio computacional. Bernard Widrow desenvolveu um novo protótipo de processamento para redes neurais artificiais a qual se destacava por seu padrão de aprendizado. Em 1986, David E. Rumelhart e James L. McClelland apresentaram uma nova proposta de modelo computacional que explora o treinamento supervisionado dos neurônios artificiais, por um algoritmo de *backpropagation* (PARK; PARK, 2018).

O treinamento supervisionado consiste em uma entrada de dados de valor contínuo ou dados previamente rotulados para capacitar a rede neural artificial a prever a saída para quaisquer dados de entrada válidos, alterando os valores sempre que preciso para que a saída seja a mais próxima do resultado esperado, após observar um número expressivo de exemplos durante os treinamentos. Nesta vertente, o algoritmo de aprendizado é o *backpropagation*, que se desenvolve em duas fases distintas. A fase *forward pass* é a que propaga os dados de entrada, onde cada camada se conecta à próxima camada, as conexões, portanto, têm a mesma direção, partindo da camada de entrada rumo a camada de saída, realizando as multiplicações entre os vetores e excitação dos neurônios, gerando previsões de saída. Já a fase *backward pass* realiza o cálculo da função de perda, baseado nos valores de previsão, após é aplicado recursivamente a regra definida atualizando os valores dos pesos, prática também denominada como retro-propagação. Os cálculos que auxiliam a RNA na descoberta dos valores finais são executados nas camadas ocultas, que apesar de não interagirem com o ambiente externo, exercem enorme influência no funcionamento da rede neural artificial. Neste treinamento supervisionado, com o erro calculado, onde o algoritmo corrige os pesos em todas as camadas, partindo da camada de saída até a camada de entrada, o caminho inverso feito pelo modelo *feedforward* (LEGNINI *et al.*, 2014).

A camada de saída é responsável por retornar o padrão ao ambiente externo. O número de neurônios da camada de saída está diretamente relacionado com a tarefa que a rede neural executa. Em geral, o número de neurônios presentes na camada de saída, é igual ao número de grupos distintos. A estrutura das camadas de uma RNA pode ser observada na Figura 13.

**Figura 13 – Modelo de Camadas da RNA.**



**Fonte: Autoria própria (2022).**

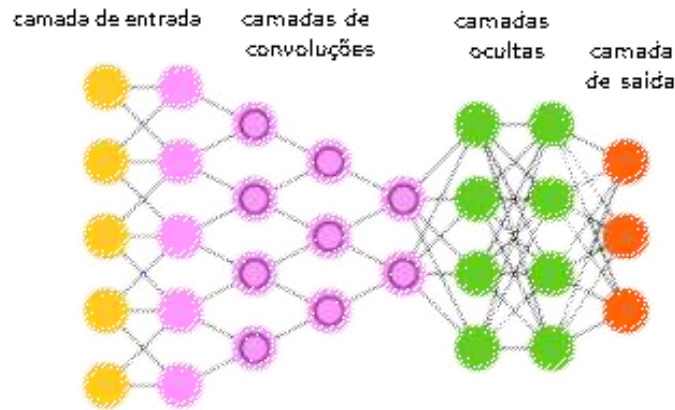
A complexidade da RNA define quantas camadas ocultas serão necessárias entre as camadas de entrada e saída. Os dados de entrada e o problema a ser solucionado definem os valores recebidos pelos neurônios em cada camada. Classes de RNA que possuam melhor aplicabilidade em problemas específicos também podem ser utilizadas, é o caso da rede neural convolucional, que possui maior taxa de precisão quando aplicada a reconhecimento de imagens.

## 2.4 Rede Neural Convolucional - CNN

Seguindo a estrutura não linear das RNA, as Redes Neurais Convolucionais (CNN), são uma evolução no campo da *Deep Learning*. Redes Neurais Convolucionais estão sendo aplicadas nos campos de reconhecimento de imagens, pois apresentam resultados satisfatórios na capacidade de extração automática de características gerais das imagens (LECUN; BENGIO; HINTON, 2015).

A capacidade de extração de características das imagens sem a imposição de um pré-processamento, faz com que as Redes Neurais Convolucionais demonstrem vantagens sobre os métodos tradicionais de aprendizagem de máquina. O número de características extraídas é equivalente ao número de camadas de convolução exemplificado na Figura 14.

**Figura 14 – Modelo de Camadas Rede Neural Convolutacional.**



**Fonte: Autoria própria (2022).**

Por se utilizarem de um maior número camadas e parâmetros quando comparado com redes neurais tradicionais, conseguem maior execução paralela, sua extração de informações das imagens é mais eficiente. Esse modelo de rede neural combina camadas de convolução, de retificação não linear e de agregações em sequência, extraindo e selecionando recursos de maneira hierárquica e, finalmente, tornando um classificador (KIM, 2014; LAI *et al.*, 2015; AMIR *et al.*, 2016). As redes neurais convolucionais, por meio de suas convoluções, são inspiradas no córtex visual de animais, o sistema de processamento visual mais poderoso existente, utilizando um modelo de perceptrons multicamadas.

No córtex visual dos animais, a luz projetada na retina é decomposta e remodelada em pulsos elétricos. Os pulsos elétricos são enviados ao nervo óptico para decodificação. O córtex visual reconhece os elementos da imagem, quebrando-as e analisando as partes separadamente.

Baseadas no processo biológico do córtex visual, as Redes Neurais Convolucionais são constituídas por duas etapas centrais: extração de características e classificação. Para uma melhor extração das características existe a necessidade correta de passagem das especificações por meio dos hiperparâmetros, camadas que irão compor a rede neural convolutacional. Essas camadas são responsáveis pelo tratamento e disposição dos dados desde sua entrada até que sejam encaminhados para a classificação.

Ao final da execução de todas as camadas da rede neural convolutacional, os dados dispostos são ajustados automaticamente por meio do conceito de *Backpropagation*, transformando seus pesos dinamicamente a fim de chegar a classificação mais promissora dos dados (HOCHULI, 2016). Dentre as etapas de execução da rede neural convolutacional se destacam as de convolução, *pooling* e totalmente conectada.

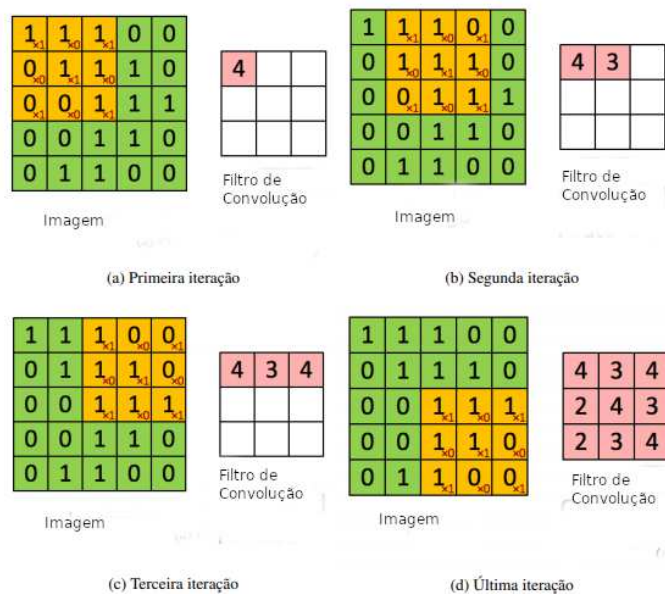
### 2.4.1 Convolução

A etapa de convolução é formada digitalmente por mapas de atributos ou características que se conectam à camada anterior, usando parâmetros partilhados entre todos os elementos. O conjunto de filtros que formam as camadas convolucionais recebem o *input* de um arranjo 3D, chamado volume. Apesar de todo filtro possuir uma dimensão reduzida, ele engloba toda a profundidade do volume. Esses filtros são ajustados de maneira automática. Ao presenciarem alguma característica significativa eles são ativados. Essas características podem ser marcas de cores ou orientação de bordas (RAWAT; WANG, 2017). A significância das características são previamente definidas pelo conjunto de amostras classificadas; logo a ativação dos filtros é sempre otimizada.

O resultado obtido com a ativação dos filtros da convolução se baseia em três critérios, estes definem a dimensão do volume resultante da camada convolucional, são eles: *depth*, *stride* e *padding* (KARN, 2016). Cada filtro aplicado é responsável por captar uma característica, portanto a profundidade do volume depende do número de filtros. Portanto, quanto mais filtros, maior é o número de características extraídas, porém a demanda de tempo e recursos computacionais também se eleva.

Segundo KARN (2016), ao aplicarmos filtros de extração de características, podemos compreender a convolução de uma maneira mais simples se a tratarmos como uma JANELA DESLIZANTE aplicada, que percorre uma matriz, ilustrado pela sequência de imagem presentes na Figura 15.

**Figura 15 – Esquema ilustrativo do processo de Convolução.**



Fonte: KARN,2016.

A matriz "A" representada no canto superior à esquerda da Figura 15 representa uma figura onde cada binário 0 e 1 reflete a um pixel. A JANELA DESLIZANTE se chama *kernel* e representa o identificador de atributos ou filtro. Na imagem acima, se utilizou um *kernel* de proporção 3x3, que pratica a multiplicação dos binários conforme o valor da matriz original e, posteriormente, o soma. É necessário aplicar o processo sobre toda a matriz para que a convolução completa seja apresentada, uma nova matriz armazena esses valores, essa matriz pode ser chamada de vetor, esses valores serão repassados a próxima camada da rede neural convolucional (KARN, 2016).

Todo o processo que ocorre na convolução para captação dos vetores pode ser apresentado analogamente em matemática, onde se define como a modificação de uma variável de entrada, a fim de gerar uma variável de saída. Dessa maneira, o cálculo de convolução se torna relevante e pode ser aplicado em diversas áreas do conhecimento (YNOGUTI, 2017). Em nível de equivalência a um cálculo matemático de duas funções  $f$  e  $g$ , os quais constituem uma terceira função, representando uma função modificada de  $f$ . No procedimento manipulatório de imagens, onde a definição da imagem se dá como uma função bidimensional. A convolução pode ser usada para identificar bordas, suavizar imagens, extrair características, dentre outras finalidades (PARKER, 2010). Dada as funções  $f$  e  $g$ , para  $x$  sendo uma variável discreta, onde  $*$  representa o operador da convolução para as funções, quando  $x$  está presente no conjunto de inteiros  $Z$ , podemos observar a equação na Figura 16.

**Figura 16 – Modelo de Equação de Convolução Discreta.**

$$f(x) * g(x) = \sum_{n=-\infty}^{\infty} f(n).g(x - n)$$

**Fonte: Adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016).**

A interpretação do processo de convolução em uma imagem é feita por meio do somatório de cada componente da imagem, com seu antecessor e sucessor. Estes se somam aos componentes da matriz então correspondentes ao filtro de convolução.

#### 2.4.2 Pooling


Na etapa de *pooling*, funções matemáticas independentes pretendem diminuir a extensão da amostra de dados recebida sem a perda de informações - busca um aperfeiçoamento do processamento computacional. O *pooling* é executado após a aplicação dos filtros convolucionais.

Apesar de sua execução ser posterior a aplicação dos filtros convolucionais, o *pooling* trabalha de maneira semelhante, verificando toda a matriz por meio de uma JANELA DESLIZANTE. A Figura 17 demonstra a execução do *pooling* utilizando uma janela 2x2 em uma matriz e definindo a função MAX POOLING. Dessa maneira, o que se resulta é uma matriz com metade



da altura e metade da largura, possuindo os maiores valores obtidos pela verificação do *pooling* na matriz principal.

**Figura 17 – Esquema ilustrativo do processo de *pooling*.**



Fonte: Autoria própria (2022).

Os maiores valores apresentados com a aplicação da função MAX POOLING, tem por objetivo eliminar valores desprezíveis e gerar matrizes menores e acelerar o processamento para as próximas camadas.

#### 2.4.3 Totalmente Conectada

Por fim, a etapa de classificação é ALIMENTADA por dados oriundos da extração de características da imagem de entrada. A classificação da imagem de entrada é feita por meio do recebimento de um vetor de valores, onde é feita a distribuição por probabilidade, a fim de julgar a qual classe treinada anteriormente a imagem de entrada pertence.

A soma de todas as probabilidades sempre serão iguais 1. O estabelecimento da camada totalmente conectada se dá por meio de neurônios. A expressão totalmente conectada descreve a ligação de todos os neurônios das camadas anteriores a todos os neurônios das camadas subsequentes (GOODFELLOW; BENGIO; COURVILLE, 2016).

### 3 MATERIAIS E MÉTODOS

#### 3.1 Materiais

Wolfram Mathematica é um *software* proprietário multiplataforma pertencente a Wolfram Research, pode ser executado em sua versão *desktop*, ou navegador. Os dois formatos possuem integração com a Wolfram Cloud<sup>®</sup>. Wolfram Cloud<sup>®</sup> é um serviço de armazenamento em nuvem disponibilizado pela Wolfram Research<sup>®</sup>, que pode ser utilizado para *backup*, além de permitir o uso recorrente de chaves (funções) externas, vinculadas ao usuário cadastrado no *software* (RESEARCH, 2021). Para o desenvolvimento do projeto foi empregue o Wolfram Mathematica<sup>®</sup> em sua versão *desktop* 12.1, a versão mais recente disponível no período de execução do projeto, sendo praticado em um sistema operacional Windows 10.

Na sua versão 12.1 o Wolfram Mathematica<sup>®</sup> disponibiliza para a implementação de algoritmos um editor de código integrado, chamado Wolfram Notebook, seu uso permite gerar códigos que podem ser executados em simultâneo ao desenvolvimento, além de permitir aplicar formatação de texto e gráficos dinâmicos. O Wolfram Notebook possui a capacidade de tornar executável qualquer fragmento do código por meio de programação incremental, que combina elementos dos fluxos de processos tanto lineares quanto paralelos, por possuir um compilador integrado. Transferindo ao Wolfram Mathematica<sup>®</sup> a capacidade de manipular tanto a estrutura como o conteúdo do código imediatamente.

Todas as ferramentas necessárias para o desenvolvimento do projeto estão incluídas na plataforma da Wolfram Research<sup>®</sup>, não sendo necessário o uso de ferramentas de apoio ou bibliotecas computacionais externas à plataforma. Como suporte para obtenção de dados detalhados será utilizado o Wolfram Alpha.

Wolfram Alpha é um mecanismo de conhecimento computacional, oferecido no formato *online* pela Wolfram Research. Seu funcionamento se dá por meio de uma base de dados estruturados, possuindo um *dataset* de informações acrescentadas ao longo dos anos, desde o início de seu desenvolvimento. O Wolfram Alpha fornece respostas precisas sobre as pesquisas dos usuários, ou direciona para links onde o usuário possa encontrar a resposta solicitada (WOLFRAMALPHA, 2021).

Para obter características e resultados relevantes a pesquisa, funções nativas do Wolfram Mathematica<sup>®</sup> foram aplicadas ao *script*, todas descritas abaixo.

**IMAGEIDENTIFY** - função que visa buscar no *dataset* de imagens treinadas na rede neural convolucional o resultado para a imagem apresentada a fim de reconhecimento.

**TEXTTRANSLATION E TRANSLATE** - dois módulos distintos para tradução de texto no Wolfram Mathematica<sup>®</sup>, ambos aplicados para obtenção dos resultados em português.

**WEBIMAGESEARCH** - função que permite aplicação de buscas externas na internet, a partir do acréscimo de Interface de Programação de Aplicação (API) no *script* do *software*.

Definiu-se então os dois *datasets* que seriam aplicados para teste, eles foram formados com imagens buscadas na internet em bancos de dados livres de direitos autorais e por fotos tiradas no laboratório de entomologia da Universidade Tecnológica Federal do Paraná (UTFPR), no câmpus de Pato Branco, alguns exemplos das imagens utilizadas podem ser vistos na Figura 18, os *datasets* completos podem ser observados nos anexos A e B.

**Figura 18 – Agrupamento de algumas imagens utilizadas na validação da função**



Fonte: Autoria própria (2022).

O modelo definido de busca por imagens possui o intuito de validar o reconhecimento de insetos nos mais diversos cenários possíveis, estando com planos de fundo variados, ou mesmo somente o inseto, sem obstáculos na imagem que pudessem gerar uma confusão no processamento de dados.

A linguagem de programação definida para desenvolvimento do algoritmo foi a *Wolfram Language*, uma herança da linguagem funcional Lisp®. A linguagem funcional se destaca por sua robustez, simplicidade de escrita na criação de *scriptss* e exatidão nas respostas, se tornando uma alternativa às demais linguagens de programação.

### 3.2 Método

A pesquisa de natureza aplicada foi selecionada para ao desenvolvimento do projeto, esse modelo de pesquisa visa a geração de conhecimento com aplicação prática, dirigidos à solução de problemas específicos. Foi definido o modelo de pesquisa aplicada, visto que, o problema a ser solucionado caracteriza a especificidade do reconhecimento de imagens de insetos.

Essa especificidade permite a aplicação do método indutivo no reconhecimento das imagens de insetos por meio da aplicação de rede neural convolucional com 36 imagens selecionadas aleatoriamente para teste e outras 18 imagens de insetos regionais, totalizando 54 amostras número suficiente para se obter dados, se aplicadas para reconhecimento.

Ao usar o método indutivo, definiu-se os dados numa abordagem quantitativa. O modelo de dados quantitativos tem caráter conclusivo, seu objetivo é quantificar um problema e entender a dimensão dele. Em suma, esse tipo de pesquisa fornece informações numéricas sobre o problema pesquisado. Os dados coletados por meio deste método impactam diretamente na tomada de decisão, no caso do projeto, os dados obtidos pelo teste do reconhecimento de imagens pela rede neural convolucional, determina a precisão do reconhecimento.

Para cumprir os modelos de pesquisa sugeridos, o projeto se desenvolveu seguindo os módulos funcionais obedecendo à metodologia ágil de engenharia de software do ciclo de vida *Scrum*. O método de desenvolvimento *Scrum* se baseia em uma abordagem escalável, sendo executada em fases curtas chamadas *Sprints*. Cada *Sprint* apresenta um ciclo completo sendo definido objetivo e fornecendo um resultado para a demanda apresentada.

Foi criando então um *Sprint Planning*, que se trata de um plano de desenvolvimento rápido, onde demandas podem ser iniciadas e encerradas em um curto período, definindo e separando as demandas de implementação por *Sprints* que podem ser apresentados como: reconhecimento das imagens dos insetos e descrição, busca por complemento de imagens externas, apresentação da taxonomia do inseto reconhecido pela rede neural convolucional.

## 4 RESULTADOS

Os resultados da implementação do algoritmo foram obtidos através da aplicação do *Sprint Planning* por meio de oito *sprints* que apresentam a robustez do algoritmo desenvolvido, sendo eles: Reconhecimento, Descrição, Tradução da Descrição, Busca de Imagens do Google, Taxonomia e Dados Relevantes, Categorização de insetos similares, Reconhecimento por contorno de imagens e Taxas de Reconhecimento da Rede Neural.

### 4.1 *Sprint 1 - Reconhecimento*

As apresentações dos resultados, como características primárias, nome e descrição são fatores determinantes para o prosseguimento do desenvolvimento do *software*, ao buscar o reconhecimento das imagens de insetos pode ser observado dados iniciais dos índices de reconhecimento presentes na base de dados da rede neural convolucional. Executando um teste com as imagens presentes nos *datasets* foi possível observar que os dados trazidos pela função `IMAGEIDENTIFY` eram insuficientes, apresentando apenas uma linha de descrição das características do inseto e sem deixar claro qual função no meio ambiente.

### 4.2 *Sprint 2 - Descrição*

Observando a limitação em apresentar as características primárias das imagens dos insetos propostos para classificação, fez-se necessário a implementação de uma função computacional de importação da descrição capaz de obter dados de descrição mais completa. A função implementada busca por uma Identidade de Usuário (ID) dentro de um arquivo externo de texto no formato TXT, onde foram escritas características relevantes dos insetos. Para o desenvolvimento foi definido como ID o campo nome, onde o parâmetro a ser pesquisado é passado assim que a rede neural convolucional reconhece a imagem do inseto apresentado.

Para que a leitura do ID seja realizada no arquivo de texto é necessário apresentar como parâmetro da variável o caminho de localização do arquivo no computador. A lista de itens presentes no arquivo é gravada, por meio da função `RECORD`, assim como seus separadores, por meio de da função `RECORDSEPARATORS`, após isso é executado a função `FINDLIST`, que encontra onde está localizado na lista o ID com o nome do inseto trazido pelo reconhecimento da rede neural convolucional, apresentando a descrição definida para o inseto em questão.

Nesta vertente para os teste iniciais foram utilizadas as imagens do besouro de batata colorado (*colorado potato beetle*) e da borboleta almirante branco, (*white admiral butterfly*), por serem imagens com características distintas, onde em ambos os casos o *software* trouxe os resultados integralmente em inglês, surgindo a necessidade da tradução desses resultados para o português do Brasil.

### 4.3 *Sprint 3* - Tradução da Descrição

Para que a tradução ocorresse e os resultados fossem apresentados no idioma português do Brasil, foi necessária a execução das funções `TEXTTRANSLATION` e `TRANSLATE`, esses módulos são aplicados no código, antecedendo a função a ser traduzida. Ao analisar os dados trazidos como resultado do reconhecimento dos insetos, observou-se a necessidade de apresentar mais amostras da espécie ao usuário, aplicando então um buscador externo ao algoritmo.

### 4.4 *Sprint 4* - Busca de Imagens do Google

Após a execução correta da aplicação de módulos de tradução de texto, buscou-se ampliar o leque de informações apresentadas ao usuário, em novo teste, definiu-se que o *software* buscaria três imagens externas para representar a espécie. O Wolfram Mathematica® apresenta a possibilidade da incorporação de duas ferramentas de busca, por meio da importação de sua Interface de Programação de Aplicação (API), o buscador Bing®, um motor de busca desenvolvido pela Microsoft e Google®, buscador mantido pela Alphabet®.

O Google® foi definido como buscador a ser incorporado ao código e sua escolha se baseou na familiaridade de uso, conseguindo apresentar resultados mais satisfatórios na busca de imagens. Sua importação foi feita por meio de da função `WEBIMAGESEARCH`, integrando o buscador ao Wolfram Mathematica®. Para a integração da ferramenta de pesquisa é necessária a criação de uma chave de usuário dentro do buscador da Google, integrando a chave ao usuário conectado à Wolfram Cloud®. Também foi optado pela tradução da função principal implementada para `QUEINSETOÉ` de modo a auxiliar o reconhecimento da função para utilização pelo usuário comum. O resultado da troca de nome da função e a busca de imagens externas podem ser observados na Figura 19.

Figura 19 – Função Queinsetoé.



Fonte: Autoria própria (2022).

A aplicação da WEBIMAGESEARCH integrado com os dados do usuário do Wolfram Cloud® fazem com que toda vez executada consuma um crédito do usuário, por ser um *software* proprietário, o Wolfram Mathematica® apresenta algumas limitações em suas funções gratuitas, porém nada que influencie no desenvolvimento do projeto. Um meio obtido para melhorar os resultados apresentados é a utilização do Wolfram Alfa®, ferramenta que ao incorporado traz dados da cadeia taxonômica dos insetos.

#### 4.5 *Sprint 5 - Taxonomia e Dados Relevantes*

Ao pesquisar sobre um conteúdo mais denso de dados que poderiam ser apresentados ao usuário, observou-se que a apresentação da taxonomia seria relevante ao projeto, optou-se então pela definição trazida pelo Wolfram Alpha®, onde os dados trazidos acabam detalhando a espécie apresentada para reconhecimento. Observou-se uma limitação até o momento na implementação da função do Wolfram Alpha®, a dificuldade de incorporação dos módulos de tradução, sendo apresentado como resultado da busca a página original em inglês, como pode ser observado na Figura 20.

**Figura 20 – Wolfram Alpha.**

( | white admiral butterfly → 0.476588, brush-footed butterfly → 0.813328, white admiral → 0.278699 | )

---

Assuming white admiral | Use white admiral butterfly instead

---

Input interpretation:  
white admiral (animal)

---

Scientific name:  
*Limenitis arthemis*

---

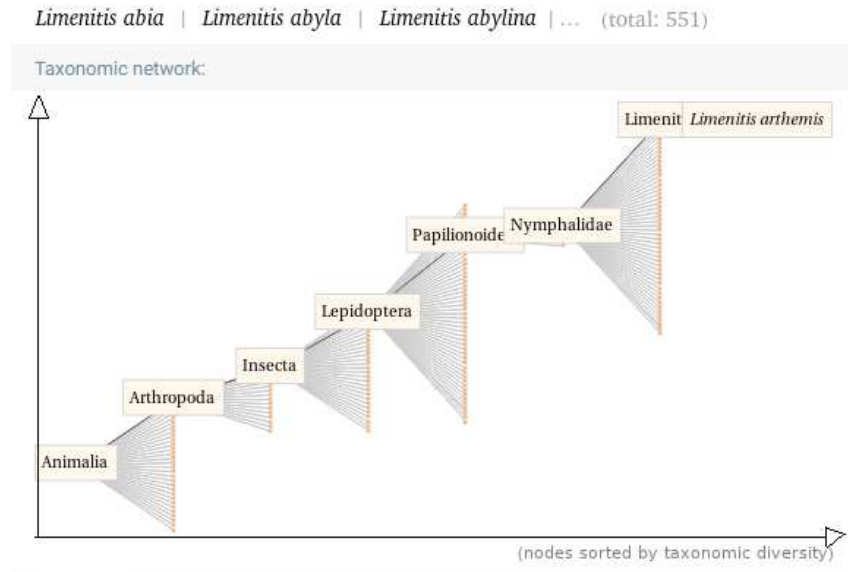
Taxonomy:

kingdom	Animalia (animals)
phylum	Arthropoda (arthropods)
class	Insecta (insects)
order	Lepidoptera (moths and butterflies)
family	Nymphalidae (brush footed butterflies)
genus	Limenitis (admirals)
species	<i>Limenitis arthemis</i> (white admiral)

Fonte: Wolfram Alpha,2021.

Além de uma segunda descrição da espécie do inseto reconhecido, Wolfram Alpha® apresenta toda a rede taxonômica da espécie, trazendo em formato de imagem que inclui o reino, filo, classe, ordem, família, gênero e espécie, tal é visto na Figura 21.

**Figura 21 – Taxonomia.**



Fonte: Wolfram Alpha,2021.

Fatores relevantes foram implementados para serem apresentados como devolutiva ao usuário quando uma imagem é reconhecida, a probabilidade aplicada pela rede neural convolucional para chegar a conclusão de qual inseto a imagem proposta representa, usamos para obter esses dados a função PROBABILITY onde foi definido que seja apresentado os três indivíduos com maior probabilidade de ser a resposta correta, como podemos ver na Figura 22.

**Figura 22 – Probability.**




Fonte: Autoria própria (2022).



#### 4.6 *Sprint 6* - Categorização de insetos similares

Alguns testes com mais de uma espécie de inseto por vez, também foram aplicados. Além do reconhecimento, a categorização das espécies foi observada. O processo de categorização consiste em reconhecer, diferenciar e classificar, as espécies de insetos, separando-os por grupos ou categorias. Para isto foi acrescentada a função `FEATURESPACEPLOT`, que objetiva plotar o resultado da categorização por meio de uma imagem com agrupamento dos insetos semelhantes. Observou-se que se maior o número de indivíduos da amostra, então melhor a taxa de precisão do agrupamento. Podemos observar o exemplo validado na Figura 23, onde foram acrescentadas barras na modificação da imagem, ocasionando a divisão entre os quatro agrupamentos apresentados para melhor compreensão do leitor.




Fonte: Autoria própria (2022)

#### 4.7 *Sprint 7* - Reconhecimento por contorno de imagens

Também foram aplicados testes de borda das imagens com a rede neural convolucional. Pela função `COLORNEGATE@EDGEDETECT@`, a qual se objetiva a conversão da imagem, apresentando apenas seus contornos, a imagem gerada após aplicação da função pode ser observada na Figura 24. Logo após sua conversão as imagens dos insetos são reapresentadas para reconhecimento.

**Figura 24 – Correlação.**



**Fonte: Aatoria própria (2022).**

Seu objetivo é permitir a identificação de semelhanças ou equivalências entre os resultados dos testes aplicados com a imagem em cores e a imagem apresentando apenas os contornos.

#### **4.8 *Sprint 8* - Taxas de Reconhecimento da Rede Neural Convolutacional**

O meio computacional empregado compreendeu dois agrupamentos de 54 imagens de insetos de diferentes espécies, imagens no formato colorido e em contornos, apresentando dois indivíduos da mesma família, são eles: a borboleta almirante branco e a borboleta almirante vermelho.

Buscando observar as limitações de reconhecimento das imagens pela rede neural convolutacional, a aplicação dos testes se deu com imagens coloridas obtidas por meio de banco de imagens e fotografias feitas pelo autor a partir de insetos reais armazenados para estudo no laboratório da Universidade Tecnológica Federal do Paraná (UTFPR) no campus de Pato Branco. Posteriormente feito sua conversão em contornos, e assim refeita a aplicação dos testes, apresentando então o contorno das imagens como espécie a ser reconhecida. Visando observar qual seria a probabilidade de reconhecimento ao utilizar apenas os contornos dos insetos, os dados podem ser melhor observados na tabela 1.

**Tabela 1 – Tabela com os dados de estudo**

	Imagens Coloridas	Contornos	Ambos	Sem Reconhecimento
Número de Imagens	54	54	108	108
Porcentagem de Reconhecimento	68,52%	1,62%	1,62%	9,18%

**Fonte: Aatoria própria (2022).**


Ao utilizar apenas os contornos das imagens de insetos não foram obtidos resultados expressivos, apenas 1.62% das imagens foram reconhecidas. Diferentemente da aplicação do primeiro teste onde foram utilizadas imagens coloridas, e a taxa de reconhecimento foi

de 68.52%. Apenas 9.18% imagens não obtiveram reconhecimento de nenhuma maneira. Em apenas 1.62% dos casos foram obtidos resultados corretos ao apresentar como parâmetro a imagem em cores e posteriormente apenas seu contorno.

Após a obtenção das porcentagens de reconhecimento surgiu então a necessidade de uma melhor visualização dos resultados. Assim foram enumeradas as amostras de imagens de insetos de 1 a 54, a totalidade das amostras de imagens coloridas. Com isso definiram-se pesos de 1 a 4, sendo 1 - Imagens Coloridas, 2 - Não Reconhecido, 3 - Contornos e 4 - Ambos, gerando assim uma planilha no formato .XLSX para ser aplicada como base de dados no RStudio®. Assim, podemos obter uma melhor visualização dos resultados referente as porcentagens gerando um gráfico dendrograma ao aplicarmos análise de agrupamento.

A análise de agrupamento é uma técnica analítica pertencente a análise multivariada, sua aplicação ocorre quando surge a necessidade de identificação de grupos em dados multivariados. Seu princípio consiste em observação da amostra e seu espaço euclidiano multidimensional, onde o resultado é o agrupamento dos pontos que ocorre através da análise dos aspectos marcantes evidenciados na amostra. O resultado se apresenta graficamente pela aplicação métodos hierárquicos, representado em forma de um gráfico dendrograma contendo a síntese dos resultados. Ao aplicarmos os dados de reconhecimento das imagens de insetos obtivemos o gráfico dendrograma apresentado na Figura 25.

**Figura 25 – Gráfico Dendrograma.**



**Fonte: Autoria própria (2022).**

Ao realizarmos o exame do dendrograma, podemos observar o número de reconhecimento de cada amostra na parte inferior e os índices de similaridades que correspondem às distâncias euclidianas em que ocorrem as junções dos pontos observados para formar grupos podem ser lidos do lado esquerdo variando de 0 a 4. Distâncias com valores bastante discrepantes indicam que a agregação percebeu grupos muito dissimilares e, em razão disso, devem ser definidos os números anteriores a esses valores.

Em virtude do que foi mencionado ao analisarmos as amostras aplicadas para teste na rede neural convolucional foi possível observar que a posição das imagens interfere no seu reconhecimento. Imagem de inseto sem composição de *background*, obtiveram melhor taxa de reconhecimento, bem como imagens coloridas, visto que a taxa de sucessos em imagens apenas com contornos apresentou considerável queda.

## 5 CONCLUSÃO

Por todos esses aspectos é imprescindível a conscientização acerca da importância da classe Insecta para todo o ecossistema, visto que são agentes reguladores ambientais, suas ações causam grande interferência no meio em que vivem, afetando não somente sua espécie mas o todo.

Indubitavelmente o estímulo das ações humanas sobre as espécies de insetos também acarretam interferências em cadeia ao meio ambiente. Torna-se então cada vez mais necessária a correta identificação das espécies de inseto, em busca de evitar desequilíbrio ambiental, diminuindo a margem para equívocos quanto à interação sobre as espécies danosas ou não.

O estudo apresentado compreende o uso de inteligência artificial, através da aplicação de rede neural convolucional, um modelo algorítmico capaz de obter resultados interessantes quando utilizado a fins de reconhecimento de imagens. Essa aplicação se deu através do *software* Wolfram Mathematica<sup>®</sup>, onde apesar de proprietário, possui fluidez e permite desenvolvimentos em uma ampla gama de áreas do conhecimento.

Explorando a capacidade do *software* Wolfram Mathematica<sup>®</sup> ao ivés de um resultado, conseguimos 8 *sprints*, cada um apresentado um objetivo e conclusão de aplicação, gerando assim, além do todo, um resultado individual para cada *sprint*, demonstrando que além do reconhecimento, o algoritmo criado tem a capacidade de obter dados em vários níveis de importância.

Tendo em vista os resultados obtidos pelas taxas de reconhecimento, observou-se que o reconhecimento em imagens coloridas apresentou taxas superiores, visto que o treinamento da rede neural compreende imagens com esse formato, já em teste de reconhecimento de contornos percebe-se que pode haver espaço para melhorias na estrutura da rede neural convolucional, pode ser percebido que apenas contornos não haviam sido apresentados na etapa de treinamento, visto que por fazer parte de um *software* proprietário não se tem acesso às nuances de seu algoritmo, mesmo assim por meio do algoritmo criado foi possível apresentar algum reconhecimento, porém com restrições, já que qualquer imagem com *background* confunde a execução da rede neural convolucional, fazendo-a compreender que todo traço da imagem faz parte da mesma espécie, por não ter sido treinada com esse propósito, abrindo assim espaço para que sua aplicação seja replicada em outros modelos, estes abertos.

## 6 TRABALHOS FUTUROS

Como pesquisas futuras pode-se considerar a apresentação da geolocalização dos insetos, bem como o mapeamento das espécies de insetos regionais, assim alimentando a base de dados da rede neural convolucional e direcionando sua aplicação a localidade proposta.

Melhorias nos resultados obtidos pela execução do *software* podem ser exploradas, o reconhecimento pode ser aprimorado quando se é apresentado apenas o contorno da imagem. Ainda não foi possível a aplicação da tradução *on-the-fly* na importação de dados do Wolfram Alpha<sup>®</sup>. Pode-se também ocultar a apresentação de toda a lista de insetos presentes no arquivo .TXT, a *database* local de descrição das espécies de insetos.

Algumas correções no software também podem ser exploradas, como a aplicação do código em outras versões do *software* Wolfram Mathematica<sup>®</sup> e sua execução externa a plataforma Wolfram Research<sup>®</sup>.

## REFERÊNCIAS

- AMIR, S. *et al.* **Modelling Context with User Embeddings for Sarcasm Detection in Social Media**. 2016.
- BARROS, R.; FILHO, G. P. d. A.; ARRUDA, G. P. d. Ocorrência da cochonilha escama vermelha [*aonidiella aurantii* mask., 1878](homoptera: Diaspididae) em mamoeiro no estado de pernambuco. 2001.
- CARDOSO, J. dos S.; CARVALHO, K. S.; TEIXEIRA, P. M. M. Um estudo sobre a abordagem da classe insecta nos livros didáticos de ciências. **Sitientibus Série Ciências Biológicas**, v. 8, n. 1, p. 80–88, 2008.
- CHAPMAN, A. D.; STUDY, A. B. R. **Numbers of living species in Australia and the world**. [S.l.]: Department of the Environment, Water, Heritage and the Arts, Canberra, ACT, 2009.
- CHENG, X. *et al.* Pest identification via deep residual learning in complex background. **Computers and Electronics in Agriculture**, v. 141, p. 351–356, 09 2017.
- COMMONS, W. **File:Modelo em cascata.png — Wikimedia Commons, the free media repository**. 2022. [Online; accessed 10-May-2018]. Disponível em: [https://commons.wikimedia.org/w/index.php?title=File:Modelo\\_em\\_cascata.png&oldid=118160335](https://commons.wikimedia.org/w/index.php?title=File:Modelo_em_cascata.png&oldid=118160335).
- COSTA, E. M. *et al.* Diversidade de coleópteros em área cultivada com melancia no semiárido do rio grande do norte. **Revista Agro@mbiente On-line**, v. 8, n. 2, p. 293–297, 2014.
- CZEPAK, C. *et al.* Primeiro registro de ocorrência de helicoverpa armigera (*hübner*)(lepidoptera: Noctuidae) no brasil. **Pesquisa Agropecuária Tropical**, SciELO Brasil, v. 43, p. 110–113, 2013.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [S.l.]: MIT press, 2016.
- GULLAN, P. J.; CRANSTON, P. S. **Os Insetos: um resumo de entomologia**. São Paulo: Roca, 2012.
- HEYNEMANN, C. B. História e história natural: a escrita da época moderna. **XXII Simpósio Nacional de História**, p. 7, 2003.
- HOCHULI, A. G. **Redes Neurais Convolucionais**. [s.n.], 2016. Disponível em: [https://www.inf.ufpr.br/aghochuli/caffe/CNN\\_PPT.pdf](https://www.inf.ufpr.br/aghochuli/caffe/CNN_PPT.pdf). Acesso em: 18 agosto 2021.
- KARN, U. **An intuitive explanation of convolutional neural networks**. the data science blog, 2016. Disponível em: <https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/>.
- KIM, Y. Convolutional neural networks for sentence classification. In: **Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)**. Doha, Qatar: Association for Computational Linguistics, 2014. p. 1746–1751. Disponível em: <https://aclanthology.org/D14-1181>.
- LAI, S. *et al.* **Recurrent Convolutional Neural Networks for Text Classification**. 2015. Disponível em: <https://www.aai.org/ocs/index.php/AAAI/AAAI15/paper/view/9745/9552>.
- LAMAS, C. J. E. Antonio Carlos e. **Taxonomia zoológica no Brasil: estado da arte, expectativas e sugestões de ações futuras**. Papéis Avulsos de Zoologia, 2006. 139-174 p. Disponível em: <https://doi.org/10.1590/S0031-10492006001300001>.

- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, p. 436–44, 05 2015.
- LEGNINI, I. *et al.* A feedforward regulatory loop between hur and the long noncoding rna linc-md1 controls early phases of myogenesis. **Molecular cell**, Elsevier, v. 53, n. 3, p. 506–514, 2014.
- LEITE, G. L. D. **Entomologia Básica**. Apostila do Instituto de Ciências Agrárias da Universidade Federal de Minas Gerais, 2011. Disponível em: [https://www.ica.ufmg.br/wp-content/uploads/2017/06/ap\\_ent\\_basica.pdf](https://www.ica.ufmg.br/wp-content/uploads/2017/06/ap_ent_basica.pdf).
- LEWINSOHN, T. M.; PRADO, P. I. **Quantas espécies há no Brasil**. São Paulo: Megadiversidade, 2005.
- LIM, S.; KIM, S.; KIM, D. Performance effect analysis for insect classification using convolutional neural network. **2017 7th IEEE International Conference on Control System, Computing and Engineering (ICCSCE)**, p. 210–215, 2017.
- LIMA, W. F. de *et al.* Composição mineral do gafanhoto aposemático semiaquático tetrataenia surinama (linnaeus, 1764)(orthoptera: Acrididae). **Revista Ibero-Americana de Ciências Ambientais**, v. 12, n. 7, p. 135–147, 2021.
- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. **Revista de Informática Teórica e Aplicada**, v. 16, n. 1, p. 125–160, 2009.
- NETO, L. J. T. *et al.* Ocorrência de insetos fitófagos em adenium obesum (forssk.) roem. & schult no estado de goiás. **Revista Agro@mbiente**, v. 11, n. 4, p. 379–384, 2017.
- OLIVEIRA, A. M. *et al.* **Controle biológico de pragas em cultivos comerciais como alternativa ao uso de agrotóxicos**. [S.l.]: Revista Verde de Agroecologia e Desenvolvimento Sustentável, 2006. v.1. 01-09 p.
- PARK, W. J.; PARK, J.-B. History and application of artificial neural networks in dentistry. **European journal of dentistry**, Thieme Medical and Scientific Publishers Private Ltd., v. 12, n. 04, p. 594–601, 2018.
- PARKER, J. R. **Algorithms for image processing and computer vision**. Indianapolis: John Wiley, 2010.
- PEREIRA, P. R. V. da S. *et al.* phum maidis: A) fêmea áptera adulta em sendo a duração média do período. 2006.
- RASPLUS, J. Y. *et al.* **Hymenoptera**. [S.l.]: Pensoft Publishers, 2010.
- RAWAT, W.; WANG, Z. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. **Neural Computation**, v. 29, n. 9, p. 2352–2449, 09 2017. ISSN 0899-7667. Disponível em: [https://doi.org/10.1162/neco\\_a\\_00990](https://doi.org/10.1162/neco_a_00990).
- REINALDO, F. *et al.* **A Tool for Fast Development of Modular and Hierarchic Neural Network-based Systems**. [S.l.]: RESI : Revista Eletrônica de Sistemas de Informação, 2006.
- RESEARCH, W. . **Wolfram|One, Version 12.3.1**. 2021. Champaign, IL. Disponível em: <https://www.wolfram.com/wolfram-one>.
- RUPPERT, E. E.; FOX, R. S.; BARNES, R. D. **Zoologia dos invertebrados: uma abordagem funcional-evolutiva**. São Paulo: Roca, 2005.



SCHWERTNER, C. F.; GRAZIA, J. O gênero chinavia orian (hemiptera, pentatomidae, pentatominae) no brasil, com chave pictórica para os adultos. **Revista Brasileira de Entomologia**, SciELO Brasil, v. 51, p. 416–435, 2007.

SILVA, C. d. e. a. **Sugestões técnicas para o manejo integrado de pragas do algodoeiro no brasil**. Campina Grande: Embrapa Algodão-Circular Técnica (INFOTECA-E), 2013.

SILVA, H. H. G. d. *et al.* Atividade larvicida de taninos isolados de magonia pubescens st. hil.(sapindaceae) sobre aedes aegypti (diptera, culicidae). **Revista da Sociedade Brasileira de Medicina Tropical**, SciELO Brasil, v. 37, p. 396–399, 2004.

SNYMAN, L. P. *et al.* A review of the biology and biogeography of mantispidae (neuroptera). **Insect Systematics & Evolution**, Brill, v. 52, n. 2, p. 125–166, 2020.

SOARES, F. C. *et al.* Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, SciELO Brasil, v. 45, p. 1987–1993, 2015.

SOUZA, A. G. M. de; NETO, V. d. J. L.; JÚNIOR, A. P. Revisão integrativa sobre biologia, qualidade da água e a ordem odonata. **Research, Society and Development**, v. 10, n. 9, p. e24910917605–e24910917605, 2021.

STORER, T. I. *et al.* **Zoologia Geral**. São Paulo: Companhia Editora Nacional, 2003. v.6.

TOSCANO, W. **Inteligência Artificial Introdução**. [S.l.]: UNINOVE, 2009.

VILANI, D. B.; BIANCHI, V.; HOUSSAINI, M. L. T. S. Feromônios, uma importante ferramenta dos insetos. **Salão do Conhecimento**, 2015.

WOLF, L. F.; REIS, V. D. A.; SANTOS, R. S. S. **Abelhas melíferas: bioindicadores de qualidade ambiental e de sustentabilidade da agricultura familiar de base ecológica**. Pelotas: Embrapa, 2008.

WOLFRAMALPHA. 2021. <https://www.wolframalpha.com/>. "acessado em 10/08/2021".

YNOGUTI, C. **Processamento Digital de Sinais**. Santa Rita do Sapucaí: Instituto Nacional de Telecomunicações, 2017.

**ANEXO A – Agrupamento de Imagens Coloridas Aplicadas em Teste da  
Rede Neural Convolucional**



**ANEXO B – Agrupamento de Contornos Aplicadas em Teste da Rede  
Neural Convolutacional**

