

**UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE
CAMPUS DE NATAL
DEPARTAMENTO DE COMPUTAÇÃO
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

PAULO HENRIQUE LOPES CARLOS

**OCTOPUS TRACKER:
Ferramenta para rastrear paralarvas de polvo**

**NATAL
2019**

PAULO HENRIQUE LOPES CARLOS

**OCTOPUS TRACKER:
Ferramenta para rastrear paralarvas de polvo**

Trabalho de Conclusão de Curso apresentado à Universidade do Estado do Rio Grande do Norte - UERN - como requisito obrigatório para obtenção do título de Bacharel em Ciência da Computação.

ORIENTADOR:

Prof. Dr. Wilfredo Blanco Figuerola

NATAL
2019

L864o Lopes Carlos, Paulo Henrique

OCTOPUS TRACKER: Ferramenta para rastrear
paralarvas de polvo. / Paulo Henrique Lopes Carlos. -
Natal, 2019.
52p.

Orientador(a): Prof. Dr. Wilfredo Blanco Figuerola.
Monografia (Graduação em Ciência da Computação).
Universidade do Estado do Rio Grande do Norte.

1. Octopus insularis. Localização e rastreamento.
Visão Computacional. Inteligência Artificial. Redes Neurais
Convolucionais.. I. Figuerola, Wilfredo Blanco. II.
Universidade do Estado do Rio Grande do Norte. III.
Título.

PAULO HENRIQUE LOPES CARLOS

OCTOPUS TRACKER:

Ferramenta para rastrear paralarvas de polvo

Trabalho de Conclusão de Curso
apresentado à Universidade do
Estado do Rio Grande do Norte -
UERN - como requisito obrigatório
para obtenção do título de Bacharel
em Ciência da Computação.

Aprovado em: __/__/__.

Banca Examinadora

Prof. Dr. Wilfredo Blanco Figuerola
Universidade do Estado do Rio Grande do Norte

Prof. Dra. Adriana Takahashi
Universidade do Estado do Rio Grande do Norte

Prof. Me. Bruno Cruz de Oliveira
Universidade do Estado do Rio Grande do Norte

AGRADECIMENTOS

Este estudo recebeu o apoio da UFRN, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Universal 408145/2016-1 e Produtividade em Pesquisa 308775/2015-5; Centro de Neuromatemática da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) 2013/07699-0, Boehringer-Ingelheim International GmbH (outorga 270561). Agradecimentos a aluna de mestrado Sylvia Lima de Souza Medeiros e ao Dr. Prof. Sidarta Ribeiro do Instituto do Cérebro - UFRN por cederem os vídeos analisados pela ferramenta. Ao aluno João Paulo Trindade do curso de Ciência da Computação da UERN Campus de Natal por sua colaboração e ajuda ao longo de todo este trabalho. Por fim, ao CNPq UERN pelo apoio financeiro.

RESUMO

No campo da biologia, o registro e estudo do comportamento de animais são tradicionalmente feitos de maneira manual, causando desconforto aos pesquisadores, imprecisões nos resultados e dispêndio de tempo. Uma das espécies de polvo que possuem poucos dados é a *Octopus insularis*, um animal endêmico nas águas rasas da costa e ilhas oceânicas do norte e nordeste brasileiro. O estudo deste polvo no período larval é de extrema importância para entender seu comportamento e melhorar as condições da vida em cativeiro. Quando este animal está em fase de desenvolvimento embrionário e pós-embrionário as informações sobre o seu comportamento são ainda mais escassas. Para facilitar os estudos nessa área é possível fazer uso de ferramentas computacionais, ou seja, softwares que irão contribuir no monitoramento desses animais. Nesta perspectiva, o objetivo deste trabalho é desenvolver um software que utiliza técnicas de visão computacional para detectar e rastrear a locomoção de paralarvas desta espécie de polvo, e uma Rede Neural Convolucional para identificar seus comportamentos. A ferramenta foi desenvolvida utilizando tecnologias de softwares livres, como: a linguagem de programação Python com auxílio da biblioteca de código aberto OpenCV e Tensorflow. De acordo com os experimentos realizados, esta ferramenta foi capaz de rastrear a localização de vários animais; e reconhecer os diferentes comportamentos com mais de noventa por cento de precisão. Com o resultado deste trabalho é possível analisar de forma mais rápida e precisa o comportamento destes animais na fase larvária e com isso melhorar as condições de vida em cativeiro, facilitando o trabalho antes feito manualmente.

Palavras-chave: *Octopus insularis*. Localização e rastreamento. Visão Computacional. Inteligência Artificial. Redes Neurais Convolucionais.

ABSTRACT

In the field of biology, the recording and study of animal behavior are traditionally done manually, causing researchers discomfort, inaccurate results, and time expenditures. One of the octopus' species that have few data is *Octopus insularis*, an endemic animal in the shallow waters of the north and northeast Brazilian coast and oceanic islands. The study of this octopus in the larval period is extremely important to understand its behavior and improve the conditions of life in captivity. When this animal is in the embryonic and post-embryonic stage of development, information on its behavior is even scarcer. To facilitate studies in this area it is possible to make use of computational tools, that is, software that will contribute to the monitoring of these animals. In this perspective, the objective of this work is to develop software that uses computer vision techniques to detect and track the locomotion of parasites of this octopus species, and a Convolutional Neural Network to identify their behaviors. The tool was developed using free software technologies such as: Python programming language with the aid of OpenCV and Tensorflow open source library. According to the experiments performed, this tool was able to track the location of various animals; and recognize different behaviors with over ninety percent accuracy. With the result of this work, it is possible to analyze more quickly and accurately the behavior of these animals in the larval phase and thereby improve captive living conditions, facilitating the work previously done manually.

Keywords: *Octopus insularis'* paralarvae. Location and tracking. Computer vision. Artificial intelligence. Convolutional Neural Networks.

LISTA DE ILUSTRAÇÕES

Figura 1: Anatomia da paralarva <i>Octopus insularis</i> . (A) Ilustração esquemática de partes e dimensões do corpo. (B) Ilustração esquemática dos cromatóforos.	13
Figura 2: Cromatóforos. (A) Cromatóforos expandidos. (B) Cromatóforos contraídos.	14
Figura 3: Comportamento das paralarvas do polvo <i>O. insularis</i>	15
Figura 4: Operação de convolução.	18
Figura 5: Diagrama de uma Rede Neural Artificial.	20
Figura 6: Arquitetura da MobileNet.	22
Figura 7: Rastreamento dos Zebrafish.	24
Figura 8: Rastreamento dos <i>Caenorhabditis elegans</i>	25
Figura 9: Amostra de imagens do dataset de Wava.	26
Figura 10: Rastreamento dos animais.	28
Figura 11: Marcadores do Deep Lab Cut.	29
Figura 12: Recipiente com cinco paralarvas do <i>O. insularis</i>	30
Figura 13: Pipeline geral da Ferramenta.	31
Figura 14: Histograma, em destaque o valor 80.	32
Figura 15: Pipeline do pré-processamento de imagem.	34
Figura 16: Rastreamento das paralarvas usando o Algoritmo Húngaro.	35
Figura 17: Arquitetura da MobileNet.	36
Figura 18: Tensorflow. (A) Código para ativar a rede. (B) Informações retornadas pela rede.	38
Figura 19: Arquivo .py gerado pela ferramenta ao final do processamento do vídeo.	38
Figura 20: Localização dos animais no recipiente.	41
Figura 21: Velocidade das paralarvas ao longo dos frames.	43
Figura 22: Comportamento ao longo do tempo.	45
Figura 23: Densidade de cor das paralarvas.	46

SUMÁRIO

1 INTRODUÇÃO	9
1.1 MOTIVAÇÃO	10
1.2 OBJETIVOS	11
1.2.1 Objetivos Específicos	11
2 REFERENCIAL TEÓRICO	13
2.1 <i>OCTOPUS INSULARIS</i>	13
2.2 COMPUTAÇÃO GRÁFICA	15
2.2.1 Operações Espaciais	16
2.3 INTELIGÊNCIA ARTIFICIAL	18
2.3.1 REDES NEURAS CONVOLUCIONAIS	20
3 TRABALHOS RELACIONADOS	23
3.1 RASTREIO DE ZEBRAFISH	23
3.2 LOCOMOÇÃO DE CAENORHABDITIS ELEGANS	24
3.3 WAVA	25
3.4 RECONHECIMENTO DE VARIAS ESPECIES ANIMAIS COM RNC	26
3.5 DEEP LAB CUT	28
4 DESENVOLVIMENTO	30
4.1 DETECÇÃO	32
4.2 RASTREIO DAS PARALARVAS	34
4.3 CLASSIFICAÇÃO DE COMPORTAMENTOS	36
5 RESULTADOS	40
5.1 MAPAS DE LOCALIZAÇÃO	40
5.2 PERFIL DE VELOCIDADE	41
5.3 DINÂMICA DE COMPORTAMENTOS	44
5.4 DINÂMICA MORFOLÓGICA DOS CROMATÓFOROS	46
6 CONCLUSÃO	47
6.1 TRABALHOS FUTUROS	47
REFERÊNCIAS BIBLIOGRÁFICAS	49

1 INTRODUÇÃO

Tendo em vista que há uma tendência na aquicultura mundial para a criação de polvos em cativeiros, e também considerando seu elevado preço no mercado, pesquisadores estão concentrando esforços na intenção de construir avanços tecnológicos afim de atender essa demanda (LENZ et al., 2015).

A espécie *Octopus insularis*, são polvos comuns nas águas rasas, recifes e ambientes rochosos do litoral das regiões Norte e Nordeste Brasileira. Sua alimentação é composta basicamente por crustáceos, gastrópodes, bivalves e pequenos peixes. No arquipélago de Fernando de Noronha por exemplo, a pesca desta espécie tem sido uma das principais fontes de renda dos pescadores, além de ser uma alternativa a pesca de lagosta (LEITE; HAIMOVICI; MATHER, 2009).

Na criação desta espécie em cativeiro, seja para consumo, comércio ou até mesmo pesquisa acadêmica, exige-se um certo nível de desenvolvimento tecnológico para espelhar o ambiente natural. Com uma ótima condição de vida, estes animais são capazes de aumentar a produção dos ovos (RÉ; BOSCHI, 1998). Por este motivo, o estudo deste polvo no período larval é de extrema importância para entender seu comportamento e melhorar as condições da vida em cativeiro permitindo o aumento da produtividade.

Esta espécie é extremamente delicada, possuindo poucas ventosas (órgão muscular que auxilia na locomoção e captura de presas) e com baixa habilidade de nado (VILLANUEVA; NORMAN, 2008). Além disso, estes animais possuem uma distribuição de cromatóforos, órgãos neuromusculares responsáveis por camuflar o polvo sempre que necessário. Estes órgãos possuem pigmentos que contém músculos ligados a nervos. Quando o animal está excitado os músculos se contraem, expandindo assim os cromatóforos, já quando estão relaxados a energia armazenada nos músculos retrai os cromatóforos (MESSENGER, 2001).

Nos polvos, os cromatóforos possuem uma morfologia/forma conservadora, ou seja, eles não mudam conforme o crescimento do animal, podendo assim ser um elemento a mais (junto com os olhos) para identificar as paralarvas (VILLANUEVA; NORMAN, 2008).

Atualmente a identificação, assim como, rastreamento dos animais é realizada maiormente de forma manual através de observações visuais, causando desconforto aos pesquisadores, imprecisões nos resultados e tomando muito

tempo na execução destas tarefas.

Além de obter a localização das paralarvas, biologicamente é também interessante a detecção de alguns comportamentos desta espécie. Neste cenário, foi realizado uma pesquisa para identificar a existência de alguma ferramenta computacional no mercado que pudesse viabilizar/melhorar estas questões e constatamos a ausência de uma ferramenta específica capaz de realizar estas tarefas de forma automática; assim como a escassez de dados sobre o desenvolvimento embrionário e pós-embrionário da espécie supracitada.

Nas últimas décadas a inteligência artificial vem se destacando e avançando a passos largos. Uma das linhas de pesquisa nesse campo são as RNAs (Redes Neurais Artificiais). Essas redes são sistemas paralelos complexos compostos por unidades simples (Neurônios Artificiais) conectados entre si que processam modelos matemáticos. A rede é capaz de analisar padrões não explícitos em um conjunto de informações de entrada e ao final devolver uma única resposta (DA SILVA BINOTI; BREDA BINOTI; GARCIA LEITE, 2013). Estes sistemas neurais artificiais podem e são utilizados em reconhecimento de padrões como é o caso dos comportamentos animais.

Nesse contexto, foi desenvolvido uma ferramenta capaz de detectar e rastrear em tempo real o posicionamento destes animais ao longo de gravações em vídeos. Adjunto a isso, uma RNA foi treinada para reconhecer e classificar os diferentes tipos de comportamento da referida espécie. Com esta ferramenta o trabalho de pesquisadores se torna mais fácil; possibilitando fazer um estudo mais rápido, preciso e detalhado sobre este animal no seu período larval.

1.1 MOTIVAÇÃO

O motivo principal deste trabalho é ajudar pesquisadores, sobretudo biólogos que realizam trabalhos manuais com animais da espécie *Ocotpus insularis* no estágio larval. A ausência de uma ferramenta gratuita capaz de obter automaticamente dados, tais como: posicionamento dos animais no recinto, velocidade e tipo de comportamento; desta espécie neste período de vida também foi um grande incentivo. A ferramenta desenvolvida neste trabalho irá agilizar e facilitar o estudo deste animal num período de vida tão escasso de informações, o estágio larval, além de trazer melhorias na sua criação em cativeiro.

Nossa ideia foi desenvolver uma ferramenta utilizando inteiramente apenas tecnologias bem conhecidas e gratuitas no mercado. Tendo isso em mente, utilizamos apenas técnicas de Visão Computacional para reconhecer e rastrear os animais e com o auxílio de Redes Neurais Artificiais (RNA), fomos capazes de reconhecer os diferentes tipos de comportamento apresentados pelo animal. A ferramenta trabalhou com gravações em vídeos dos animais em laboratório.

1.2 OBJETIVOS

O objetivo principal deste trabalho é criar uma ferramenta capaz de reconhecer e rastrear a espécie *Octopus insularis* em seu estágio larval, e com o auxílio de Redes Neurais Artificiais (RNA), possa reconhecer os diferentes tipos de comportamento apresentados pelo animal. Em seguida, gerar gráficos com os dados extraídos pela ferramenta, tais quais: posicionamento, velocidade, tipo de comportamento e densidade média de cor.

1.2.1 Objetivos Específicos

Configuramos todo o ambiente de trabalho com a linguagem de programação Python (ROSSUM, 2002), a biblioteca de código aberto OpenCV (BRADSKI; KAEHLER, 2008a) e suas dependências, tal qual configuramos o ambiente com uma Rede neural artificial e suas dependências. Em seguida, desenvolvemos um pipeline de processamento de imagens utilizando apenas técnicas de visão computacional capazes de reconhecer e rastrear o posicionamento dos animais em gravações em vídeos. Junto a isso, treinamos uma RNA para reconhecer os diferentes tipos de comportamentos da espécie *Octopus insularis* no seu estágio larval; e atrelamos esta RNA junto as técnicas de processamento de imagens para obter dados biológicos do animal. Ao final deste processo supracitado, executamos testes para verificar o funcionamento da ferramenta, validamos o sistema e documentamos os testes. Por fim, desenvolvemos alguns códigos para visualizar graficamente os dados biológicos gerados pela ferramenta, tais quais: localização dos animais ao longo do vídeo, velocidade individual e populacional das paralarvas, comportamento

individual e populacional ao longo do tempo, e densidade média de cor presente nos animais ao longo do vídeo.

2 REFERENCIAL TEÓRICO

Este capítulo é destinado a transmitir alguns conhecimentos fundamentais que facilitarão o leitor no entendimento deste trabalho e a problemática abordada.

2.1 *OCTOPUS INSULARIS*

A espécie *Octopus insularis* é um animal endêmico nas águas rasas da costa e ilhas oceânicas do norte e nordeste brasileiro. Devido a sua semelhança com a espécie *Ocotpus vulgaris*, apenas recentemente temos estudos direcionados exclusivamente ao *O. insularis* e maiormente na sua fase adulta (LENZ et al., 2015). Sua alimentação é composta basicamente por crustáceos, gastrópodes, bivalves e pequenos peixes (LEITE; HAIMOVICI; MATHER, 2009). A pesca desta espécie tem sido uma das principais fontes de renda dos pescadores do arquipélago de Fernando de Noronha, além de ser uma alternativa a pesca de lagosta.

Na criação desta espécie em cativeiro, seja para consumo, comércio ou até mesmo pesquisa acadêmica, exige-se um certo nível de desenvolvimento tecnológico para espelhar o ambiente natural. Com uma ótima condição de vida, estes animais são capazes de aumentar a produção dos ovos (RÉ; BOSCHI, 1998). A Figura 1 retrata a anatomia deste animal na fase larval.

Figura 1: Anatomia da paralarva *Octopus insularis*. (A) Ilustração esquemática de partes e dimensões do corpo. (B) Ilustração esquemática dos cromatóforos.

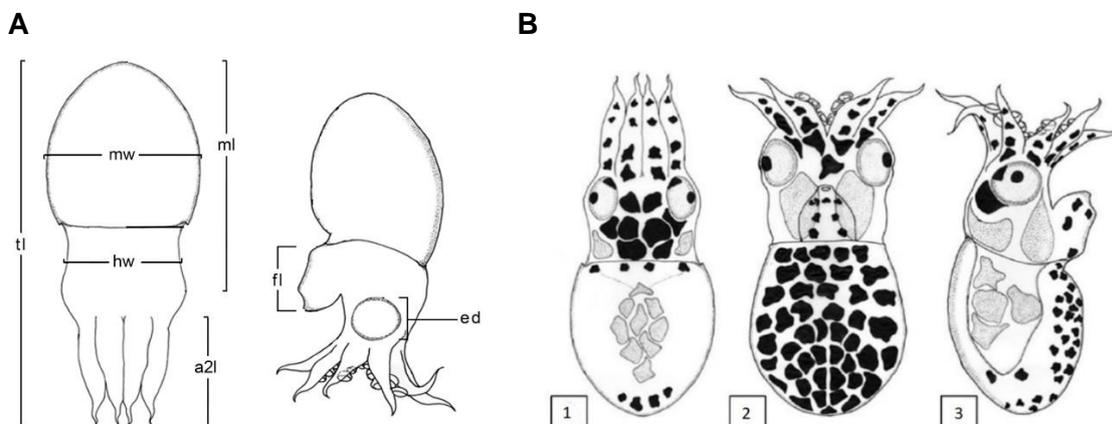


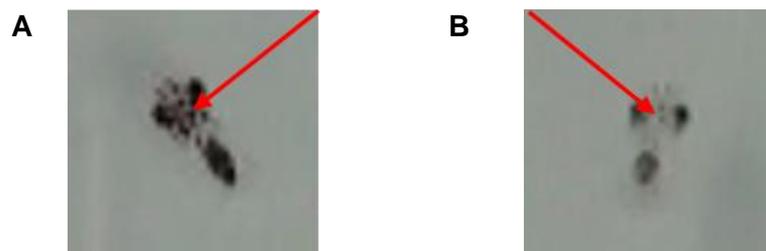
Ilustração esquemática mostrando as dimensões corporais medidas nas paralarvas do *Octopus insularis*. Abreviações: **a2l**, comprimento do segundo par de braços; **ed**, diâmetro ocular; **fl**, comprimento do funil; **hw**, largura da cabeça; **ml**, comprimento do manto; **mw**, largura do manto; **tl**, comprimento total.

Octopus insularis. Ilustração esquemática do padrão cromatóforos das paralarvas recém-eclodidas. 1, vista dorsal; 2, vista ventral; 3, disposição lateral.

Fonte: adaptada de (LENZ et al., 2015).

Estes animais são bastante delicados, possuindo poucas ventosas (órgão muscular que auxilia na locomoção e captura de presas) e baixa aptidão para o nado (VILLANUEVA; NORMAN, 2008). Também possuem ao longo do corpo uma distribuição de cromatóforos, que são órgãos neuromusculares. Estes órgãos são responsáveis, entre outras coisas, pela camuflagem do animal para sua proteção ou na caça de suas presas. Os cromatóforos possuem pigmentos no seu interior que agem sobre o comando do sistema nervoso absorvendo seletivamente partes do espectro visível da luz (SUGIMOTO, 2002). A cor que é exibida ou refletida nos cromatóforos é uma mistura de difração, reflexão e dispersão da luz que incide nestes pigmentos. Além disso, estes pigmentos possuem músculos ligados a nervos, sempre que o animal está excitado os músculos se contraem e expandem os cromatóforos (Figura 2A, Seta Vermelha) e enquanto estão relaxados, a energia que foi armazenada nos músculos retrai os cromatóforos (Figura 2B, Seta Vermelha) (MESSENGER, 2001). Estes animais possuem uma morfologia imutável de cromatóforos ao longo do corpo, ou seja, eles não mudam conforme o envelhecimento, podendo assim, juntamente com os olhos, serem usados para identificar as paralarvas (VILLANUEVA; NORMAN, 2008).

Figura 2: Cromatóforos. (A) Cromatóforos expandidos. (B) Cromatóforos contraídos.



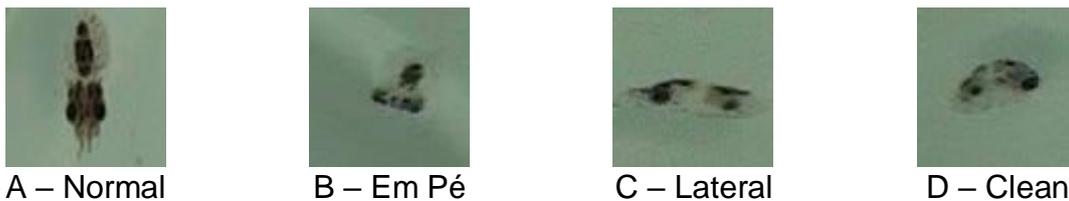
Fonte: Autor.

Através de análises visuais, constatamos quatro principais tipos de comportamentos deste animal, são eles: nado Normal, nado em Pé, nado Lateral e *Clean*. Três desses comportamentos (Nado Normal, em Pé e Lateral) já foram descritos em trabalhos anteriores (ORTIZ; RÉ; MÁRQUEZ, 2006), *Clean* é totalmente novo neste estágio da vida do *O. insularis*.

O nado Normal é o padrão do animal, ele fica alinhado de forma paralela ao chão com os olhos (Figura 1A, *ed*) virados para cima (Figura 3 - A), sendo esta a

posição em que a paralarva passa a maior parte do tempo. Já no nado em Pé (Figura 3 - B), o animal direciona seus braços para o chão e o saco/manto (Figura 1A, *ml*) para cima, simulando uma caminhada. O Nado Lateral (Figura 3 - C), é similar ao Nado Normal, porém girando seu corpo noventa graus horizontalmente em torno do próprio eixo; nesta posição, apenas um olho é visível sobre a perspectiva superior. Esses nados supracitados também podem ser vistos em paralarvas de outras espécies de polvos. No nado Clean (Figura 3 - D), a paralarva se contrai inteira em forma de curvatura, enquanto seus braços esfregam-se entre eles e sobre a superfície do corpo, ficando juntos com seu saco/manto. Em todos esses comportamentos a paralarva pode ficar parada ou se movimentar pelo recipiente.

Figura 3: Comportamento das paralarvas do polvo *O. insularis*.



A – Normal

B – Em Pé

C – Lateral

D – Clean

Fonte: Autor.

O estudo deste polvo no período larval é de extrema importância para entender seu comportamento e melhorar as condições da vida em cativeiro. Além disso, informações como morfologia, comportamento, hábitos alimentares; neste período inicial da vida são cruciais para distinguir e identificar a espécie (LENZ et al., 2015).

2.2 COMPUTAÇÃO GRÁFICA

A Computação Gráfica (CG) é uma área da Ciência da Computação que estuda e desenvolve técnicas para geração, manipulação e análise de imagens (MANSSOUR; COHEN, 2006). Esta área está em constante mudanças, principalmente ao longo dos últimos anos devido ao crescimento exponencial da qualidade e do número de hardwares capazes de gerar imagens, tais quais: câmeras fotográficas, filmadoras, smartphones, entre outros. Atualmente a CG é

dividida em três grandes subáreas: Síntese de Imagens, Visão Computacional e Processamento Digital de Imagens.

A Síntese de Imagens é a subárea dedicada a criação, manipulação e representação de imagens através de modelos matemáticos. Fazendo uso de técnicas de computação gráfica e modelos matemáticos, é possível criar modelos industriais, imagens de ambientes; com diversas palhetas de cores e simular efeitos de sombras e luzes em diferentes pontos. Essa área é muito utilizada em criação de filmes de animação e simulação de ambientes populacionais, como por exemplo: condomínios, áreas públicas como praças, ginásios, áreas privadas (MANSSOUR; COHEN, 2006).

A Visão Computacional estuda e desenvolve algoritmos para analisar e obter características específicas das imagens. Com essas técnicas é possível extrair das imagens informações importantes como número de objetos, dimensões, textura, geometria, propriedade de luz, entre outros. Identificar doenças em raios-x, placas de carros e motos são exemplos do uso das técnicas desta subárea (MANSSOUR; COHEN, 2006).

O Processamento Digital de Imagens (PDI) é o estudo e desenvolvimento de técnicas para criar e manipular imagens. Com PDI é possível modificar características da imagem, tais quais: brilho, contraste, ajuste de cor; ou ainda aplicar operações de filtros para acentuar certas características da imagem. Uma utilização bem comum da aplicação desses filtros são os aplicativos de celulares para manipular imagens, como por exemplo o Instagram (INSTAGRAM. Disponível em: <<https://www.instagram.com/>>. Acesso em 10 abr. 19) e o Snapchat (SNAPCHAT. Disponível em: <<https://www.snapchat.com//pt-br/>>. Acesso em 10 abr. 19). Estes aplicativos, tal qual o Octopus Tracker, fazem usos de Operações espaciais para modificar a imagem.

2.2.1 Operações Espaciais

Toda imagem digital é formada por uma matriz finita de pixels bidimensional, f (x, y) onde x e y são coordenadas espaciais (plano) e a amplitude do par de coordenadas é denominado intensidade ou nível de brilho ou cinza da imagem (GONZALEZ; WOODS, 2009). Cada par ordenado de x e y na imagem é chamado

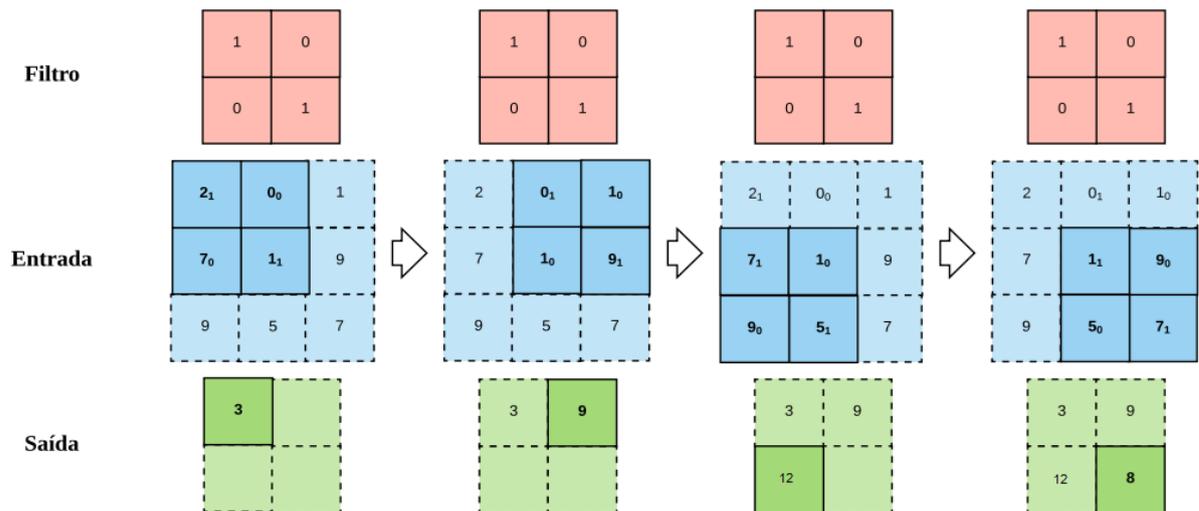
elemento de imagem ou pixel (MANSSOUR; COHEN, 2006) e existem vários sistemas de cores que representam a quantidade de luz que incide nele, como por exemplo: RGB (*Red, Green e Blue* – Vermelho, Verde e Azul) onde cada pixel possui três valores ou canais que variam de 0 (preto) a 255 (cor máxima do canal); o caso específico de imagens representadas em escala de cinza, cada pixel possui um único valor que varia de 0 (preto) a 255 (branco).

Existem procedimentos aplicados sobre cada pixel para modificar seu valor ou os valores dos pixels adjacentes a fim de modificar a imagem digital, esses procedimentos são chamados Operações espaciais. Estas operações são divididas em duas categorias: pontuais ou ponto-a-ponto e locais ou localizadas (MANSSOUR; COHEN, 2006).

Nas operações ponto-a-ponto, o valor de cada pixel da imagem de saída (imagem processada) depende apenas do valor do mesmo pixel da imagem de entrada, pois nesta categoria as operações trabalham individualmente cada valor do pixel. Um exemplo desta operação e que foi utilizada neste trabalho temos a Binarização, esta operação tem como saída uma imagem com apenas duas cores. Nesta técnica cada pixel da imagem é analisado individualmente e tem seu valor modificado para preto (valor 0) ou branco (valor 255).

Já nas operações locais, um pixel específico da imagem processada possui seu valor alterado conforme o valor próprio e os valores dos pixels que estão na sua vizinhança, esta operação é chamada de convolução. Como exemplo desta operação temos o filtro de suavização ou filtros passa-baixa, estes filtros realçam detalhes da imagem e minimizam os efeitos de ruídos. Nestas técnicas é idealizado uma janela ou uma matriz de pixels chamada de máscara ou filtro, essa máscara desliza sobre a imagem original modificando os valores dos pixels conforme o próprio valor e os valores da vizinhança abrangido pelo tamanho da máscara. A Figura 4 demonstra um exemplo dessa janela deslizante. O quadrado vermelho representa a máscara ou filtro e irá deslizar por toda a imagem (quadrados azuis) aplicando operações matemáticas e ao final, tendo como saída, uma nova imagem modificada (quadrados verdes).

Figura 4: Operação de convolução.



Fonte: Adaptada de (MORAES, 2018)

Para o desenvolvimento do Octopus Tracker foram utilizadas técnicas de PDI e Visão Computacional. Com PDI, alteramos a coloração dos pixels e fizemos uso de filtros para melhorar o rastreamento dos animais. Com Visão Computacional, identificamos os contornos consequentemente os clusters, isto é, o conjunto de pontos na imagem que representam o animal.

2.3 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma grande área da Ciência da Computação, ela abrange inúmeros subcampos como a aprendizagem de máquinas e softwares em geral, ou propósitos específicos como diagnósticos de doenças, demonstração de teoremas matemáticos, reconhecimento de padrões, entre outros. A IA pode ser definida como o esforço de fazer os computadores pensarem como mentes (HAUGELAND, 1985).

Uma das subáreas da IA muito utilizada e de grande prestígio são as Redes Neurais Artificiais (RNA ou do inglês *Artificial Neural Network* - ANN) (DE PÁDUA BRAGA; DE LEON FERREIRA; LUDERMIR, 2007). Essas redes são baseadas no sistema nervoso de animais, particularmente no sistema presentes no cérebro, e são capazes de aprender e reconhecer padrões.

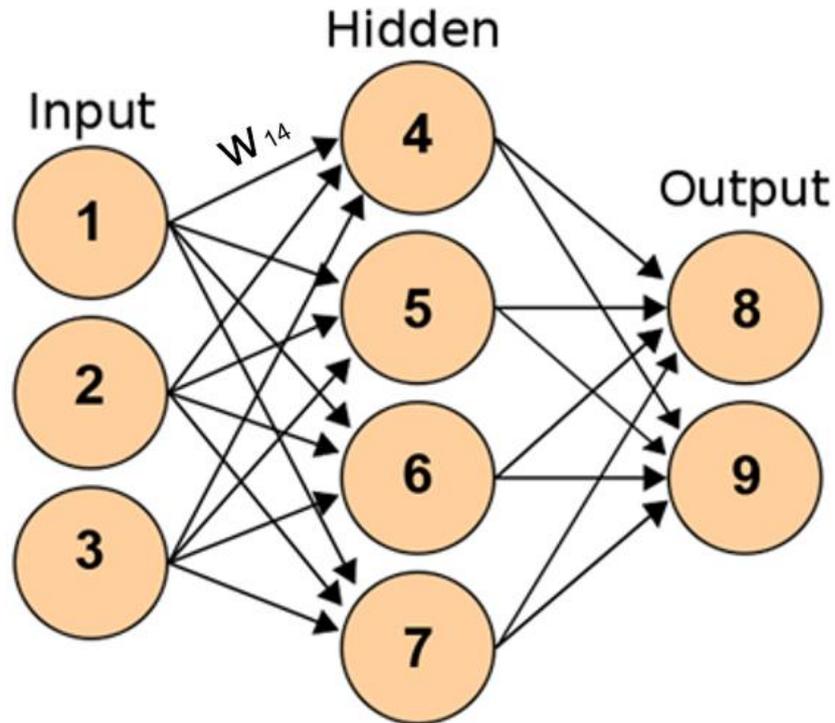
As RNAs são sistemas complexos compostos por unidades simples denominadas Neurônios Artificiais (ou do inglês *Perceptrons*) conectados entre si,

eles emulam através de modelos matemáticos e de forma simplificada os neurônios biológicos (DA SILVA BINOTI; BREDÁ BINOTI; GARCIA LEITE, 2013). Cada neurônio possui uma conexão com um ou mais neurônios, essa conexão é chamada ligação sináptica ou peso sináptico, quanto mais sinais um neurônio envia para o outro maior será a força da conexão (Figura 5, w_{14}). As redes são capazes de analisar padrões não explícitos em um conjunto de informações de entrada e processar através de pesos sinápticos estes dados recebidos, fornecendo ao final uma única resposta (DA SILVA BINOTI; BREDÁ BINOTI; GARCIA LEITE, 2013). A distribuição dos neurônios em conjuntos específicos é chamada de camadas, esta organização de camadas e o padrão de pesos sinápticos é denominado Arquitetura da Rede (KOVÁCS, 2002).

Existem diferentes tipos de Arquiteturas de Redes e uma das mais famosas é o *Feed-Foward* onde o fluxo da informação é linear, partindo sempre no sentido da camada de entrada para a camada de saída. Nestas arquiteturas, os neurônios situados em uma camada só se comunicam com os neurônios na mesma camada e os situados nas camadas a sua frente, ou seja, não possuem retroalimentação (BIANCHINI, 2001).

Outro modelo de arquitetura muito famoso são as Redes Multicamadas ou MLP (*Multilayer Perceptrons* - Perceptrons Multicamadas). De forma sucinta, os neurônios presentes nesta rede estão divididos em três camadas conectadas entre si (Figura 5), cada camada possui sua própria distribuição de neurônios. Os neurônios de uma mesma camada se comportam geralmente da mesma forma e possuem seus próprios pesos sinápticos. A primeira camada é denominada Camada de Entrada e é responsável pela entrada de dados. A segunda camada recebe as informações processadas pela camada de entrada e é denominada camada escondida, é possível ter várias camadas escondidas. Por fim, existe a camada de saída, esta camada é a última da rede (DE PÁDUA BRAGA; DE LEON FERREIRA; LUDERMIR, 2007).

Figura 5: Diagrama de uma Rede Neural Artificial.



Fonte: Adaptada de (CHOUDHURY; TALUKDAR; SARMA, 2015).

Com o passar dos anos surgiram problemas mais complexos e as abordagens clássicas de RNAs não conseguiram mais solucioná-los. Foi preciso desenvolver novas arquiteturas de redes mesclando as antigas entre si ou com outras técnicas, tais quais as técnicas presentes no campo da visão computacional. Uma nova arquitetura de rede que surgiu nessa nova onda de pesquisa foram as Redes Neurais Convolucionais que serão abordadas a seguir.

2.3.1 Redes Neurais Convolucionais

A partir de pesquisas com as RNA foram desenvolvidas as Redes Neurais Convolucionais (RNC) (do inglês *Convolutional Neural Network* – CNN) e sua evolução se deu principalmente na comunidade de visão computacional, maiormente na área de detecção de objetos em imagens (GOLDBERG, 2016). As RNAs e as RNCs trabalham de forma semelhante e com arquitetura similar, contendo neurônios, pesos sinápticos; camadas de entrada, escondidas e de saída.

Os dados processados pelas redes podem ser dispostos de diferentes formas, seja em dois eixos (largura e altura) como imagens, séries temporais como

sinais de áudios e cadeias de DNA, entre outros (MORAES, 2018). Esse conjunto de dados de entrada é chamado de mapa de atributos de entrada.

Estas Redes Neurais possuem esse nome pois aplicam, em pelo menos uma das suas camadas, a operação de convolução (MAZZA, 2017). Para implementar a convolução são utilizados filtros não lineares, ou uma janela deslizante, que percorrem o mapa de atributos e em cada conjunto de dados onde a janela está sobreposta, é realizado uma operação de transformação linear. Essa operação soma todos os produtos da multiplicação ponto-a-ponto entre os valores dos filtros e o subconjunto de valores do mapa de atributos (MORAES, 2018). O resultado é definido em apenas uma única unidade de saída, produzindo os mapas de características (*Feature maps*) que serão utilizados posteriormente nas próximas operações.

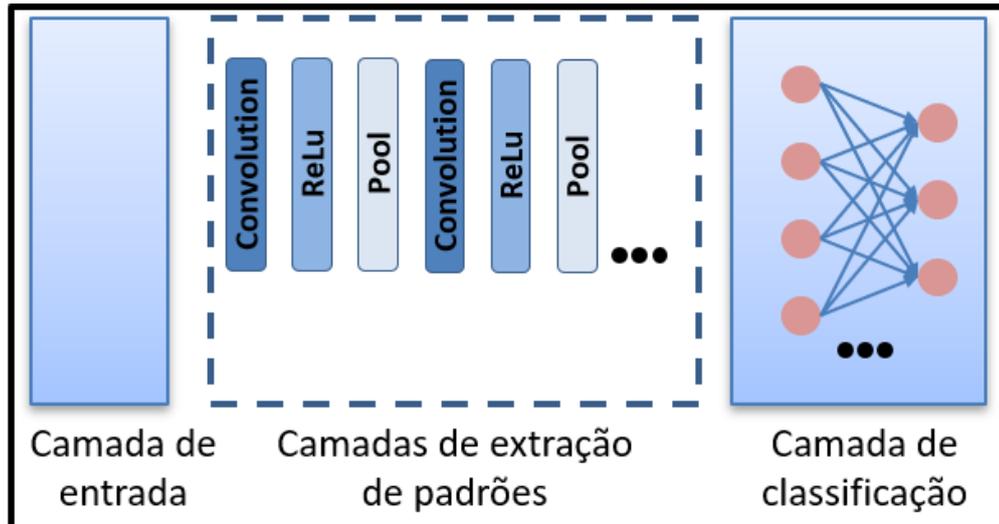
As RNCs também são conhecidas como redes neurais artificiais invariantes a deslocamento ou ao espaço, isso ocorre pois mesmo que o objeto analisado na imagem analisada esteja em diferentes rotações, cores ou com partes deslocadas, a rede é capaz de analisar e reconhecer este objeto com um grande percentual de acerto (MORAES, 2018). Elas foram inspiradas na organização do córtex visual de animais (MATSUGU et al., 2003) e são utilizadas, entre outras coisas, na área de processamento de linguagem natural abordando temas como, a rotulagem de regras semânticas (COLLOBERT et al., 2011) e análise de sentimentos (KALCHBRENNER; GREFFENSTETTE; BLUNSOM, 2014), porém o seu maior protagonismo vem sendo há algum tempo na área de classificação de imagens. Este tipo de rede é usada atrelada a visão computacional, para classificação, detecção e reconhecimento de padrões encontrados em imagens e vídeos, embora seu uso demande um pré-processamento maior se comparado a uma RNA ou mesmo algoritmos de visão computacional (HAN; MAO; DALLY, 2015).

Pelo exposto, podemos dizer que estes sistemas neurais artificiais podem e são utilizados em reconhecimento de padrões, como é o caso deste trabalho, para o reconhecimento dos diferentes tipos de comportamentos das paralarvas do *O. insularis*.

Para o Octopus Tracker utilizamos a Rede Neural Convolutacional MobileNet (HOWARD et al., 2017). Na arquitetura desta rede (Figura 6), além das camadas responsáveis pela operação de convolução, esta RNC também utiliza as operações de *Pooling* e *Relu*. Nas camadas de operações de *Pooling* também é usada uma

janela deslizante que percorre toda a imagem aplicando métodos de subamostragem e ao final gerando uma nova imagem com dimensões menores que será propagada para o resto da rede. A operação *ReLU* é uma função não linear que age nas camadas de entrada e extrai características básicas da imagem (MORAES, 2018).

Figura 6: Arquitetura da MobileNet



Fonte: Adaptada de (HOWARD et al., 2017)

3 TRABALHOS RELACIONADOS

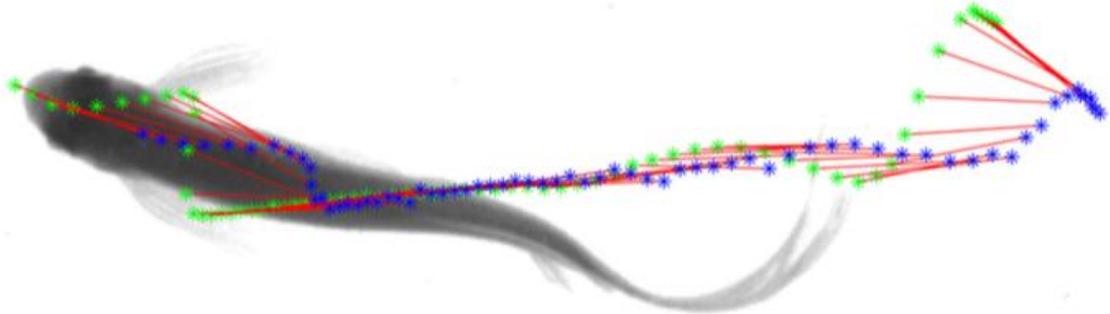
As observações e os estudos de animais em ambiente natural no seu dia-a-dia nos resultam nos conhecimentos para determinar os diferentes tipos de comportamentos apresentados por ele. Estes comportamentos variam conforme as condições do ambiente, o humor ou a presença humana, este último podendo inibir o comportamento natural (KODAMA SALTORATTO et al., 2013)(KODAMA SALTORATTO et al., 2013). Com as tecnologias atuais, é possível captar os diferentes comportamentos dos animais de forma mais precisa e menos invasivo, tornando o comportamento animal mais próximo possível do ambiente natural. Neste capítulo serão abordados trabalhos que apresentam características e finalidades similares ao Octopus Tracker, tais quais: técnicas para reconhecer, diferenciar e rastrear objetos em imagens.

3.1 RASTREIO DE ZEBRAFISH

O primeiro trabalho analisado é o artigo intitulado “*Automated Planar Tracking the Waving Bodies of Multiple Zebrafish Swimming in Shallow Water*” (WANG et al., 2016) e implementa um algoritmo capaz de rastrear a localização dos peixes da espécie *Danio rerio*, popularmente conhecido como Zebrafish ou Peixe-Zebra. Esta espécie de peixe é amplamente estudada e analisada na comunidade científica devido ao seu pequeno tamanho, versatilidade e possuir uma população numerosa. Estes peixes são usados em diversos experimentos como por exemplo biológicos, triagens de genes, análise de neurotoxicologia, desenvolvimento de inteligência entre outros (BAI et al., 2018).

O artigo trabalha com vídeos gravados do comportamento do peixe em laboratório, para realizar o rastreio dos animais (Figura 7) foi utilizado a técnica binarização. Com um valor previamente calculado na (limiar), os pesquisadores aplicaram a binarização nos *frames* do vídeo, tornando cada pixel da imagem branco (valor 255) ou preto (valor 0). Desta forma, eles conseguiram destacar o peixe nos *frames* do vídeo, facilitando posteriormente o rastreio dos animais ao longo do vídeo.

Figura 7: Rastreo dos Zebrafish.



Fonte: Adaptada de (WANG et al., 2016).

Para rastrear o deslocamento dos peixes ao longo do vídeo foi utilizado o algoritmo Húngaro (CUI et al., 2016), esta técnica recebe como parâmetro de entrada as coordenadas x e y de cada animal em *frames* subsequentes, em seguida é calculada de forma otimizada a distância euclidiana mínima entre todos as coordenadas para encontrar a melhor trajetória de cada animal.

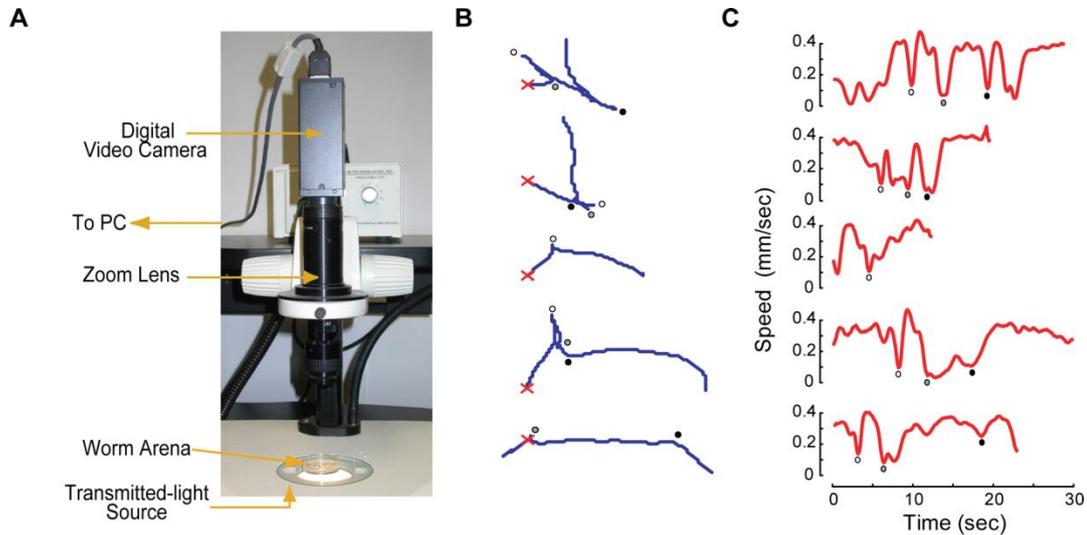
O algoritmo apresentado no artigo não funciona em tempo real e faz uso de softwares pagos, como é o caso do Matlab (MATLAB Disponível em: <<http://twixar.me/YCP1>>. Acesso em 09 ago. 19). Para o Octopus Tracker usamos apenas tecnologias de softwares livres e incorporamos a utilização das técnicas de Limiarização, binarização para melhorar o reconhecimento dos animais e o algoritmo Húngaro para calcular o deslocamento das paralarvas do *O. insularis*.

3.2 LOCOMOÇÃO DE CAENORHABDITIS ELEGANS

Caenorhabditis elegans é uma espécie de nematódeo bastante estudada no campo da genética comportamental e aspectos da neurobiologia. Sua análise é muito versátil pois possui um tempo de vida curto, seu genoma já foi sequenciado por completo e tem o sistema nervoso compacto composto por apenas 302 neurônios, além de requisitar métodos simples e baratos para o cultivo em laboratório. A comunidade que pesquisa este animal se baseia na sua locomoção para tirar métricas e diferenciar o comportamento entre animais selvagens, mutantes e sobre condições diferentes no ambiente (RAMOT et al., 2008). O artigo “The Parallel Worm Tracker: A Platform for Measuring Average Speed and Drug-Induced

Paralysis in Nematodes” (RAMOT et al., 2008) trabalha com o rastreamento desses animais em gravações de vídeos (Figura 8).

Figura 8: Rastreio dos *Caenorhabditis elegans*.



Fonte: Adaptada de (RAMOT et al., 2008).

Para melhorar o reconhecimento dos animais ao longo do vídeo, os pesquisadores do artigo fizeram uso da limiarização e da binarização. Com estas técnicas foi calculado e estabelecido um valor entre 0 (preto) e 255 (branco) chamado de limiar.

A desvantagem deste trabalho é a necessidade de um software pago, o Matlab (MATLAB Disponível em: <<http://twixar.me/YCP1>>. Acesso em 09 ago. 19). Neste artigo são utilizadas técnicas bastante conhecidas que também foram utilizadas no Octopus Tracker, tais quais: limiarização e o algoritmo de binarização, ambas para melhorar na detecção das paralarvas de polvo.

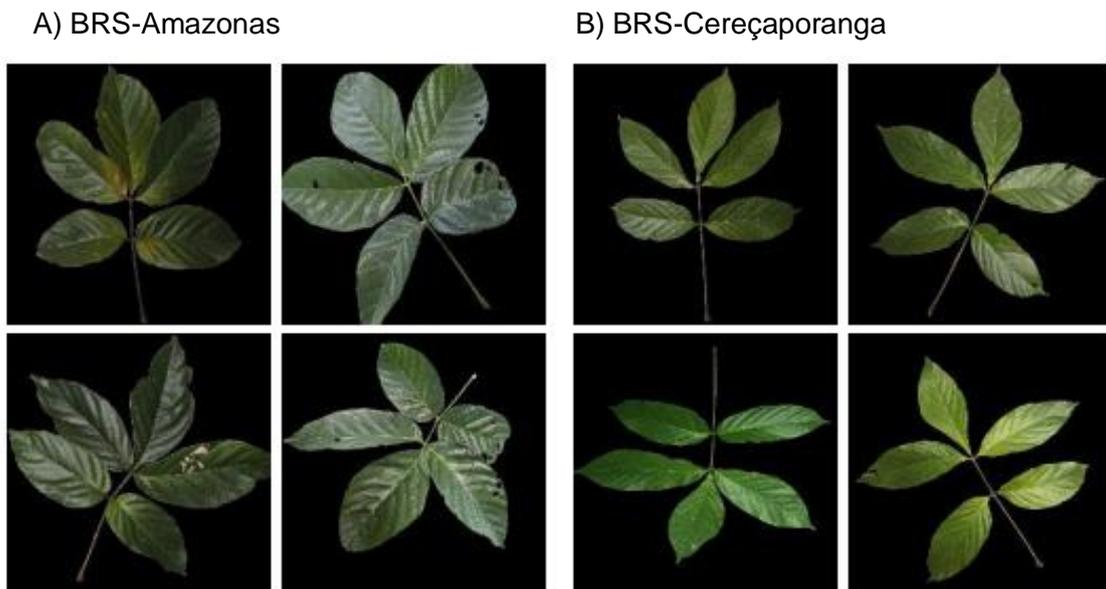
3.3 WAVA

WAVA é a sigla para *Warana's Automated Visual Analysis*, uma ferramenta que utiliza Redes Neurais Convolucionais para auxiliar pesquisadores e agricultores que trabalham no plantio de guaraná na Amazônia (SOUSA et al., 2017). Devido ao grande número de fungos e doenças que afetam estas plantas, foi necessária uma evolução genética buscando maior resistência a estes empecilhos. Todavia, esta evolução está causando problemas na hora de distinguir essa variedade genética,

esta diferenciação é maiormente realizada pelos agricultores e são passíveis de falha humana (SOUSA et al., 2017).

Os pesquisadores elaboraram um banco de dados com 60 imagens coloridas (escala RGB) das folhas das plantas BRS-Amazonas e BRS-Cereçaporanga (Figura 9), 30 para cada planta. Devido ao número pequeno de imagens, foi utilizado a técnica de *data augmentation*, isto é, foi elaborado mais imagens baseadas nas primeiras com a rotação diferente, espelhamento vertical e horizontal, pequena variação de cores, entre outros. Com este banco de dados eles treinaram duas redes neurais, capazes de reconhecer e distinguir as folhas destas plantas. Ao final do estudo eles comparam o desempenho das duas redes.

Figura 9: Amostra de imagens do dataset de Wava.



Fonte: Adaptada de Souza et al., 2017.

Similar ao Wava, no Octopus Tracker também foi selecionado imagens (escala RGB) dos objetos de estudos (paralarvas do *O. insularis*) e elaborado um banco de dados para treinamento de uma RNA, todavia, fizemos uso de apenas uma RNA. Também não utilizamos a técnica de *data augmentation*.

3.4 RECONHECIMENTO DE VARIAS ESPECIES ANIMAIS COM RNC

No trabalho intitulado “Deep convolutional neural network based species recognition for wild animal monitoring” (CHEN et al., 2014) é apresentado um código baseado apenas em técnicas de visão computacional e código baseado numa

arquitetura de uma RNC ambos capazes de reconhecer e classificar animais selvagens de várias espécies através de imagens de armadilhas fotográficas. Foram espalhados sensores de movimento juntamente com armadilhas fotográficas em um ambiente natural frequentado por animais de várias espécies, cada vez que o sensor de presença fosse acionado estas armadilhas coletavam um conjunto de imagens subsequentes que varia de seis a cinquenta imagens (CHEN et al., 2014). Ao total, foram coletadas pouco menos de vinte e quatro mil imagens de vinte espécies diferentes na América do Norte (Figura 10). O conjunto de imagens foram divididas entre duas categorias: treinamento (14346 imagens) e teste (9530 imagens) e são amostradas nos mais diferentes cenários, isso inclui imagens coloridas, na escala de cinza, imagens de infravermelho, entre outros; e em todas as imagens capturadas existe apenas uma espécie presente.

No classificador baseado em técnicas de visão computacional é utilizado o algoritmo Bag of visual Words (BOW) que é uma técnica que contabiliza as principais características de uma imagem para classificar-la. Além disso, para ajudar nesse processo de classificação, foram utilizados o algoritmo de Áreas de Interesse (do inglês, *ROI – Region of Interest*) para delimitar apenas uma região da imagem, Histograma para ter um conhecimento melhor da imagem e o algoritmo de agrupamento K-means, para agrupar os objetos iguais presentes na imagem.

Semelhante a este artigo, no Octopus Tracker também são utilizadas técnicas de visão computacional, tais quais: o algoritmo de *ROI* e *K-means*; para melhorar o reconhecimento e rastreamento dos animais.

Figura 10: Rastreamento dos animais.



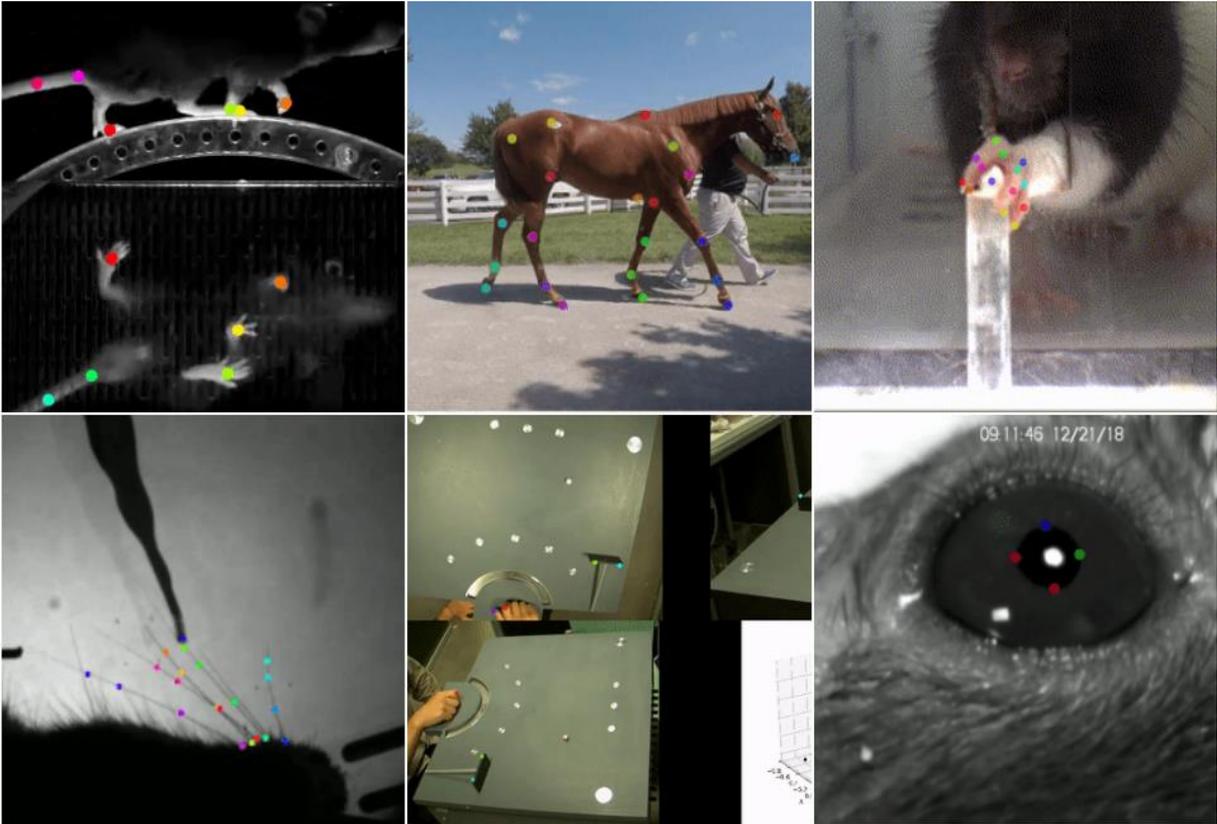
Fonte: adaptada de (CHEN et al., 2014).

3.5 DEEP LAB CUT

Deep Lab Cut (DLC) são ferramentas de código livre na linguagem de programação Python (ROSSUM, 2002) para estudar o comportamento de animais através de uma RNA profunda treinada. Foi desenvolvida pela equipe de pesquisa no Instituto Rowland da Universidade de Harvard, liderada pela PhD Mackenzie Mathis.

O DLC faz uso no seu código da ResNet (Residual Networks), que é uma RNA geralmente usada como *backend* de várias aplicações que trabalham com dados relativos à Visão Computacional. A principal característica dessa RNA é a capacidade de treinar e posteriormente utilizar uma rede neural com mais de 150 camadas.

Figura 11: Marcadores do Deep Lab Cut.



Fonte: Nath et Al. 2018.

A ferramenta surgiu da necessidade de estudos menos invasivos em animais. Através da análise de vídeos o usuário pode fazer uso de marcadores (Figura 11, Pontos coloridos) especiais para detectar partes do corpo dos animais em ambientes visualmente dinâmicos, com componentes difíceis de se trabalhar como mudança de luz, movimento repentino de objetos, entre outros (NATH et al., 2018).

Apesar de possuir pouca semelhança entre o DLC com o trabalho apresentado neste documento, achamos válido mencionar esse software pois mostra que a tecnologia avançou a tal ponto que hoje somos capazes de rastrear pontos específicos nos animais, isso irá gerar grande avanço na ciência e sobretudo, no campo da biologia.

4 DESENVOLVIMENTO

Para analisar o comportamento das paralarvas do *Octopus insularis*, tivemos acesso a um vídeo com aproximadamente 22 minutos de duração, este vídeo possui frames de resolução 1440x1080 (largura x altura) e são gravações do comportamento das paralarvas que medem de 2 a 3 milímetros de comprimento. Os animais estão em um recipiente cilíndrico de 8 centímetros de diâmetro e 5 milímetros de profundidade (Figura 12).

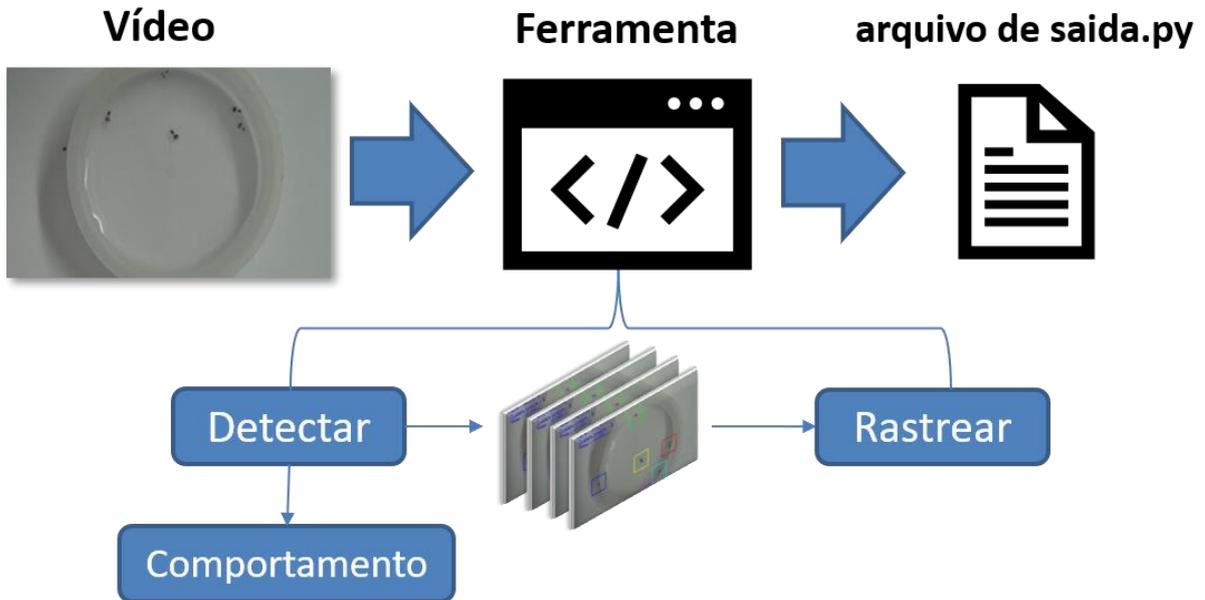
Figura 12: Recipiente com cinco paralarvas do *O. insularis*.



Fonte: Autor.

Para o desenvolvimento da ferramenta utilizamos a Linguagem de Programação Python (ROSSUM, 2002) na versão 3.6.5 e a biblioteca Open Source OpenCV (BRADSKI; KAEHLER, 2008a) na versão 3.4.1 e a Tensorflow (GIRIJA, 2016) na versão 1.8. O desenvolvimento, validação e testes da ferramenta foram executados principalmente em um computador com configuração de hardware com processador Intel i7-8700, com 16GB de RAM e uma placa gráfica GTX1070 8GB Nvidia GeForce.

Figura 13: Pipeline geral da Ferramenta.



Fonte: Autor.

Como demonstra a Figura 13, a ferramenta possui um fluxo de processamento, onde inicialmente o vídeo é carregado e processado em quadros (*frames*). Cada quadro passa por três fases específicas: detecção, rastreamento das paralarvas e classificação de seus comportamentos.

Fase 1 - Detecção: Em cada *frame* do vídeo, aplicamos um pipeline utilizando apenas técnicas bem conhecidas de visão computacional para melhorar o reconhecimento e o rastreamento de cada animal presente num *frame*. No final deste processo é obtido uma lista de coordenadas $\{(x_1, y_1), \dots, (x_n, y_n)\}$ e das Áreas de interesse (do inglês, Region of Interest – ROIs) correspondentes de cada animal dentro do frame.

Fase 2 - Rastreamento das paralarvas: Uma vez detectadas os animais, a ferramenta é capaz realizar o rastreamento. Para este processo, utilizamos um algoritmo que calcula a distância euclidiana entre a posição (x,y) de cada animal em *frames* consecutivos, sendo que a mínima distancia encontrada sugeriria que estamos com o mesmo animal. Com isso, é possível rastrear os animais ao longo do vídeo.

Fase 3 - Classificação de comportamentos: Com as ROIs obtidas na fase 1, e utilizando uma CNN construída e treinada, podemos extrair os diferentes tipos de comportamentos apresentados pela paralarva em cada *frame* do vídeo.

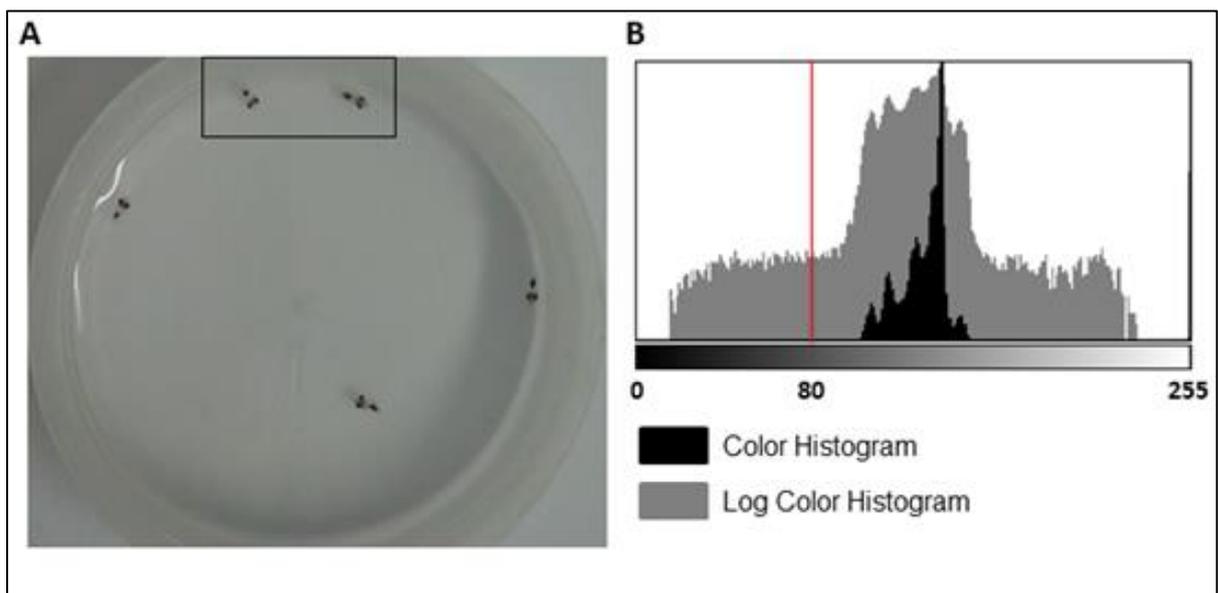
Ao final destas três etapas as informações obtidas pela ferramenta são armazenadas num arquivo de saída do tipo Python, que posteriormente será utilizado para analisar e visualizar esses dados graficamente (ver sessão de Resultados). Cada fase será melhor detalhada nas próximas sessões.

4.1 DETECÇÃO

O vídeo originalmente está colorido na escala RGB (do inglês: *Red*, *Green* e *Blue*. Vermelho, Verde e Azul) (Figura 14 - A). Tendo em vista que a coloração original não seria relevante, convertemos o *frame* para escala de cinza para trabalhar apenas com um canal de cor (Figura 15 - Cinza).

Visualmente percebemos que as paralarvas possuem coloração maiormente obscura, variando entre o valor preto (zero) e um valor cinza (menor que cento e vinte oito). Para ter noção da coloração da imagem, sobretudo dos animais, nós verificamos o histograma do *frame* por completo (Figura 14 - B) e percebemos que o valor = 80 seria ideal para trabalhar com este vídeo (*threshold* = 80) (Linha vertical vermelha na Figura 14 - B), desta forma poderíamos detectar muito bem as paralarvas e descartar todo o resto na imagem (ex: recipiente, reflexão da luz).

Figura 14: Histograma, em destaque o valor 80.



Fonte: Autor.

Em seguida executamos uma operação chamada binarização baseado no *threshold* (limiar) previamente calculado; em outras palavras, geramos uma imagem só com cores branco e preto, onde todo pixel que sua cor original era menor que

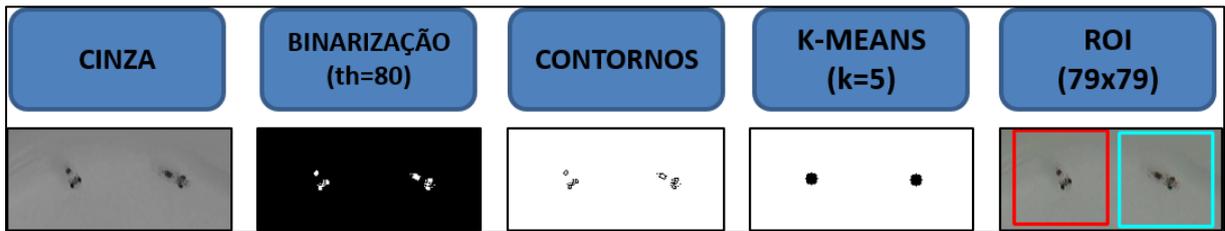
esse limiar ($th = 80$) passa a ser branco e tudo que estava acima disso passa a ser preto. O resultado dessa operação é uma imagem toda preta com várias regiões brancas próximas umas das outras, estes conjuntos de pontos brancos representam um animal (Figura 15 - Binarização).

Como cada animal é representado por microrregiões de vários pontos brancos, o algoritmo para obtenção de contornos (SUZUKI; OTHERS, 1985) foi escolhido para obter o centro de massa de cada microrregião. Esta técnica de programação é usada para obter objetos que possuem uma mesma intensidade de cor e estão ligados por pontos contínuos. Ao final desse processo, temos uma lista de coordenadas (x, y) que representam os centros de massa das várias microrregiões, agora chamadas de regiões brancas (Figura 15 - Contornos).

Cada lista de coordenadas $[(x_1, y_1), (x_2, y_2) \dots (x_n, y_n)]$ das regiões brancas obtidas na etapa anterior se tornará as coordenadas (x, y) de um único animal após aplicarmos o K-Means (KANUNGO et al., 2002); uma técnica de programação que agrupa várias coordenadas e ao final resulta em um número fixo pré-estabelecido de *clusters*, onde cada par de coordenada (*cluster*) passará a ser a localização de um animal. No caso abordado são cinco animais, logo $k = 5$ (Figura 15 - *K-Means*). A lista de coordenadas cedidas pelo K-Means reflete a localização de cada animal no recipiente ao longo dos *frames*. Estas coordenadas serão utilizadas posteriormente para rastrear os animais.

Avaliamos o tamanho dos animais em vários *frames* e em vários ângulos diferentes ao longo do vídeo e concluímos que uma região quadrada com uma base de 79×79 pixels seria ideal para comportar os animais. Desta forma, a marcação não excluiria uma parte dos polvos e não deixaria muito espaço ocioso dentro do quadrado. Partindo das coordenadas cedidas pelo K-Means como ponto inicial, calculamos 39 pixels para as extremidades e fizemos uma Área de Interesse (BRADSKI; KAEHLER, 2008b) (Figura 15 – *ROI*). A subimagem demarcada pelas ROIs será utilizada como parâmetro de entrada na RNC para avaliar o tipo de comportamento do animal.

Figura 15: Pipeline do pré-processamento de imagem.



Fonte: Autor.

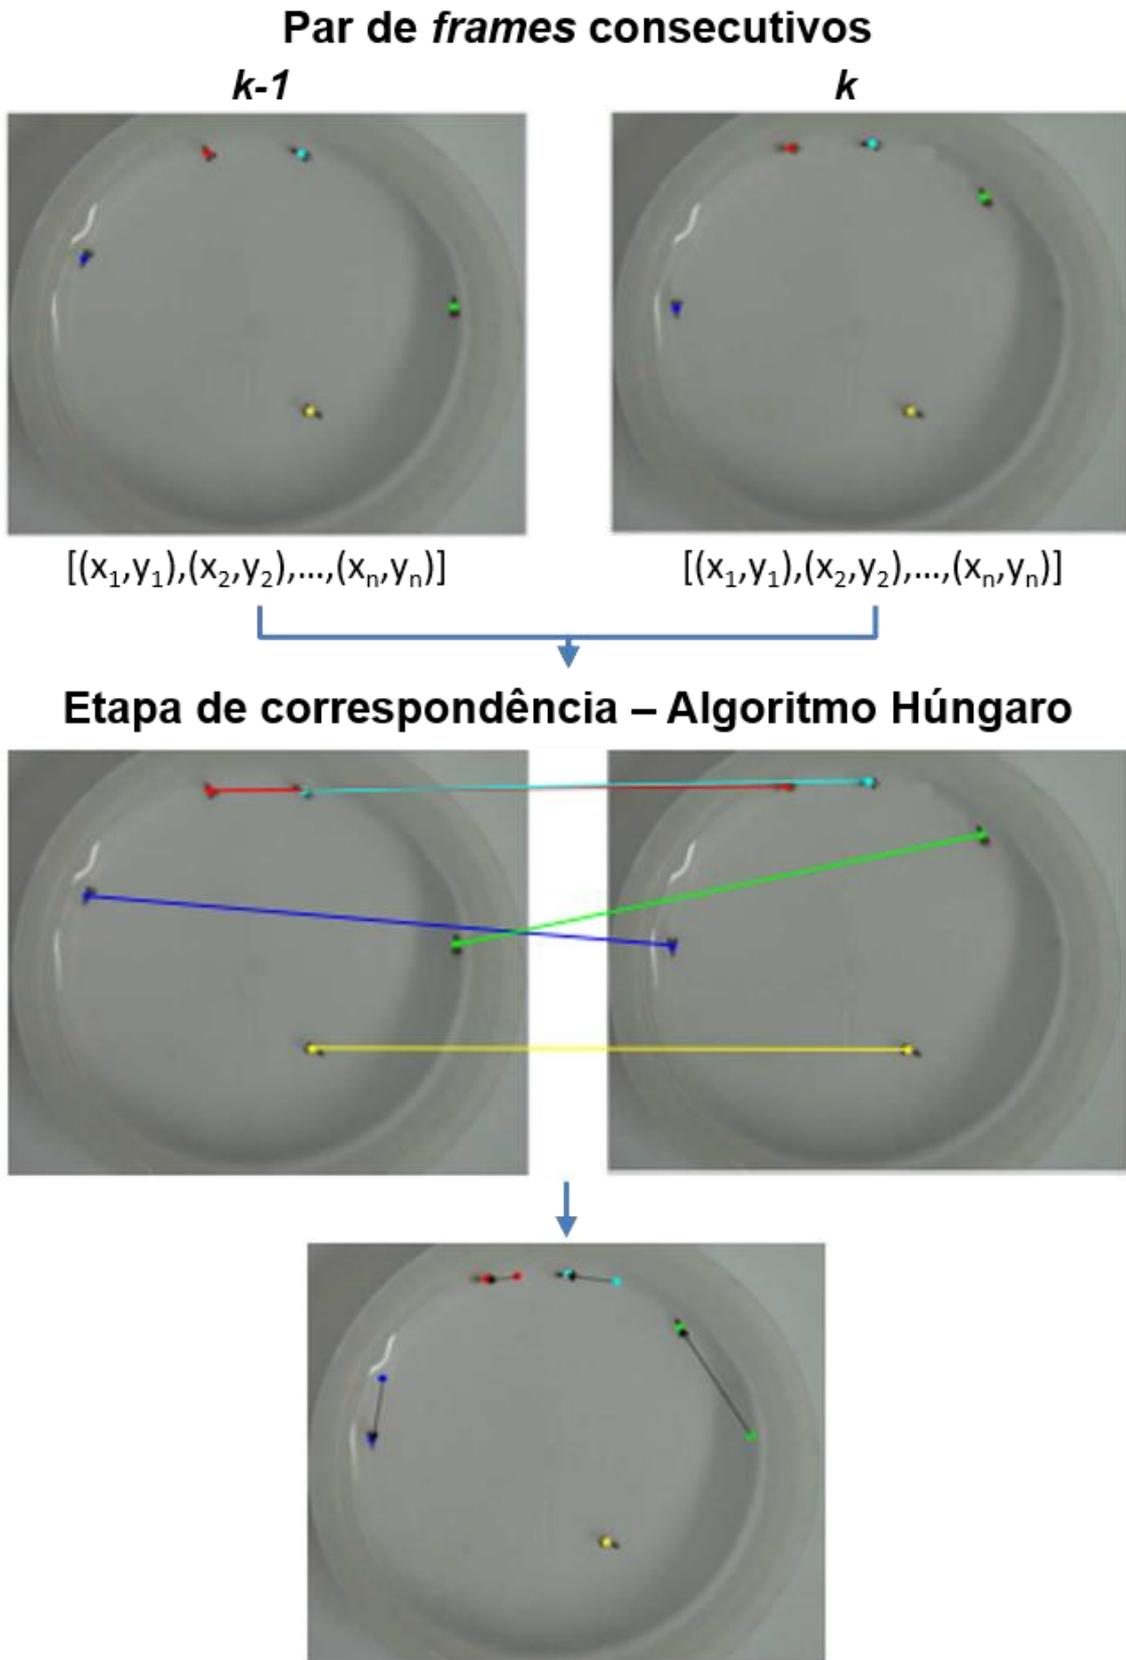
Ao final do processo supracitado nesta sessão a ferramenta é capaz de detectar as paralarvas nos *frames*.

4.2 RASTREIO DAS PARALARVAS

O pipeline de pré-processamento de imagens explicado na sessão anterior será aplicado sequencialmente em todos os *frames* do vídeo, desta forma, em todo *frame* teremos as coordenadas cartesianas (x, y) cedidas pelo K-Means para cada animal (cluster).

Para rastreamos os animais ao longo do vídeo precisamos calcular a distância euclidiana entre as coordenadas obtidas pelo o K-Means, desta forma, deduziremos que o animal no *frame* K-1 é o mesmo no *frame* K se a distância entre eles é mínima. Nesse caso, o algoritmo Húngaro (CUI et al., 2016) foi selecionado para realizar essa tarefa, este código é baseado no cálculo da distância euclidiana entre dois objetos (clusters) e visa encontrar um objeto ótimo a partir de um conjunto finito de objetos em tempo computacional polinomial. O objeto ideal é a distância mínima entre clusters de dois quadros consecutivos. O problema pode ser modelado como um grafo bipartido, com todos os clusters do *frame* k-1 conectados a todos os clusters do *frame* k. Cada borda tem um custo não negativo, isto é, a distância em pixels entre os elementos. O algoritmo encontra a melhor correspondência entre dois pontos com um custo total mínimo, permitindo calcular o deslocamento de cada animal entre dois quadros consecutivos. A Figura 16 mostra o fluxo total e a sequência de etapas para obter esses dados.

Figura 16: Rastreamento das paralarvas usando o Algoritmo Húngaro.



Fonte: Autor.

4.3 CLASSIFICAÇÃO DE COMPORTAMENTOS

Como previamente relatado no Referencial Teórico no capítulo 2, constatamos quatro tipos de comportamentos do *O. insularis*, são eles: nado Normal, nado em Pé, nado Lateral e Clean. Três desses comportamentos supracitados (Nado Normal, em Pé e Lateral) foram descritos em trabalhos anteriores (ORTIZ; RÉ; MÁRQUEZ, 2006), já o comportamento Clean é totalmente novo neste estágio larval do *O. insularis*.

Para o Octopus Tracker, criamos, treinamos e utilizamos uma RNC usando a biblioteca Tensorflow, uma biblioteca de código aberto que ajuda no desenvolvimento de modelos de redes neurais convolucionais (TENSORFLOW. Disponível em: <<https://www.tensorflow.org/>>. Acesso em 10 abr. 19).

A arquitetura criada foi baseada na rede do google chamado MobileNet V2 (HOWARD et al., 2017), um modelo pré-treinado no conjunto de dados ImageNet que é um grande conjunto de dados web com mais de 1.4 milhão de imagens e mais de 1000 classes. O MobileNet é baseado numa arquitetura simples que usa convoluções separáveis em profundidade para construir redes neurais profundas leves (Figura 17).

Figura 17: Arquitetura da MobileNet



Fonte: Autor

No treinamento para a detecção dos comportamentos das paralarvas foram utilizados 4000 passos e uma taxa de aprendizado de 0.01, baseamos a estrutura da nossa rede no exemplo da rede neural convolucional disponível pelo google em <<https://codelabs.developers.google.com/codelabs/tensorflow-for-poets/#0>>.

Esta configuração de rede conseguiu aprender e reconhecer os comportamentos da espécie *O. insularis* e com isso extrair informações sobre esse animal no seu estágio larvário.

Geramos imagens de 79x79 pixels das paralarvas em diferentes ângulos e diferentes tipos de comportamentos para treinamos a RNC. As imagens foram separadas em duas categorias: treinamento e testes. No total, foram utilizadas 592 imagens - 148 de cada comportamento, onde 50% (74 imagens por comportamento) foram usadas para treinamento e os outros 50% (74 imagens por comportamento) foram utilizadas para testar a rede.

Na tabela abaixo temos o resultado da validação de treinamento com uma taxa de acerto de: 100% para “Normal”, 86% para “Clean”, 97% para “Pé” e 96% para “Lado”.

Tabela 1: Validação da Rede Neural.

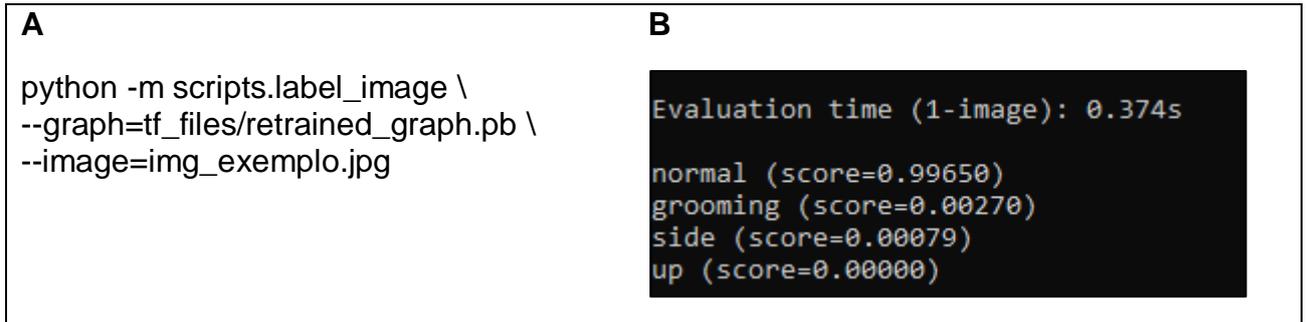
Comportamentos definidos na validação	Comportamentos retornados pela RNA				Acerto (%)
	Normal	Clean	Em pé	Lado	
Normal	74	0	0	0	100%
Clean	0	64	10	0	86%
Em pé	1	1	72	0	97%
Lado	1	0	2	71	96%

Fonte: Autor.

Cada vez que enviamos uma imagem para a Tensorflow, ela retorna uma lista contendo as seguintes informações: os tipos de categorias (comportamentos) que a rede é capaz de detectar e a acurácia para cada um deles. No painel A da Figura 18 temos o código utilizado num exemplo em que a rede classifica uma imagem. O código possui dois parâmetros, o primeiro é o modelo da rede com a estrutura e os pesos sinápticos, este gráfico contém uma versão da rede base com uma camada final nos moldes das categorias utilizadas no treinamento. O segundo parâmetro é a imagem a ser analisada pela rede.

Já no painel B da Figura 18 temos as informações retornadas ao final do processamento da rede, a primeira linha faz referência ao número de imagens e o tempo gasto neste processo de classificação, as linhas subsequentes são as categorias dos comportamentos (Normal, Clean, Lateral e Pé, conseqüentemente) e a acurácia da rede para cada comportamento.

Figura 18: Tensorflow. (A) Código para ativar a rede. (B) Informações retornadas pela rede.



Fonte: Autor.

Incorporamos o código para ativar a rede ao nosso pipeline geral de processamento do vídeo e em cada *frame* enviamos uma imagem (Figura 15 - ROI) de cada animal para a rede e ela retorna apenas a maior acurácia e o número correspondente ao comportamento.

4.4 DADOS DE SAIDA DO PIPELINE

No decorrer das etapas supracitadas no processamento do vídeo, a ferramenta salva algumas informações num arquivo do tipo Python (Figura 19). Este arquivo é composto por um cabeçalho contendo as dimensões originais do vídeo em pixels (altura e largura) (Figura 19 - Linhas 1 e 2) e um dicionário dos comportamentos do animal (Figura 19 - Linha 5).

Além disso, em cada *frame* alocamos para cada paralarva um vetor de tuplas contendo as seguintes informações: as coordenadas cartesianas (x, y), o retorno da rede contendo apenas o número da categoria correspondente ao comportamento identificado pela mesma e a sua acurácia (valor varia entre 0 e 1.0), e a densidade média de cor na área de interesse (Figura 15 - ROI) (Figura 19 - Linha 8).

Figura 19: Arquivo .py gerado pela ferramenta ao final do processamento do vídeo.

```
1 height = 1080          # Original Height
2 width = 1440          # Original Width
3
4 # List with animals behavior
5 list_behavior = {'swnormal': 1, 'swup': 2, 'swside': 3, 'grooming': 4}
6
7 # List with (X Value, Y Value, Number of Behavior, Percent of Behavior, Average
8 bioTracker = [(1068, 433, 4, 1.0, 111.758), (1068, 433, 4, 1.0, 111.758), (1067, 433,
```

Fonte: Autor.

Posteriormente, este arquivo será utilizado para visualizar graficamente os dados processados pela ferramenta e compor as figuras que serão apresentadas no próximo capítulo.

5 RESULTADOS

Para gerar cada uma das figuras neste capítulo, implementamos códigos na linguagem de programação Python que fossem capazes de ler o arquivo de saída gerado pela ferramenta ao final do processamento do vídeo.

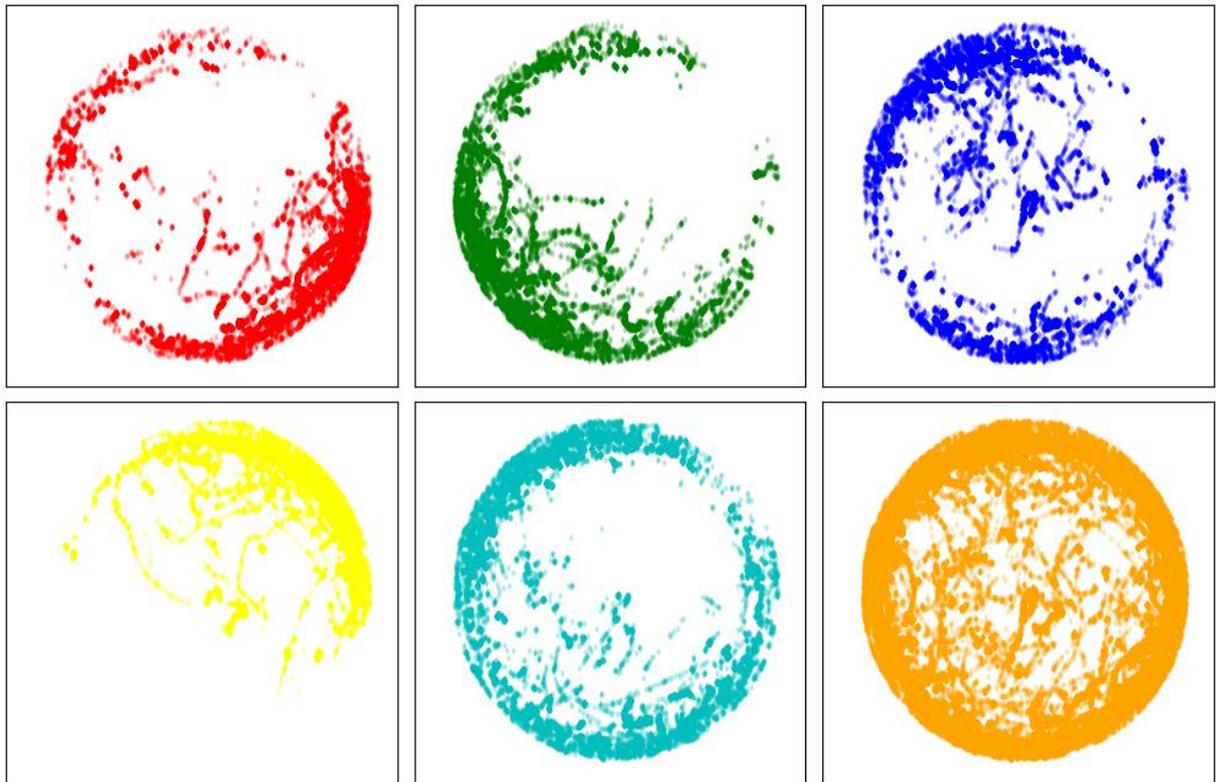
Fomos capazes de gerar quatro resultados principais, são eles: mapas de localização, onde são mostradas posições para cada animal dentro do recipiente cilíndrico (Figura 20), serie temporal da velocidade individual e populacional, assim como suas distribuições (Figura 21), o comportamento individual e populacional (Figura 22) e a densidade de cor dos animais em cada *frame* (Figura 23). Cada uma dessas figuras será apresentada e melhor detalhada nas próximas sessões.

5.1 MAPAS DE LOCALIZAÇÃO

A Figura 20 apresenta os mapas de localização das paralarvas individuais e a localização populacional (o mapa laranja) ao longo de todo vídeo analisado; estimado a partir do algoritmo de rastreamento implementado. A partir das figuras, é possível perceber que os animais preferem se deslocar em regiões mais próximas da borda do contêiner. Este é um aspecto interessante que pode ser analisado melhor neste período larval do animal; este comportamento pode estar ligado ao fato dos animais terem um instinto natural de buscar proteção em estruturas sólidas. Este comportamento é comumente observado em animais inseridos em seu habitat natural, buscando abrigos contra predadores.

Percebe-se também que os animais preferem ficar em regiões definidas, não explorando todas as regiões da fronteira. Uma região escolhida por um animal não se cruza completamente com outra escolhida por um animal diferente. O que se pode conjecturar, é que depois do estágio de paralarvas, os polvos preferem assumir um comportamento de isolamento, tendo poucas interações com outros indivíduos, como observado na natureza.

Figura 20: Localização dos animais no recipiente.



Fonte: Autor.

5.2 PERFIL DE VELOCIDADE

A Figura 21 exibe as séries de *frames* individuais e populacionais de valores de velocidade em 40963 quadros analisados a partir do conjunto de dados gerados pelo algoritmo de rastreamento. A última linha (gráfico em laranja) representa a média da velocidade de todos os animais. Os gráficos do lado direito caracterizam a distribuição de velocidade para cada animal e para a população.

Em todos os gráficos, é visível que há várias mudanças repentinas de velocidade, nas quais os animais deixam um momento de velocidade zero e chegam à velocidade máxima rapidamente, o valor mais alto encontrado no gráfico populacional foi de 20,3 px/ms (pixel/milissegundos). Isso mostra a capacidade desses animais de nadar e seu dinamismo, mesmo em seu estágio de larval.

Além disso, é possível notar que a maioria dos indivíduos possui picos de velocidade máxima semelhante (maior marca alcançada foi de 30,8 px/ms, apenas o quinto animal (na cor ciano) registrou esta marca); com exceção da paralarva correspondentes ao gráfico em magenta (quarto gráfico), seu maior valor de velocidade foi de 26,5 px/ms, o menor registrado entre os animais.

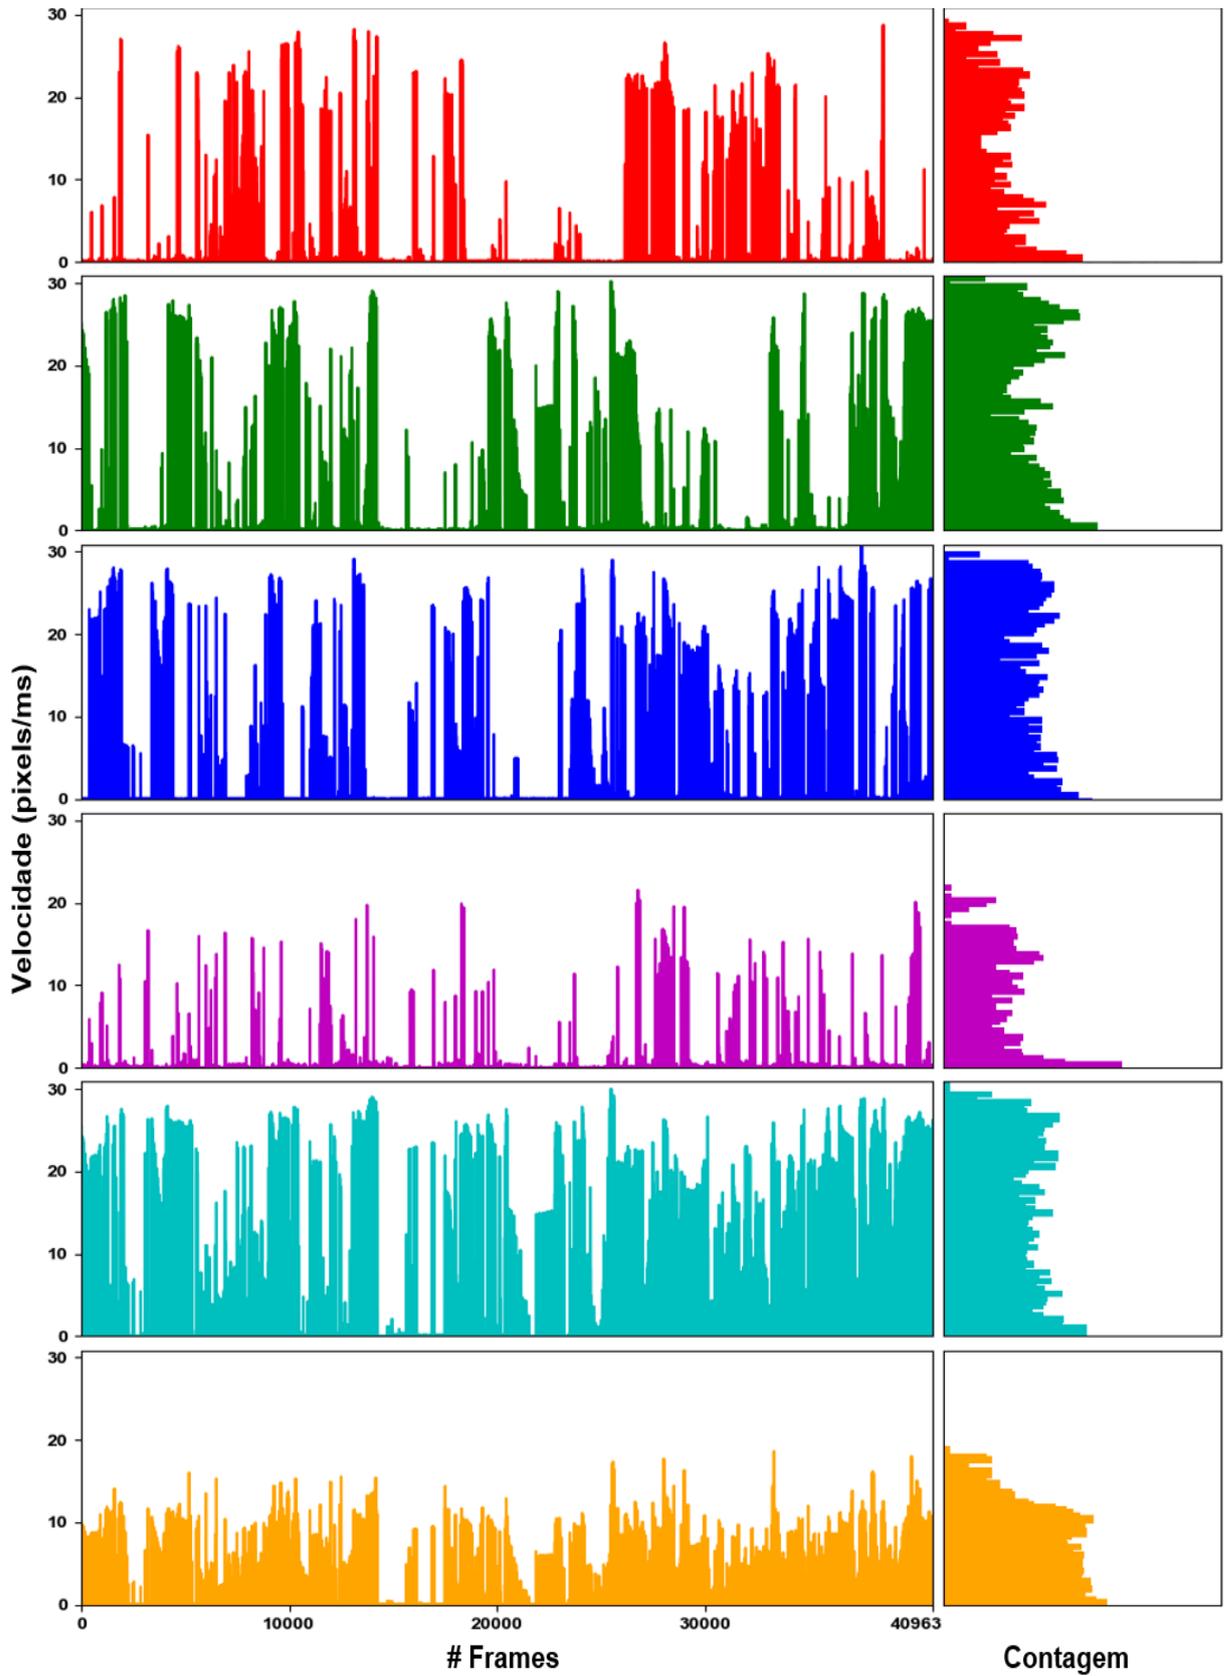
As distribuições de velocidade dos animais representados pelos gráficos vermelho e verde aproximam-se de uma distribuição bimodal, isto é, maiormente composto com picos em menor nível de velocidade e em maiores níveis de velocidade, o que significa que estes animais permanecem estáticos ou nadando em velocidades maiores por mais tempo.

Os gráficos em azul e em ciano (terceiro e quinto respectivamente) demonstram que as paralarvas correspondentes apresentaram uma distribuição de velocidade mais uniforme, significando que assumiram velocidades diferentes para se moverem, sem priorizar estar em um estado estático ou nadando em velocidades mais altas. O animal representado pelos gráficos ciano é o animal mais ativo.

Essa diversidade no perfil de velocidade tem sido explicada por estudos anteriores com polvos adultos, eles mostraram que em cativeiro pode alterar sua organização social de solitária para hierárquica devido ao confinamento (MATHER, 1985).

Considerando que essas paralarvas são colocadas em um espaço muito limitado durante as gravações em vídeo, é possível que, mesmo nesse estágio inicial, elas sejam capazes de estabelecer um ranking de dominância. Outro estudo concluiu que esses animais apresentam diferenças individuais mesmo em situações padronizadas, com várias classificações (ex: ativa, reativa e evitação) foram definidas para descrever esses múltiplos comportamentos (MATHER; ANDERSON, 1993).

Figura 21: Velocidade das paralarvas ao longo dos frames.



Fonte: Autor.

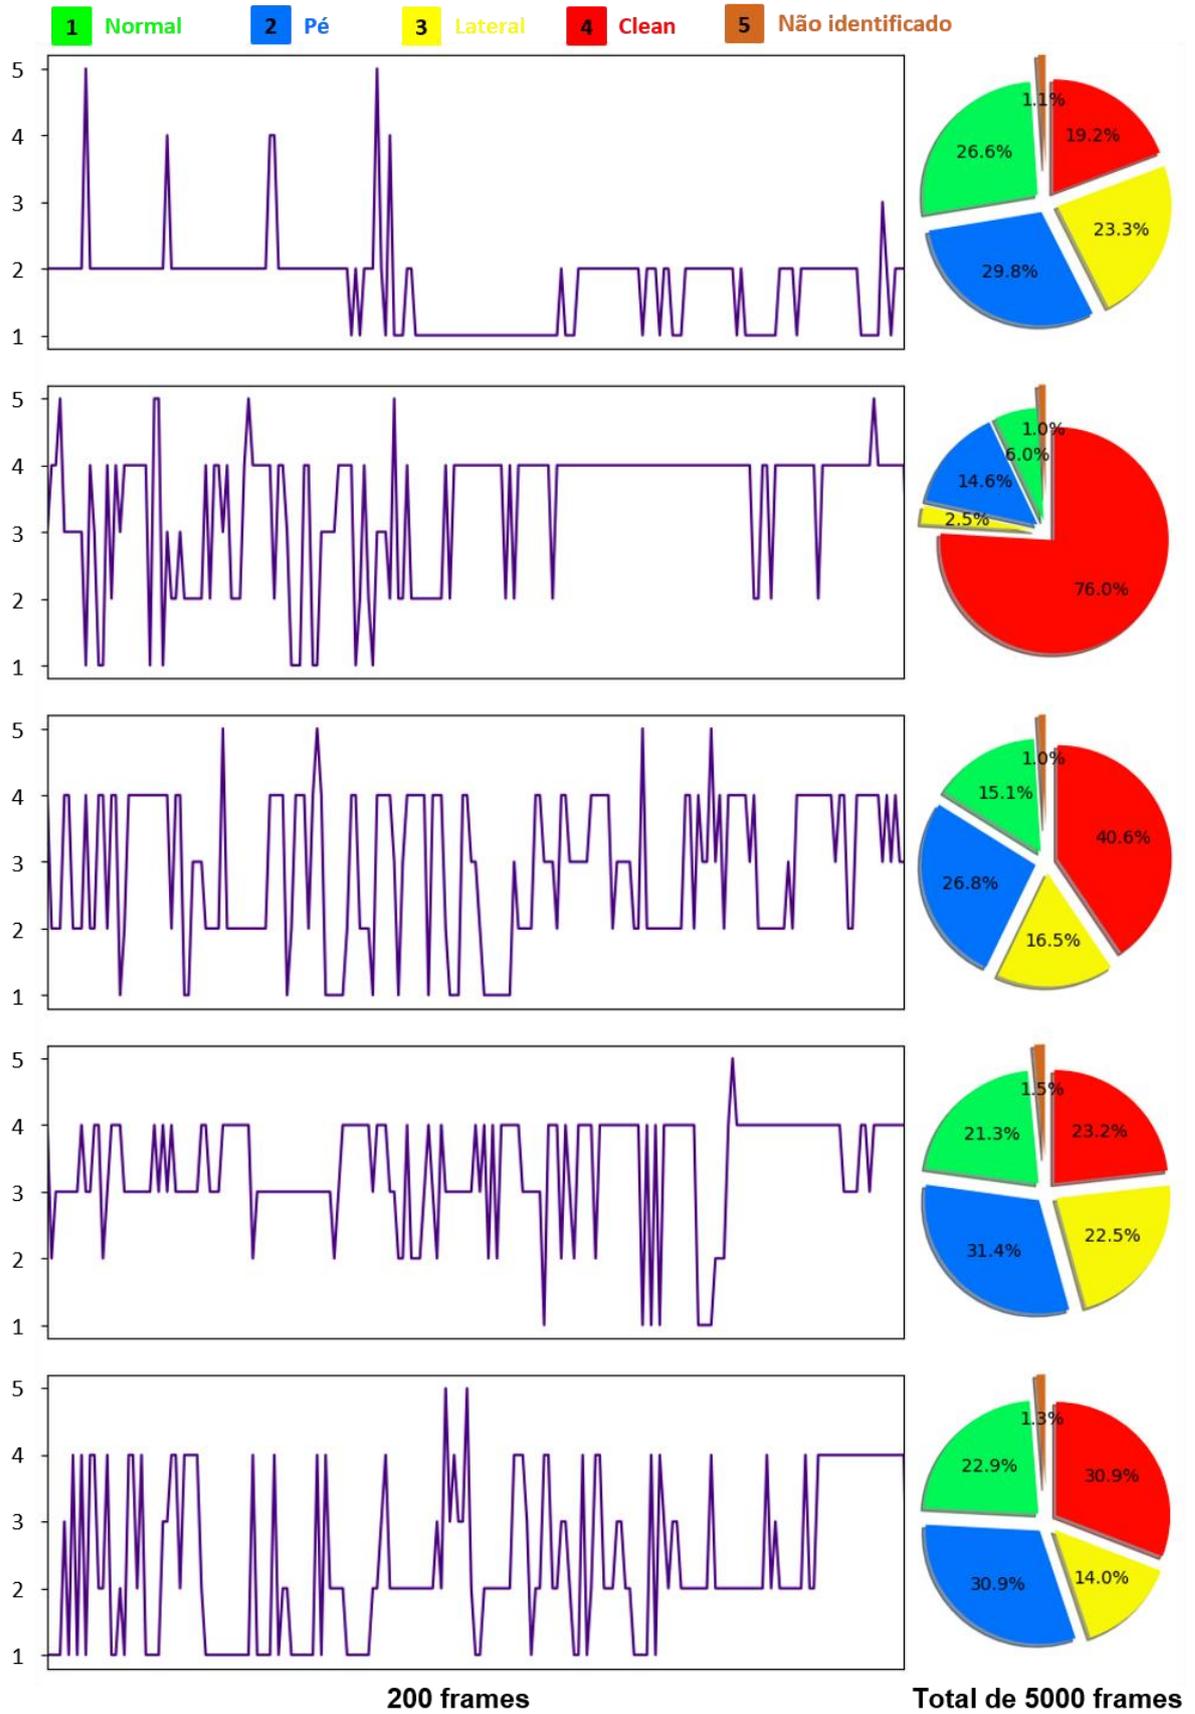
5.3 DINÂMICA DE COMPORTAMENTOS

A Figura 22 mostra o comportamento realizado por cada animal e por quanto tempo ele é mantido (em porcentagem) ao longo do tempo analisado. Isso foi possível graças ao classificador da rede neural, que permitiu identificar os comportamentos das imagens obtidas pela ferramenta durante o processamento do vídeo (Figura 15 - ROI). Conforme explicado no Desenvolvimento no Capítulo 4, a rede neural classifica os comportamentos das paralarvas em quatro categorias: Normal, Pé, Lateral e Clean.

A partir da figura, verifica-se que o animal representado na segunda e terceira linha preferem fazer o comportamento **Clean** (76.0% e 40.6% respectivamente) e ter o comportamento **Pé** como o segundo maior valor (14.6% e 26.8%). No entanto, os outros animais possuem uma distribuição mais uniforme de comportamentos, o que significa que eles têm comportamentos diferentes, mantendo proporções de tempo semelhantes em cada um deles. Em média, o comportamento mais presente em animais é o **Clean**, com 38% seguido por **Pé** 26.7%, **Normal** 18.4% e **Lateral** 15.8%.

Quando a rede identifica um comportamento com uma precisão menor que 90%, esse comportamento entra na categoria denominada **Não identificado**. O animal da quarta fileira teve a maior pontuação nessa categoria, atingindo apenas 1.5%. É importante ressaltar que as situações onde o comportamento é definido como **Não identificado** correspondem a uma parte muito pequena da análise, apenas 1.18% no geral, o que não compromete a investigação comportamental.

Figura 22: Comportamento ao longo do tempo.

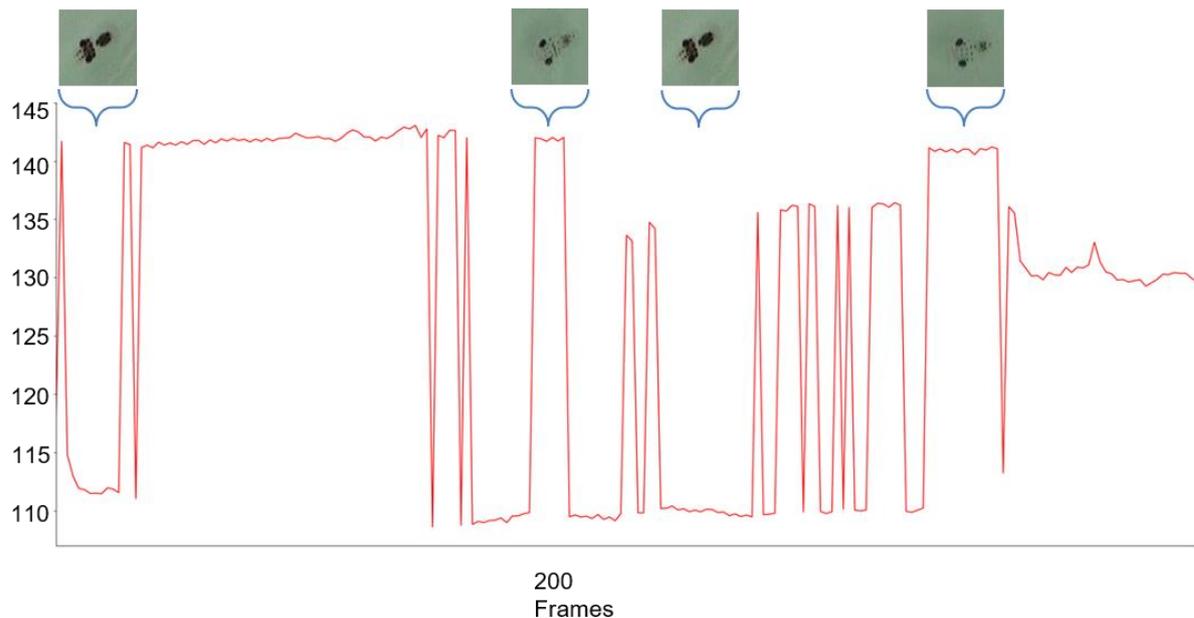


Fonte: Autor.

5.4 DINÂMICA MORFOLÓGICA DOS CROMATÓFOROS

Conforme abordado no Referencial Teórico no Capítulo 2, as paralarvas possuem pequenas estruturas chamadas Cromatóforos (Figura 2), estes órgãos neuromusculares estão atrelados a disposição energética dos animais. A Figura 23 retrata a densidade de cor nas Áreas de interesse (Figura 15 - ROI) dos polvos ao longo do vídeo. Quando os animais estão excitados eles contraem os cromatóforos, deixando a paralarva com as cores mais brancas/transparente, a cor deste valor está por volta dos 140 na escala de cinza. Já quando estão relaxados, a energia que outrora foi armazenada, agora expande os cromatóforos deixando o animal mais obscuro, a cor deste valor fica em torno dos 100 na escala de cinza.

Figura 23: Densidade de cor das paralarvas.



Fonte: Autor.

6 CONCLUSÃO

Apresentamos uma ferramenta robusta de código aberto capaz de identificar, rastrear e reconhecer os diferentes tipos de comportamento das paralarvas da espécie *Octopus insularis*. A ferramenta implementada foi baseada em algoritmos bem conhecidos de processamento de imagem e visão computacional para reconhecer e rastrear os animais em um vídeo, e uma RNC treinada para reconhecer e diferenciar os diferentes tipos de comportamentos apresentados por cada paralarva; com uma acurácia acima de noventa por cento de precisão.

Dados sobre o desenvolvimento embrionário e pós-embrionário da espécie mencionada acima são muito raros, assim como as ferramentas gratuitas capazes de extrair e fazer análises detalhadas sobre estas informações. A criação desta espécie de polvo do estágio larval até o estágio adulto ainda é um desafio devido à alta taxa de mortalidade. Algumas das causas de morte nesses animais são o volume inadequado do tanque (SÁNCHEZ-CONDE et al., 2010). Desta forma, com informações sobre como estes animais se movimentam (mapa de localização, velocidade e distância), será mais fácil estimar o tamanho ideal do tanque para evitar a colisão com as paredes, e muito contato entre as paralarvas, bem como definir a quantidade de alimentos que devem ser oferecidos por litro de água. Além disso, os dados podem ser utilizados para a padronização de tanques adequados, que também fornecerão bem-estar às paralarvas.

Esta ferramenta pretende facilitar e acelerar o estudo deste animal, antes feito manualmente, sem ferir ou interagir com eles, tornando o estudo mais natural possível; e automatizando com precisão a detecção, rastreamento e reconhecimento do comportamento.

6.1 TRABALHOS FUTUROS

Para trabalhos futuros pretendemos aprimorar a escrita na parte biológica dos animais e fazer uma análise mais elaborada em cima dos dados gerados pela ferramenta. Com este aprimoramento, visamos publicar esta pesquisa em forma de artigo científico em alguma revista com conceitos voltados mais para a área biológica.

Identificar os frames onde há a troca repentina dos *clusters* (animais) pelo algoritmo de rastreamento, e assim fazer uma análise profundo dos motivos desta troca para propor melhorarias ao algoritmo. Implementar uma interface gráfica para visualizar e configurar melhor o rastreio dos animais e ao final gerar um arquivo de saída com informações mais detalhadas.

REFERÊNCIAS BIBLIOGRÁFICAS

- BAI, Y.-X. et al. Automatic multiple zebrafish tracking based on improved HOG features. **Scientific reports**, v. 8, n. 1, p. 10884, 2018.
- BIANCHINI, Â. R. Arquitetura de redes neurais para o reconhecimento facial baseado no neocognitron. 2001.
- BRADSKI, G.; KAEHLER, A. **Learning OpenCV**. [s.l.: s.n.].
- BRADSKI, G.; KAEHLER, A. **Learning OpenCV: Computer vision with the OpenCV library**. [s.l.] “ O’Reilly Media, Inc.”, 2008b.
- CHEN, G. et al. **Deep convolutional neural network based species recognition for wild animal monitoring**. 2014 IEEE International Conference on Image Processing (ICIP). **Anais...IEEE**, 2014
- CHOUDHURY, A.; TALUKDAR, A. K.; SARMA, K. K. A review on vision-based hand gesture recognition and applications. In: **Intelligent applications for heterogeneous system modeling and design**. [s.l.] IGI Global, 2015. p. 256–281.
- COLLOBERT, R. et al. Natural language processing (almost) from scratch. **Journal of machine learning research**, v. 12, n. Aug, p. 2493–2537, 2011.
- CUI, H. et al. **Solving large-scale assignment problems by Kuhn-Munkres algorithm**. international conference on advances in mechanical engineering and industrial informatics. Hangzhou, Zhejiang. **Anais...2016**
- DA SILVA BINOTI, M. L.; BREDÁ BINOTI, D. H.; GARCIA LEITE, H. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v. 37, n. 4, 2013.
- DE PÁDUA BRAGA, A.; DE LEON FERREIRA, A. C. P.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. [s.l.] LTC Editora Rio de Janeiro, Brazil:, 2007.
- GIRIJA, S. S. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. **Software available from tensorflow. org**, 2016.
- GOLDBERG, Y. A primer on neural network models for natural language processing. **Journal of Artificial Intelligence Research**, v. 57, p. 345–420, 2016.
- GONZALEZ, R. C.; EDDINS, S. L.; WOODS, R. E. **Digital image publishing using MATLAB**. [s.l.] Prentice Hall, 2004.
- GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens** . [s.l.] Pearson Educación, 2009.
- HAN, S.; MAO, H.; DALLY, W. J. Deep compression: Compressing deep neural networks with pruning, trained quantization and huffman coding. **arXiv preprint arXiv:1510.00149**, 2015.

- HAUGELAND, J. **Artificial intelligence: the very idea** Cambridge, MA: MIT Press, , 1985.
- HOWARD, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv preprint arXiv:1704.04861**, 2017.
- INSTAGRAM. Disponível em: <<https://www.instagram.com/>>. Acesso em: 10 de abr. 2019.
- KALCHBRENNER, N.; GREFFENSTETTE, E.; BLUNSON, P. A convolutional neural network for modelling sentences. **arXiv preprint arXiv:1404.2188**, 2014.
- KANUNGO, T. et al. An efficient k-means clustering algorithm: Analysis and implementation. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, n. 7, p. 881–892, 2002.
- KODAMA SALTORATTO, A. Y. et al. **MONITORAMENTO DE AVICULTURA A PARTIR DE TÉCNICAS DE VISÃO COMPUTACIONAL**. Colloquium Exactarum. **Anais...**2013
- KOVÁCS, Z. L. **Redes neurais artificiais**. [s.l.] Editora Livraria da Física, 2002.
- LEITE, T. S.; HAIMOVICI, M.; MATHER, J. Octopus insularis (Octopodidae), evidences of a specialized predator and a time-minimizing hunter. **Marine Biology**, v. 156, n. 11, p. 2355–2367, 2009.
- LENZ, T. M. et al. First description of the eggs and paralarvae of the tropical octopus, Octopus insularis, under culture conditions. **American Malacological Bulletin**, v. 33, n. 1, p. 101–110, 2015.
- MANSSOUR, I. H.; COHEN, M. Introdução à computação gráfica. **RITA**, v. 13, n. 2, p. 43–68, 2006.
- MATHER, J. A. Behavioural interactions and activity of captive Eledone moschata: laboratory investigations of a ‘social’ octopus. **Animal behaviour**, v. 33, n. 4, p. 1138–1144, 1985.
- MATHER, J. A.; ANDERSON, R. C. Personalities of octopuses (Octopus rubescens). **Journal of Comparative Psychology**, v. 107, n. 3, p. 336, 1993.
- MATLAB. Disponível em: <<https://www.mathworks.com/products/matlab.html>>. Acesso em 09 ago. 19.
- MATSUGU, M. et al. Subject independent facial expression recognition with robust face detection using a convolutional neural network. **Neural Networks**, v. 16, n. 5–6, p. 555–559, 2003.
- MAZZA, L. O. APLICACAO DE REDES NEURAIAS CONVOLUCIONAIS DENSAMENTE CONECTADAS NO PROCESSAMENTO DIGITAL DE IMAGENS PARA REMOCAO DE RUÍDO GAUSSIANO. 2017.
- MESSENGER, J. B. Cephalopod chromatophores: neurobiology and natural history.

Biological Reviews, v. 76, n. 4, p. 473–528, 2001.

MORAES, L. Â. G. DE. Utilização de redes em cápsulas para classificação de regiões promotoras em sequências de DNA. 2018.

NATH, T. et al. Using DeepLabCut for 3D markerless pose estimation across species and behaviors. 2018.

ORTIZ, N.; RÉ, M. E.; MÁRQUEZ, F. First description of eggs, hatchlings and hatchling behaviour of *Enteroctopus megalocyathus* (Cephalopoda: Octopodidae). **Journal of Plankton Research**, v. 28, n. 10, p. 881–890, 2006.

RAMOT, D. et al. The Parallel Worm Tracker: a platform for measuring average speed and drug-induced paralysis in nematodes. **PloS one**, v. 3, n. 5, p. e2208, 2008.

RÉ, M. E.; BOSCHI, E. E. Pulpos octopódidos (Cephalopoda, Octopodidae). **El Mar Argentino y sus Recursos Pesqueros**; 2. 69-98, 1998.

ROSSUM, G. VAN. Introduction to Python. **New York**, 2002.

SÁNCHEZ-CONDE, F. J. et al. Effect of tank volume on the growth and survival of reared *Octopus vulgaris* paralarvae. 2010.

SNAPCHAT. Disponível em: <<https://www.snapchat.com/l/pt-br/>>. Acesso em: 10 de abr. 2019.

SOUSA, A. DE L. et al. **Redes neurais convolucionais aplicadas ao processo de classificação de cultivares de guaranazeiros**. Embrapa Amazônia Ocidental- Artigo em anais de congresso (ALICE). **Anais...In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL**, 14., 2017 ..., 2017

SUGIMOTO, M. Morphological color changes in fish: regulation of pigment cell density and morphology. **Microscopy research and technique**, v. 58, n. 6, p. 496–503, 2002.

SUZUKI, S.; OTHERS. Topological structural analysis of digitized binary images by border following. **Computer vision, graphics, and image processing**, v. 30, n. 1, p. 32–46, 1985.

TENSORFLOW. Disponível em: <<https://www.tensorflow.org/>>. Acesso em 10 abr. 19.

VILLANUEVA, R.; NORMAN, M. D. Biology of the planktonic stages of benthic octopuses. In: **Oceanography and Marine Biology**. [s.l.] CRC Press, 2008. p. 106–203.

WANG, S. H. et al. Automated planar tracking the waving bodies of multiple zebrafish swimming in shallow water. **PloS one**, v. 11, n. 4, p. e0154714, 2016.