



UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SISTEMA INTELIGENTE PARA RECONHECIMENTO DE NEMATODAS -  
CICLA OCELLARIS EM PESCADA BRANCA-PLAGIOSCION  
SQUAMOSISSIMUS DA FAMÍLIA SCIAENIDAE UTILIZANDO DETECÇÃO  
DE OBJETOS EM TEMPO REAL

Valdeson Dantas de Souza

Manaus  
Dezembro de 2024

UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SISTEMA INTELIGENTE PARA RECONHECIMENTO DE NEMATODAS -  
CICLA OCELLARIS EM PESCADA BRANCA-PLAGIOSCION  
SQUAMOSISSIMUS DA FAMÍLIA SCIAENIDAE UTILIZANDO DETECÇÃO  
DE OBJETOS EM TEMPO REAL

Valdeson Dantas de Souza

Dissertação de Mestrado apresentada a  
Programa de Pós-Graduação em Engenharia  
Elétrica, da Universidade Federal do  
Amazonas, como parte dos requisitos  
necessários à obtenção do título de Mestre  
em Engenharia Elétrica.

Orientador: Carlos Augusto de Moraes Cruz

Manaus  
Dezembro de 2024

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

S729s Souza, Valdeson Dantas de  
Sistema inteligente para reconhecimento de nematodas – *Cicola ocellaris* em pescada branca-*Plagioscion squamosissimus* da família Sciaenidae utilizando detecção de objetos em tempo real / Valdeson Dantas de Souza . 2024  
39 f.: il. color; 31 cm.

Orientador: Carlos Augusto de Moraes Cruz  
Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Amazonas.

1. Reconhecimento de Padrões. 2. Detecção de pontos com parasitas. 3. Análise de parâmetros. 4. Deep Learning. 5. Imagens.  
I. Cruz, Carlos Augusto de Moraes. II. Universidade Federal do Amazonas III. Título



Ministério da Educação  
Universidade Federal do Amazonas  
Coordenação do Programa de Pós-Graduação em Engenharia Elétrica

### FOLHA DE APROVAÇÃO

Poder Executivo Ministério da Educação  
Universidade Federal do Amazonas  
Faculdade de Tecnologia  
Programa de Pós-graduação em Engenharia Elétrica

Pós-Graduação em Engenharia Elétrica. Av. General Rodrigo Octávio Jordão Ramos, nº 3.000 - Campus Universitário, Setor Norte - Coroado, Pavilhão do CETELI. Fone/Fax (92) 99271-8954 Ramal:2607. E-mail: ppgee@ufam.edu.br

**VALDESON DANTAS DE SOUZA**

**SISTEMA INTELIGENTE PARA RECONHECIMENTO DE NEMATODAS - CICLA OCELLARIS EM PESCADA BRANCA-PLAGIOSCION SQUAMOSISSIMUS DA FAMÍLIA SCIAENIDAE UTILIZANDO DETECÇÃO DE OBJETOS EM TEMPO REAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Aprovada em 12 de dezembro de 2024.

#### BANCA EXAMINADORA

Prof. Dr. Carlos Augusto de Moraes Cruz- Presidente  
Prof. Dr. Waldir Sabino da Silva Junior- Membro Titular 1 - Interno  
Prof. Dr. Frederico da Silva Pinagé - Membro Titular 2 - Externo

Manaus, 09 de dezembro de 2024.



Documento assinado eletronicamente por **Frederico da Silva Pinagé, Professor do Magistério Superior**, em 16/12/2024, às 15:03, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Waldir Sabino da Silva Júnior, Professor do Magistério Superior**, em 17/12/2024, às 09:35, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Carlos Augusto de Moraes Cruz, Professor do Magistério Superior**, em 17/12/2024, às 10:37, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



A autenticidade deste documento pode ser conferida no site [https://sei.ufam.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2364588** e o código CRC **F271EE4A**.

---

Av. Octávio Hamilton Botelho Mourão - Bairro Coroadó 1 Campus Universitário Senador Arthur Virgílio Filho,  
Setor Norte - Telefone: (92) 3305-1181  
CEP 69080-900 Manaus/AM - [mestrado\\_engeletrica@ufam.edu.br](mailto:mestrado_engeletrica@ufam.edu.br)

Referência: Processo nº 23105.051170/2024-65

SEI nº 2364588

---

Criado por [31183646291](#), versão 3 por [31183646291](#) em 09/12/2024 13:32:54.

# Agradecimentos

- Agradeço primeiramente a Deus pela oportunidade de acesso aos estudos e por todas as dificuldades que foram colocadas no meu caminho, serviram como experiências de vida.
- À todas as pessoas que fazem e fizeram parte da minha vida desde a minha infância até este momento e que contribuíram de alguma forma para que eu chegasse onde estou.
- À minha família, em especial à minha mãe Cristiane e meu pai Valclides pelo total apoio nessa jornada da minha vida.
- Ao professor Dr e orientador Carlos Augusto de Moraes Cruz pelo compromisso com a educação e formação de Engenheiros nesta instituição.
- Aos amigos de faculdade com quem estudei diariamente, em especial aos grandes amigos Paulo André , Thiago Pinheiro pelos bons momentos na instituição.
- À Dr. Daniel porto por toda as aulas de parasitologia e afins
- Gostaria de expressar minha profunda gratidão ao meu marido, João Torres, pelo apoio incansável, paciência e amor durante todo o processo de elaboração desta dissertação. Sua compreensão e incentivo foram essenciais para que eu chegasse até aqui. Agradeço também por estar ao meu lado, sempre me motivando a seguir em frente, especialmente nos momentos mais desafiadores. Sem ele, este trabalho não teria sido possível

Resumo da Dissertação apresentada à UFAM como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

SISTEMA INTELIGENTE PARA RECONHECIMENTO DE NEMATODAS -  
CICLA OCELLARIS EM PESCADA BRANCA-PLAGIOSCION  
SQUAMOSISSIMUS DA FAMÍLIA SCIAENIDAE UTILIZANDO DETECÇÃO  
DE OBJETOS EM TEMPO REAL

Valdeson Dantas de Souza

Orientador: Carlos Augusto de Moraes Cruz

Programa de Pós-Graduação em Engenharia Elétrica

Este trabalho apresenta uma proposta detalhada sobre a detecção dos pontos de parasitas com o uso de Deep-learning. O motivo pelo qual o estudo é realizado refere-se ao problema dos procedimentos que são manuais e com o uso da visão humana e, portanto causando um atraso, ou erros na inspeção dependendo da quantidade analisada de alguns parasitas em peixes. Dentre as ferramentas de imagem existem opções para reconhecer padrões que se baseiam em aplicações computacionais que conseguem reconhecer, vozes, imagem e afins. Em virtude disso, as análises de reconhecimento e detecções de formas estão voltadas em cálculos matemáticos envolvendo áreas e perímetros, e partes estatísticas dos próprios padrões escolhidos para detecção das larvas no tucunaré. Dessa forma, este trabalho discorre sobre os principais funções para o reconhecimento de padrões com o uso de filtros digitais de processamento, os resultados com a quantidade de larvas e detecção das áreas com os mesmos será gerada uma imagem em IDE'S com o Python, câmera OV7670, e afins, para converter os dados gerado pela câmera em linguagem de máquina ou uma foto já existente do objeto estudado.

**Palavras-chave:** reconhecimento de padrões, detecção de parasitas, análise de imagem, parâmetros computacionais, deep learning.

Abstract of Dissertation presented to UFAM as a partial fulfillment of the requirements for the degree of Master in Eletrical Engineering

INTELLIGENT SYSTEM FOR RECOGNITION OF NEMATODES - CICLA  
OCELLARIS IN WHITE HAKE-PLAGIOSCION SQUAMOSISSIMUS OF THE  
FAMILY SCIAENIDAE USING REAL-TIME OBJECT DETECTION

Valdeson Dantas de Souza

Advisor: Carlos Augusto de Moraes Cruz

Postgraduate Program in Electrical Engineering

This work presents a detailed proposal on the detection of parasite points using Deep-learning. The reason why the study is carried out refers to the problem of procedures that are manual and use human vision and, therefore, causing a delay or errors in inspection depending on the analyzed quantity of some parasites in fish. Among the image tools there are options for recognizing patterns that are based on computational applications that can recognize voices, images and the like. As a result, shape recognition and detection analyzes are focused on mathematical calculations involving areas and perimeters, and statistical parts of the patterns chosen to detect larvae in peacock bass. Thus, this work discusses the main functions for pattern recognition with the use of digital processing filters, the results with the number of larvae and detection of areas with them, an image will be generated in IDE'S with Python, OV7670 camera , and the like, to convert the data generated by the camera into machine language or an existing photo of the studied object.

**Keywords:** pattern recognition, parasite detection, image analysis, computational parameters, deep learning.

# Lista de Siglas

**ANDIOES** Associação Nacional de Desenvolvimento de Inovações e Organizações de Ensino Superior

**CMOS** Semicondutor de Óxido Metálico Complementar (*Complementary Metal-Oxide-Semiconductor*)

**CGI** Coordenação Geral de Inspeção)

**COCO** Objetos Comuns em Contexto (*Common Objects in Context*)

**CODEX** Palavra do latim que significa código

**GPI** Interface de Periféricos Geral (*General Purpose Interface*)

**GPU** Unidade de Processamento Gráfico (*Graphics Processing Unit*)

**HDMI** Interface Multimídia de Alta Definição (*High-Definition Multimedia Interface*)

**IDE** Ambiente de Desenvolvimento Integrado (IDE)

**INPA** Instituto Nacional de Pesquisas da Amazônia

**IoU** Intersecção sobre União(Intersection over Union)

**LUX** (símbolo lx) é a unidade derivada do Sistema Internacional de Unidades usada para medição do fluxo luminoso por unidade de área

**mAP** Precisão Média (*Mean Average Precision*)

**MP4** Grupo de Especialistas em Imagens em Movimento( *MPEG-4*) Part 14

**OPENCV** Biblioteca de Visão Computacional (*Open Source Computer Vision Library*)

**RIISPOA** Regulamento de Inspeção Industrial e Sanitária de Produtos de Origem Animal

**SIF** Serviço de Inspeção Federal

**SO** Sistema Operacional (*Operating System*)

**USB** Barramento Serial Universal (*Universal Serial Bus*)

**VGA** Adaptador Gráfico de Vídeo (*Video Graphics Array*)

**URL** Localizador Uniforme de Recursos (*Uniform Resource Locator*)

**YOLO** Você Apenas Olha Uma Vez (*You Only Look Once*)

**GPIO** Interface de Entrada/Saída de Propósito Geral (*General Purpose Input/Output*)

**RGB** Vermelho, Verde e Azul (*Red, Green, Blue*)

**ZIP** Plano de Melhora de Zona (*Zone Improvement Plan*)

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Objetivos da Dissertação . . . . .	3
1.2	Organização da Dissertação . . . . .	4
1.3	Motivação . . . . .	5
1.4	Contexto . . . . .	7
<b>2</b>	<b>Fundamentos Teóricos</b>	<b>8</b>
2.1	Regulamentação técnica sobre inspeção de pescados em estabelecimentos . . . . .	8
2.1.1	Requisitos da inspeção e reinspeção de pescado na instalação e equipamentos . . . . .	9
2.2	Técnica de inspeção visual . . . . .	10
2.3	Plano amostral e critério de julgamento na inspeção de pescado . . . . .	11
2.4	Detecção através do YOLO v5 com OpenCV . . . . .	12
2.5	Yolo e Roboflow . . . . .	14
2.6	O que é COCO? . . . . .	15
2.7	COCO e YOLO . . . . .	15
2.8	Código para Binarização de Imagens . . . . .	16
2.9	A função houghcircles no python . . . . .	16
2.10	Código para o IoU . . . . .	17
2.11	Roboflow . . . . .	18
2.12	Base de Dados . . . . .	20
2.13	IoU . . . . .	21
2.14	Procedimentos . . . . .	22
2.14.1	RAPBERRY PI B+ . . . . .	22

2.14.2	Câmera VGA Digital OV7670 . . . . .	22
2.14.3	Configuração das bibliotecas opencv no python 3.8 . . . . .	23
2.14.4	Adicionamento scikit-image . . . . .	23
2.14.5	Detecção dos pontos de parasitas-houghcircles . . . . .	23
2.14.6	Fluxograma do Sistema . . . . .	24
2.14.7	Realizando o Dataset no Roboflow . . . . .	25
<b>3</b>	<b>Experimentos e Resultados</b>	<b>27</b>
3.1	Filé de Peixe no laboratório do INPA . . . . .	27
3.2	Resultado do IoU . . . . .	33
<b>4</b>	<b>Conclusão</b>	<b>34</b>
	<b>Referências Bibliográficas</b>	<b>35</b>
<b>A</b>	<b>Anexos-Testes</b>	<b>39</b>
A.1	Testes, Detecção e roboflow . . . . .	39

# Lista de Figuras

1.1	RIISPOA e incisos com suas leis . . . . .	3
2.1	Aplicação de luz branca para inspeção do filé de peixe . . . . .	10
2.2	Aplicação de luz negra em ambientes . . . . .	11
2.3	Remoção dos parasitas com o uso da pinça . . . . .	11
2.4	YOLO representação de detecção de Bounding boxes . . . . .	13
2.5	Representação de Fluxo de dados . . . . .	14
2.6	Comparativo entre YOLO e COCO . . . . .	15
2.7	Image da amosta de peixe no roboflow . . . . .	20
2.8	Modelo do YOLO para o treinamento. . . . .	21
2.9	Câmara ov7670 . . . . .	22
2.10	Fluxograma Geral do Sistema . . . . .	24
2.11	Fluxograma Yolo v5 . . . . .	24
2.12	Fluxograma Yolo v5 . . . . .	25
2.13	Fluxograma de requisição. . . . .	25
2.14	Campo de carregamento de vídeos, anotações ou imagens para o Dataset. . . . .	26
3.1	Filé de peixe . . . . .	28
3.2	Filé de peixe com o reconhecimento do sistema proposto . . . . .	28
3.3	Quantidade detectada . . . . .	29
3.4	parasita detectado . . . . .	29
3.5	Pescadas Brancas . . . . .	30
3.6	Tratamento do Peixe . . . . .	30
3.7	Luz UV . . . . .	31
3.8	Negatoscópio . . . . .	31

3.9	parasita detectado outro ângulo . . . . .	32
3.10	Câmera Logitech C920 Full HD 1080P . . . . .	32
3.11	Ambiente roboflow . . . . .	33
3.12	Banco de Imagens na nuvem . . . . .	33

# Lista de Tabelas

2.1 Segundo a CODEX STAN 233-1969 – menor ou igual a 1Kg.Inspeção de Lotes e níveis de aceitação . . . . .	12
---	----

# Capítulo 1

## Introdução

Existem vários tipos de doenças relacionadas a alimentos, e principalmente, em peixes e outros animais, que não estão próprios para o consumo. O índice de consumo humano referente a peixes Manaus e Itacoatiara, que foi estimado entre 100 e 200 g/dia, e para os ribeirinhos dos lagos de várzea do médio Amazonas, de 369 g/dia [1]. E no Amazonas, tem-se um consumo de até 500 g/dia[2], onde moram famílias de diversas classes sociais. Em ambiente natural, os peixes são hospedeiros de uma infinidade de parasitas, e segundo o Ministério da agricultura, pecuária e abastecimento junto com a GPI as análises devem ser implantadas, mantidas, monitoradas e verificadas pelos estabelecimentos, contendo registros auditáveis que atentem os requisitos sanitários e tecnológicos estabelecidos pelo RIISPOA – aprovado pelo Decreto nº 9.013, de 29 de março de 2017 alterado pelo Decreto nº 9.069, de 31 de maio de 2017[3]. E esses requisitos de inspeção e fiscalização é feita por meio de controle oficial de inspeção visual macroscópica para detecção de parasitas, mediante procedimentos específicos com ou sem uso de equipamentos auxiliares. Como já exposto, os procedimentos são manuais e com o uso da visão humana e, portanto causando um atraso, ou erros na inspeção dependendo da quantidade analisada de alguns parasitas em peixes. Dentre as ferramentas de imagem existem opções para reconhecer padrões que se baseiam em aplicações computacionais que conseguem reconhecer, vozes, imagem e afins. Em virtude disso, as análises de reconhecimento e detecções de formas estão voltadas em cálculos matemáticos envolvendo áreas e perímetros, e partes estatísticas dos próprios padrões escolhidos para detecção das larvas no tucunaré. Para iniciar esse procedimento existe uma ferramenta chamada

OpenCV, que junto com o programa Python permite desenvolver aplicações voltadas a áreas de visão computacional[4], Haja vista que essa biblioteca pode ser voltada a aplicações em dispositivos, como também outros tipos de aplicações de processamento digital de imagens. Há vários tipos de formas básicas de detecção em imagem digitais que são pontos, linhas e as bordas. Esse reconhecimento de padrões agrega técnicas computacionais e suas respectivas classes com mínima intervenção humana possível. Essa inspeção com o uso de visão computacional permite diminuir o tempo de inspeção e fiscalizar o procedimento através do uso do controle de resultados, pois operações de defesa do consumidor apontaram fraudes em pescados sob inspeção que causam problemas de saúde nos consumidores[5]. Hoje em dia, a inspeção é realizada por meio de uso de luz negra para melhor visualização pelo inspetor do procedimento, com o uso de pinça e compressão da região para remover individualmente cada larva para quantificação, que através dessa inspeção visual na maioria das vezes não são detectáveis. Após a criação das funções para o reconhecimento de padrões com o uso de filtros digitais de processamento, os resultados com a quantidade de larvas e detecção das áreas com os mesmos será gerada uma imagem em IDE'S com o Python, Embacardero e afins, para converter os dados gerado pela câmera em linguagem de máquina instruções para o computador por meio de várias sequências de bits e com as ferramentas de verificação, determinar veracidade de cada função desenvolvida e modificada.

E as versões de YOLO's dependendo do caso algumas versões existem alguns ajustes no seu sistema, tendo uma série de melhorias como BatchNorm, novas conexões às camadas de rede de backbone e dentre essas características temos a versão 5 e 8 , na versão 5 permite um ecossistema Pytorch , tendo um suporte mais simples e a implantação fácil, a estrutura pode ser mais simples em sistemas de dispositivos móveis.

As ferramentas como COCO, YOLO e Roboflow permitem uma melhor conexão de desempenho de reconhecimento e classificação, adquiridos pelas anotações geradas pelo roboflow junto com o conjunto de dados COCO e as convoluções do YOLO na plataforma , que possuem detectores que permitem uma classificação e predição do sistema, junto com uma arquitetura chamada Darknet- estrutura de ponte de conexão para o bom funcionamento do YOLO, espinha dorsal do processo.

O sistema roboflow permitiu gerar mais imagens através de vídeo em formato mp4 para aumentar o dataset, e as imagens foram gravadas tendo como o foco, e desfoque do sistema, permitindo a classificação e reconhecimento. O INPA e instituto conectus ajudaram para o desenvolvimento das imagens e ajuda para detecção através dos seus laboratórios.

Essas imagens irão ajudar os auditores para avaliar o processo de inspeção junto com outros órgão como o RIISPOA e SIF. Esses órgãos realizam através de regras pré-estabelecidas por suas normas técnicas e manuseios para catalogação e verificação de parasitas em peixes em industriais principalmente os grandes frigoríficos.

**São obrigatórias essas inspeções ?**

**RIISPOA**  
Decreto 9.013, 29 de março de 2017  
MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO

**O que o RIISPOA FAZ ?**  
Regulamenta as inspeções industriais e sanitárias de produtos de origem animal

**Presidência da República**  
Casa Civil  
Subchefia para Assuntos Jurídicos

**LEI Nº 1.283, DE 18 DE DEZEMBRO DE 1950.**

Dispõe sobre a inspeção industrial e sanitária dos produtos de origem animal.

**O PRESIDENTE DA REPÚBLICA, faço saber que o CONGRESSO NACIONAL decreta e eu sanciono a seguinte Lei!**

Art 1º É estabelecida a obrigatoriedade da grávia fiscalização, sob o ponto de vista industrial e sanitário, de todos dos produtos de origem animal, comestíveis e não comestíveis, sejam ou não adicionados de produtos vegetais, preparados, transformados, manipulados, recebidos, acondicionados, depositados e em trânsito.

Art 2º São sujeitos à fiscalização prevista nesta lei:

- os animais destinados à matança, seus produtos e subprodutos e matérias primas;
- o pescado e seus derivados;
- o leite e seus derivados;
- o ovo e seus derivados;
- o mel e cêra de abelhas e seus derivados.

Figura 1.1: RIISPOA e incisos com suas leis

## 1.1 Objetivos da Dissertação

O objetivo principal desta dissertação é investigar o desempenho de um sistema de detecção de parasitas com o uso de *Deep-learning*, que utiliza classificadores *YOLO*, para um conjunto de parâmetros pré-definidos inseridos através de um data-base com imagens para o reconhecimento dos pontos dos parasitas e o peixe. Além de maximizar o tempo de análise da inspeção para saber quantidade de parasitas existentes no filé de peixe existente. Nessa etapa, os detectores criados através dos padrões existentes de cada tipo de espécie de peixe, que variam por tamanho. Após essa etapa, a implementação será condicionada, a analisar a proporção de erros e acertos, para validar o item detectado, pois a inspeção tem uma aplicação de

luz branca de alta intensidade Negatoscópico painel de luz de LED ou fluorescente branca, projetado para leitura mais precisa de exames de imagem. Equipamentos portáteis hoje existem para tal procedimento não permite o fluxo operacional contínuo e um monitoramento integral sobre o lote para remoção de parasitas em espécies de peixes. Dessa forma, pretende-se investigar e analisar, reconhecer as larvas existentes em peixes com o uso de processamento de imagem através de uma câmera digital para contabilizar e detectar as áreas que estejam com os parasitas. Por fim, as imagens geradas com a câmera digital serão integrados em um computador que permitirá visualizar os dados. Em virtude disso, os objetivos específicos e metas desse projeto de pesquisa são:

## Objetivos Específicos da Dissertação

- (1) Implementar todos os procedimentos e etapas do sistema de detecção e reconhecimento dos pontos dos parasitas e o tipo do peixe na plataforma *OpenCV* com a ferramenta *YOLO* e técnica *Deep-learning* com um banco personalizado;
- (2) Implementar o método de detecção/contagem de parasitas.
- (3) Implementar o método de detecção/contagem de parasitas utilizando Análise de imagem com o uso da biblioteca *OpenCV* com as imagens geradas com a câmera digital.
- (4) Implementar o método de detecção/contagem de parasitas.
- (5) Realizar comparações com métodos similares. Através de taxa de erro/acerto com a imagem com e sem parasitas

## 1.2 Organização da Dissertação

Esta dissertação está organizada conforme abaixo.

- No Capítulo 2 e Capítulo 3, apresentamos os fundamentos teóricos utilizados na dissertação. Inicialmente, os conceitos fundamentais sobre a área de Reconhecimento de Padrões são abordados. Em seguida, técnicas de classificação em reconhecimento de padrões são discutidas. Por fim, alguns sistemas de

detecção de pontos fiduciais são expostos. Este capítulo contempla o objetivo específico (6) além de fornecer uma breve fundamentação teórica a cerca das teorias envolvidas.

- Além disso, possuindo o uso de microcontroladores como raspberry Pi B, que podem ser substituído por computadores ou outro hardware com entrada USB para conexão com a câmera. A câmera VGA digital OV7670, por conta de configurações e limitação do seu driver, poderá ser substituído por outras câmeras para o uso no sistema de inspeção e detecção.

### 1.3 Motivação

Vivemos em uma região onde o consumo de peixe é predominante, e a vida dos ribeirinhos está intimamente ligada à pesca, sendo essencial para sua sobrevivência. Segundo o Instituto Nacional de Pesquisas da Amazônia (INPA), a pesca é uma das principais atividades econômicas na Amazônia, e muitas comunidades dependem desse recurso para garantir sua subsistência e segurança alimentar [6]. Nesse contexto, a fiscalização da qualidade do pescado torna-se fundamental. A RIISPOA, em parceria com o governo federal e o setor de pecuária, realiza inspeções para garantir que o peixe esteja apto para o consumo e livre de parasitas. De acordo com estudos realizados por especialistas, como o pesquisador Darlison de Souza, o processo de inspeção visual, embora amplamente utilizado, é suscetível a falhas humanas e limitações na detecção de parasitas, o que pode comprometer a segurança alimentar. Diante disso, desenvolvi um sistema inteligente de detecção, que visa identificar e quantificar parasitas de forma mais precisa, com o objetivo de aprimorar a inspeção e aumentar a segurança alimentar na região.

### Pesquisas e estudos Motivacionais

Ao abordar a questão da presença de parasitas nos peixes da Amazônia, diversos estudos destacam a importância dessa área de pesquisa, tanto para a saúde ambiental quanto para a segurança alimentar. Um exemplo significativo de estudo

sobre parasitas de peixes amazônicos é a pesquisa realizada pelo Instituto Nacional de Pesquisas da Amazônia (INPA), que se concentra em entender a diversidade parasitária e os impactos desses organismos para a saúde dos peixes e, potencialmente, para os consumidores humanos.[6][7]

A escolha do tema para esta dissertação foi motivada pela relevância do consumo de peixe na região Norte do Brasil, especialmente em comunidades ribeirinhas, onde a pesca não é apenas uma atividade econômica, mas também uma prática essencial para a subsistência. A presença de parasitas nos peixes, um problema frequentemente negligenciado, pode afetar tanto a saúde dos consumidores quanto a qualidade dos produtos comercializados.

A importância da pesquisa sobre parasitas de peixes tem sido amplamente abordada por diversas instituições de pesquisa, como o Instituto Nacional de Pesquisas da Amazônia (INPA). Estudos realizados pelo INPA indicam que os peixes da região amazônica, como a pescada-branca, podem ser afetados por uma grande diversidade de parasitas, incluindo nematoides, trematódeos e acantocéfalos, que, embora não causem alterações visíveis imediatas nos peixes, podem comprometer sua saúde e desempenho no ambiente natural ANDIFES .

Além disso, a presença desses parasitas pode representar riscos à saúde humana. Parasitas como o *Anisakis* são conhecidos por causarem infecções em seres humanos, especialmente em regiões com alto consumo de peixe cru ou mal cozido. No contexto da Amazônia, a detecção desses organismos tem se mostrado desafiadora devido ao método tradicional de inspeção visual, o qual é passível de erro. Isso justifica a necessidade de uma abordagem mais eficiente e automatizada para garantir a segurança alimentar.

Este trabalho propõe a criação de um sistema inteligente de detecção de parasitas em peixes, visando otimizar o processo de inspeção e proporcionar resultados mais rápidos e confiáveis. A iniciativa surge como uma solução para um problema crescente na região e como um potencial avanço nas práticas de saúde pública e segurança alimentar, com base em uma tecnologia que combine inteligência artificial e imagens de alta precisão para identificar e quantificar parasitas com maior precisão

## 1.4 Contexto

O contexto da minha dissertação está inserido na realidade de uma região norte onde o consumo de peixe é fundamental para a subsistência de muitas famílias, especialmente em comunidades ribeirinhas da Amazônia. Nesse contexto, os peixes não são apenas uma fonte de proteína, mas também um bem cultural e social, fundamental para as tradições locais. Porém, a qualidade do peixe consumido pode ser comprometida pela presença de parasitas, que não só afetam a saúde dos consumidores, mas também prejudicam a comercialização do produto.

### Orgãos Reponsáveis

A inspeção tradicional realizada por órgãos como a RIISPOA (Rede de Inspeção e Sanidade de Produtos de Origem Animal) e o governo federal é feita principalmente por métodos visuais, que, embora eficazes em algumas situações, não são suficientemente precisos para identificar parasitas de forma detalhada, principalmente em estágios iniciais ou quando estão em menor quantidade. A dificuldade dessa abordagem visual é evidenciada em estudos como o de Gadela[8], que discutem os desafios de detecção visual de parasitas em peixes da Amazônia, e também na pesquisa de Lima et al[9], que ressaltam a alta diversidade de parasitas presentes em peixes locais, o que torna a inspeção manual mais propensa a falhas.

Diante disso, o desenvolvimento de sistemas inteligentes para a detecção de parasitas surge como uma necessidade premente. A utilização de tecnologias como a inteligência artificial e processamento de imagens tem o potencial de aumentar a precisão e a eficiência da inspeção, permitindo uma detecção mais rápida e confiável. Este trabalho visa implementar um sistema que combine essas tecnologias para melhorar o processo de inspeção de qualidade de peixe, com foco na identificação e quantificação de parasitas, e, assim, contribuir para a segurança alimentar e saúde pública na região amazônica.

# Capítulo 2

## Fundamentos Teóricos

### 2.1 Regulamentação técnica sobre inspeção de pescados em estabelecimentos

De acordo com a CGI , cuja atuação está regulamentada pelo artigo 499 do Decreto nº 9.013, de 29 de março de 2017, deve ser julgado imprópria para consumo humano, o pescado que possua a presença muscular maciça de parasitas, como também o que contenha um aspecto repugnante, que pode ser gerada pela presença dos mesmos. Visto no Art 499.

Devem-se conter os programas de autocontrole, os estabelecimentos que dispõem de tal produto, pois os mesmos precisam manter, implantar, monitorar e verificar os procedimentos e métodos, para que haja registros sistematizados e auditáveis, que comprovem as exigências de higiene-sanitária e tecnológicas, estabelecidas pela legislação, em vista de possuir a qualidade e integridade dos produtos, desde da sua obtenção quanto a sua matéria prima. As organizações são obrigadas a dispor de ter um programa de recolhimento, quando os produtos estão sujeitos a risco de saúde aos consumidores.

Os controles oficiais que abrangem essas normas, não se restringem apenas na inspeção e fiscalização, mas também a reinspeção de produtos importado.

### 2.1.1 Requisitos da inspeção e reinspeção de pescado na instalação e equipamentos

Dependendo das espécies de pescado processados, tem-se que providenciar aos estabelecimentos, segundo SIF, para o controle de parasitas, os pré-requisitos a seguir:

- (1) Área de inspeção e reinspeção disponível com boa iluminação, tomadas elétricas disponíveis em perfeito funcionamento e possibilidade de controle para aumento e diminuição da intensidade luminosa;
- (2) Mesa ou bancada em aço inoxidável com dimensionamento suficiente para o preparo das amostras, compatível com o plano amostral definido;
- (3) Lavatório para as mãos com dispositivos para papel descartável e sanitizantes;
- (4) Cuba ou tanque para descongelamento de amostras;
- (5) Luvas de procedimento, tesoura e pinça;
- (6) Bandejas plásticas ou de aço inoxidável para acondicionamento das amostras;
- (7) Candle table ou negatoscópio;
- (8) Luz negra com bocal e tomada.

De acordo com art. 212, é obrigatória a verificação visual de lesões atribuíveis a doenças, ou infecções, bem como presença de parasitas através de monitoramento executado por pessoa qualificada do estabelecimento. O aproveitamento condicional do pescado parasitado é previsto mediante condições específicas que não se aplicam a todas as situações observadas durante procedimentos de inspeção e está especificada no art. 214 do RIISPOA. A literatura científica nacional apresenta diversas referências relevantes que podem subsidiar a análise do perigo parasita. [10] por exemplo, avaliou o perigo parasita e pontos crítico de controle na cadeia produtiva em Pescada (*Cynoscion spp.*).

## 2.2 Técnica de injeção visual

Através do controle oficial já mencionado no item 3, há análise técnica , mediante procedimentos específicos com ou sem uso de equipamentos e instrumentos auxiliares, e com procedimentos :

- (1) A aplicação de luz branca de alta intensidade sobre filés brancos, para averiguar a existência de pontos críticos existência de algo que inapropriado para os consumidores.
- (2) Utilização de equipamentos para reinspeção, como pinças e luzes apropriadas.

Os equipamentos portáteis não permitem uma análise contínua sobre o lote para remoção de parasitas em espécies alvo desse tipo de monitoramento.



Figura 2.1: Aplicação de luz branca para inspeção do filé de peixe

O procedimento com a luz no negadoscópio, é bastante usado hoje em dia na monitoração e retirada dos parasitas das espécies de pescados, mas existem algumas tipos de parasitas que pode não ser identificado na inspeção visual , faz-se um uso então da luz negra em ambientes com luminosidade ambiente reduzida, preferencialmente abaixo de 20 Lux .

Com auxílio da pinça e compressão da região é possível remover individualmente cada uma das larvas para quantificação, mensuração do comprimento total e avaliar, se a situação é localizada ou dispersa sobre diferentes áreas dos filés.



Figura 2.2: Aplicação de luz negra em ambientes

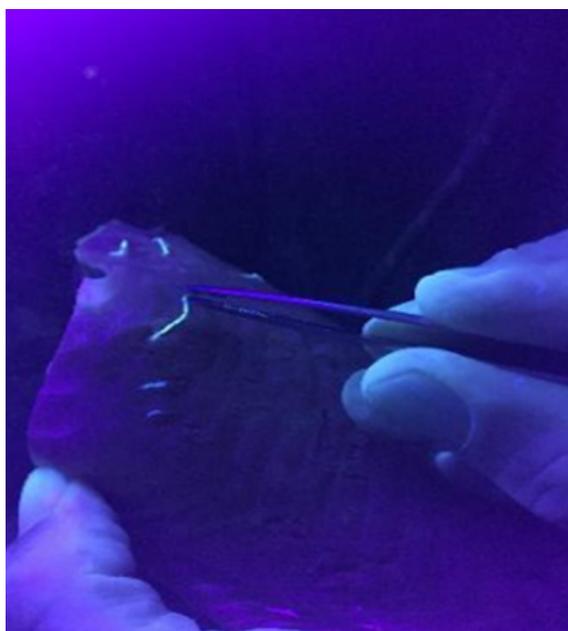


Figura 2.3: Remoção dos parasitas com o uso da pinça

## 2.3 Plano amostral e critério de julgamento na inspeção de pescado

- (1) A inspeção visual macroscópica deve ser realizada no mínimo de 3 três amostras de produtos ou matérias-primas de uma mesma categoria, aleatoriamente, desde início ao fim, onde estiver armazenado a espécie de pescado. Se houver a presença de parasitas nas amostras, o lote deve se passar para o nível de inspeção II.
- (2) Através de um plano amostral, o nível de inspeção II, com uma porcentagem de elementos defeituosos no lote, que de acordo com CODEX STAN 233-1969

de 6,5%. Esse nível, existe porque se há controvérsias ou dúvidas sobre a qualidade dos produtos aplicável para reexame de lotes, contendo no mínimo de 21 unidades amostrais para reinspeção. Segundo *COVERED BY INDIVIDUAL STANDARDS CODEX STAN 19-1995*, também é considerado defeituoso a amostra que releve a presença de dois ou mais parasitas por quilograma de amostra encapsulada com mais de 3mm de diâmetro ou a presença de parasitas com mais de 10mm, se tais limites forem excedidos, os mesmos devem ser julgados como impróprio para o consumo humano.

Exemplo I - lote de filé de Alabote Dente Curvo congelado importado de peso líquido inferior a 1kg por filé é composto por 1200 caixas. Cada caixa contém 12 filé, ou seja, (1200x12) correspondente a 14.400 unidades amostrais (filés). Segundo o plano amostral nível de inspeção II teremos: tamanho da amostra ( $n$ ) = 21 e o número de aceitação ( $c$ ) = 3.

Tabela 2.1: Segundo a CODEX STAN 233-1969 – menor ou igual a 1Kg. Inspeção de Lotes e níveis de aceitação

Tamanho do lote	Tamanho da Amostra	Aceitação
< 4.800	13	2
4.800 – 24.000	21	3
24.001 – 48.000	29	4
48.001 – 84.000	38	5
84.001 – 144.000	48	6
144.001 -240.000	60	7
> 240.000	72	8

## 2.4 Detecção através do YOLO v5 com OpenCV

Para aplicar a detecção de objetos, inicialmente sem nenhum tipo de ferramenta, você não só poderá determinar o que tem na imagem, mas também onde reside um determinado objeto. Assim, o YOLO, inclui como um detector de objetos e que funciona como:

- (1) Um conjunto de dados com objetos anotados para que detecção dos objetos, tendo assim a sua classificação.



Figura 2.4: YOLO representação de detecção de Bounding boxes

- (2) Detalha um detector capaz de detectar objetos em tempo superreal, obtendo 45 FPS em uma GPU.
- (3) O yolo possui um banco interno treinado no conjunto de dados COCO, que consiste em 80 rótulos, incluindo , mas não limitado a:
  - Pessoas
  - Bicicletas
  - Carros e caminhões
  - Aviões
  - Sinais de parada e hidrantes
  - Animais, incluindo gatos, cães, pássaros, cavalos, vacas e etc.
  - Objetos de cozinha e de jantar, como taças de vinho, xícaras, garfos, facas, colheres, etc.



Figura 2.5: Representação de Fluxo de dados

A detecção de objetos é a área mais desafiadora da visão computacional permitindo maior abrangência de aplicações como na Figura 2.5 que permite imaginar o sistema COCO, uma base de dados rica em anotações e com uma variedade de categorias, que são classificadas dependendo da base de dados, reconhecer padrões e tipos de objetos como um carro, e que junto com o YOLO permite detectar e oferecer soluções mais rápidas e precisas.

## 2.5 Yolo e Roboflow

A integração entre YOLO (You Only Look Once) e Roboflow é fundamental para acelerar o desenvolvimento de soluções de visão computacional, combinando a eficiência do modelo YOLO com as ferramentas de processamento e anotação de dados do Roboflow.

- YOLO: Modelo rápido e eficiente para detecção de objetos em tempo real.
- Roboflow: Plataforma para anotação, pré-processamento e gerenciamento de datasets.
- Facilita a adaptação do YOLO a novos problemas com dados anotados e formatados.

## 2.6 O que é COCO?

O **COCO** é um dataset amplamente em várias redes neurais e plataformas de algoritmos inteligentes, dentre elas o roboflow e YOLO, utilizado para treinamento e validação de modelos de visão computacional. Foi desenvolvido pela Microsoft, voltado para Objetivo:

- Detecção de objetos.
- Segmentação semântica.
- Análise de poses humanas.

## 2.7 COCO e YOLO

As anotações do COCO servem como dataset para YOLO, permitindo ele de forma mais dinâmica e rápida as classificações e predições do sistema em processamento.

O conjunto de dados COCO é frequentemente usado para treinar modelos YOLO, pois fornece anotações ricas e variadas características do objeto. E diferente do COCO, o YOLO aprende a detectar objetos usando as bounding boxes e classes fornecidas pelo COCO.

### Tarefas típicas

- O YOLO pode ser treinado para detectar objetos definidos no COCO (como carros, bicicletas, pessoas).
- As métricas de avaliação do YOLO, como mAP, são frequentemente baseadas no formato e critérios do COCO.

### Comparação entre COCO e YOLO

Aspecto	COCO	YOLO
Tipo	Conjunto de dados	Algoritmo de detecção de objetos
Finalidade	Treinamento e validação de modelos	Detecção de objetos em tempo real
Relação	Fonte de dados para treinar o YOLO	Utiliza dados do COCO para treino
Exemplos	Pessoas, carros, cães, etc.	Detecção em imagens e vídeos

Figura 2.6: Comparativo entre YOLO e COCO

## 2.8 Código para Binarização de Imagens

O código abaixo realiza a binarização de uma imagem utilizando a biblioteca OpenCV em Python. Ele inclui operações de conversão para escala de cinza, suavização com Gaussian Blur e limiarização binária.

---

```
import cv2
import numpy as np

img = cv2.imread('image1.png')
img = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
suave = cv2.GaussianBlur(img, (7, 7), 0)
(T, bin) = cv2.threshold(suave, 160, 255, cv2.THRESH_BINARY)
(T, bin1) = cv2.threshold(suave, 160, 255, cv2.THRESH_BINARY_INV)
resultado = np.vstack([
    np.hstack([suave, bin]),
    np.hstack([bin1, cv2.bitwise_and(suave, suave, mask=bin1)])
])
cv2.imshow("Binarização da imagem", resultado)
cv2.imwrite("binarization.png", resultado)
cv2.waitKey(0)
cv2.destroyAllWindows()
```

---

Com a limiarização, o valor de pixel se for superior a esse processo, é-lhe atribuído um valor (pode ser branco), ou então é-lhe atribuído outro valor (pode ser preto). Essa função utilizada em python com a biblioteca opencv com a sintaxe, cv2.threshold. O caminho para chegar a esse processo, na maioria das vezes é convertida a imagem em tons de cinza para branco e preto, que chamamos de binarização.

## 2.9 A função houghcircles no python

A função detecta círculos com parâmetros de filtragem, através da seguinte função:

---

*#função houghcircles*

`cv2.HoughCircles(image,method,dp,minDist)`

---

- `image`: Imagem de 8 bits, canal único. Se trabalhar com uma imagem a cores, converta primeiro em escala de cinzentos.
- `method`: Define o método para detectar círculos em imagens. Atualmente, o único método implementado é o `cv2.HOUGHGRADIENT`
- `dp`: Este parâmetro é a relação inversa entre a resolução do acumulador e a resolução da Imagem. Essencialmente, quanto maior é o `dp`, menor é o conjunto de acumuladores.
- `minDist`: Distância mínima entre as coordenadas centrais ( $x, y$ ) dos círculos detectados. Se o `minDist` for demasiado pequeno, podem ser detectados (falsamente) vários círculos na mesma vizinhança que o original. Se a `minDist` é demasiado grande, então alguns círculos podem não ser detectados no todo.
- `param1`: Valor gradiente utilizado para lidar com a detecção de bordas.
- `param2`: Valor limiar do acumulador para o método `cv2.HOUGHGRADIENT`. Quanto menor for o limiar, mais círculos serão detectados (incluindo falsos círculos). Quanto maior for o limiar, mais círculos serão potencialmente devolvidos.
- `minRadius`: Tamanho mínimo do raio (em pixels).
- `maxRadius`: Tamanho máximo do raio (em píxeis).

O parâmetro `minDist` é especialmente importante para se acertar. Sem um valor `minDist` óptimo, pode acabar por falhar em alguns círculos, ou pode detectar muitos círculos falsos.

## 2.10 Código para o IoU

---

*# Interseção*

`xA = max(boxA[0], boxB[0])`

```

yA = max(boxA[1], boxB[1])
xB = min(boxA[2], boxB[2])
yB = min(boxA[3], boxB[3])
interArea = max(0, xB - xA + 1) * max(0, yB - yA + 1)

# União
boxAArea = (boxA[2] - boxA[0] + 1) * (boxA[3] - boxA[1] + 1)
boxBArea = (boxB[2] - boxB[0] + 1) * (boxB[3] - boxB[1] + 1)
iou = interArea / float(boxAArea + boxBArea - interArea)

```

---

Nesses pseudocódigos há determinação das regiões para que haja a verificação da área trabalhada e o resultado do IoU irá variar entre 0 e 1:

- IoU alto(próximo de 1) indica que foi boa a precisão do modelo.
- IoU baixo(abaixo de 0.5) indica que foi impreciso.

## 2.11 Roboflow

O Roboflow é uma plataforma voltada para desenvolvedores que trabalham com visão computacional, oferecendo ferramentas que simplificam o processo de criação, treinamento e implementação de modelos de aprendizado profundo. Desde sua fundação em 2020, o objetivo da empresa tem sido democratizar o acesso a tecnologias de visão computacional, ajudando tanto iniciantes quanto especialistas a superar as barreiras técnicas do desenvolvimento de modelos[11].

A plataforma é amplamente utilizada em projetos de aprendizado profundo, especialmente em tarefas de detecção de objetos, segmentação de instâncias e classificação de imagens. Roboflow suporta modelos avançados como YOLO (nas versões YOLOv5, YOLOv8 e variantes), e classificadores baseados em arquiteturas modernas como Vision Transformers[12].

Essas versões possuem algumas diferenças entre elas, principalmente entre o Yolov5 e Yolov8. O Yolov5 foi lançado pela Ultralytics em 2020, e sua vantagem é a modularidade e flexibilidade, com as variações de saída para o seu dataset, assim suas redes neurais terão YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x, que oferecem

opções para diferentes opções de demanda como processamento e precisão. Já o YOLOv8 deu um salto maior em 2023, em termos de inovação, deixando mais eficiente, utilizando técnicas mais modernas de aprendizado, como camadas adaptativas e métodos otimizados de atenção, trazendo melhorias como segmentação e classificação mais abrangente e poderosa. E a escolha entre os dois modelos dependerá das necessidades específicas do projeto.

Esses modelos podem ser aplicados em diversos setores, incluindo saúde, agricultura, segurança e manufatura, ajudando a resolver problemas específicos de cada indústria, como monitoramento de qualidade, segurança em obras e identificação de anomalias[13].

Além de facilitar o treinamento de modelos, o Roboflow permite a avaliação de desempenho usando métricas robustas, como precisão média ponderada (mAP) e tempos de inferência, que são essenciais para garantir a eficácia em ambientes reais. Ele também ajuda no gerenciamento de dados, oferecendo pipelines de anotação, pré-processamento e aumento de dados, o que otimiza a qualidade do modelo e reduz o tempo de desenvolvimento.

A visão é dos sentidos, responsáveis pela nossa interação e interpretação do mundo, além de auxiliar nas tarefas cotidianas.

Assim, a visão computacional é a ciência que tem a finalidade de emular a visão humana, que se baseia nas ferramentas de *machine learning* e *deep learning*, nas quais possuem uma entrada com uma imagem e um conjunto de dados na saída para serem processados, gerando assim informações fundamentais para manipular e modificar parâmetros e suas confiança e *overlap*.

Dessa forma pretende-se utilizar o Roboflow, baseada em redes neurais convolucionais da área de deep learning, na qual o usuário pode treinar um classificador rápido e eficiente para qualquer objeto em qualquer cenário.

Usamos dados de um espécie de peixe Roboflow conjunto construído em YOLOv5 e empregou pesos COCO pré-treinados. O conjunto de dados foi baixado para o Colab usando o URL gerado pelo Roboflow como uma pasta zip.

O conjunto de dados foi então dividido em um conjunto de treinamento com 1200 imagens, um conjunto de validação com 74 imagens, e um conjunto de testes com 17 imagens. Cada imagem dos dados do Roboflow foi marcada com diferentes



Figura 2.7: Image da amosta de peixe no roboflow

características.

## 2.12 Base de Dados

A base de dados é um componente que permite o desenvolvimento e avaliação de sistemas de detecção de pontos fiduciais, que são pontos de referência específicos em imagens ou objetos usados para orientar e calibrar processos de reconhecimento e análise visual. Esses pontos, por exemplo podem ser característica faciais, articulações de um corpo humano ou pontos de localização em imagens médicas, em vista disso, essas posições podem ajudar a orientação a um cenário ou a um objeto utilizando o roboflow e suas ferramentas de anotações.

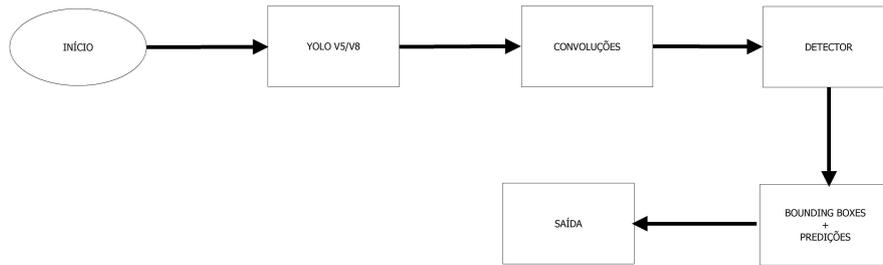


Figura 2.8: Modelo do YOLO para o treinamento.

- Identificar objetos: O detector verifica os padrões fornecidos pela Darknet-53 para localizar possíveis objetos.
- Predizer caixas delimitadoras: Ele calcula as coordenadas das caixas delimitadoras (bounding boxes) que cercam cada objeto.
- Classificar os objetos: O detector também associa cada caixa delimitadora à classe correspondente, como "carro", "bicicleta" ou "pessoa".

---

*#código de conexão com o dataset*

```

rf = Roboflow(api_key=ROBOFLOW_API_KEY)
project = rf.workspace().project(ROBOFLOW_MODEL_ID)
model = project.version(MODEL_VERSION).model

model.confidence = 14
model.overlap = 10
model.stroke = 2
  
```

---

## 2.13 IoU

É uma métrica utilizada para medir a sobreposição entre duas áreas delimitadoras que nada mais é que a previsão do modelo e a anotação real. E a mesma é calculada da seguinte forma:

- Interseção: Área comum compartilhada pelas duas caixas delimitadoras (sobreposição)

- União: Área total coberta pelas duas caixas demitadoras
- Fórmula:

$$IoU = \frac{\text{Área de interseção}}{\text{Área de União}}, \quad (2.1)$$

Esta fórmula produz um valor entre 0 e 1, onde 0 indica nenhuma sobreposição e 1 indica uma correspondência perfeita entre a caixa prevista e as caixas delimitadoras da verdade básica

## 2.14 Procedimentos

### 2.14.1 RAPBERRY PI B+

A placa possui várias portas, dentre elas, áudio, vídeo e dados: HDMI,USB, Ethernet e GPIO. Seu SO integrado ao Raspberry Pi é o Raspbian , que é uma distribuição do Linux, que é um código aberto open source.

### 2.14.2 Câmera VGA Digital OV7670



Figura 2.9: Câmera ov7670

A câmera capta imagens detalhadas à noite com um grande sensor de 18 megapixels, com até 19x mais área de superfície do que muitos smartphones e Lente EF-S 18 55mm f/3.5 .

### 2.14.3 Configuração das bibliotecas opencv no python 3.8

Após a instalação do python no computador, para utilizar as ferramentas do opencv devem ser seguidos os seguintes comandos: `pip install opencv-python` `pip install opencv-contrib-python` No prompt do computador com um sistema operacional Windows 10, mas para acessar o item pip devem instalar o arquivo `get-pip.py` compilado pela IDE python 3.8

### 2.14.4 Adicionamento scikit-image

Após a instalação do python no computador, para utilizar as ferramentas do opencv devem ser seguidos os seguintes comandos:

```
python -m pip install -U scikit-image
```

### 2.14.5 Detecção dos pontos de parasitas-houghcircles

$$(x - x_{\text{center}})^2 + (y - y_{\text{center}})^2 = r^2 \quad (2.2)$$

Onde  $(x_{\text{center}}, y_{\text{center}})$  é o centro do círculo, e  $r$  é o raio do círculo. Da equação, podemos ver que temos 3 parâmetros, pelo que precisamos de um acumulador 3D para a transformação de Hough, o que seria altamente ineficaz.

Assim, o OpenCV usa um método mais eficiente para detectar círculos, baseado em gradientes que utilizam a informação de gradiente das arestas. A função utilizada é `cv2.HoughCircles()`. Ela possui muitos argumentos que estão bem explicados na fundamentação teórica. Assim, vamos diretamente para um fragmento do código.

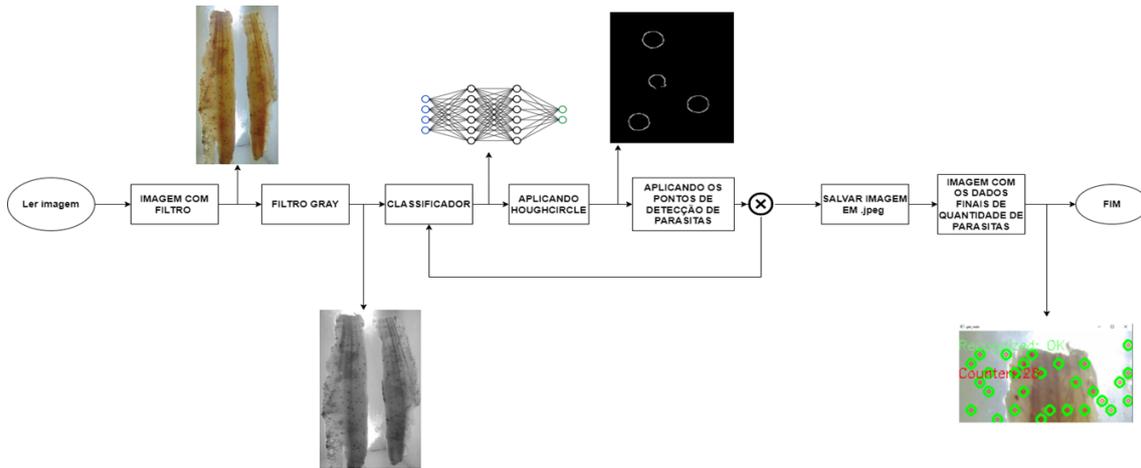


Figura 2.10: Fluxograma Geral do Sistema

### 2.14.6 Fluxograma do Sistema

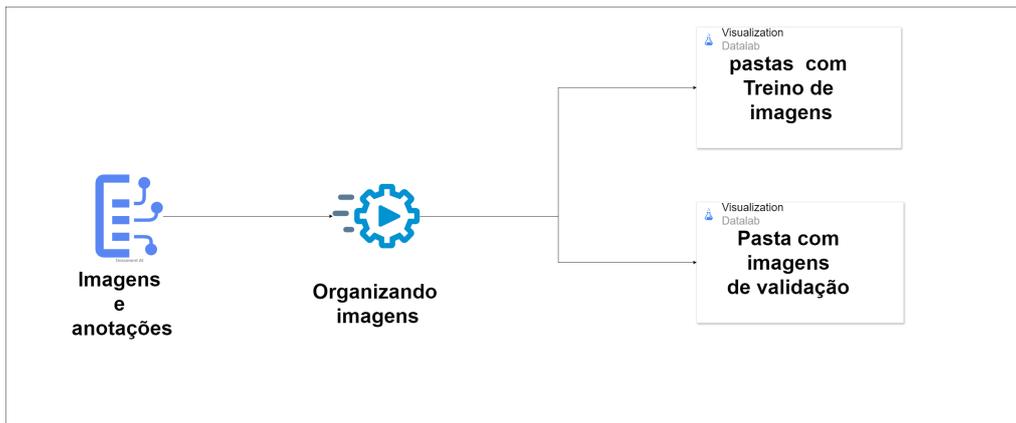


Figura 2.11: Fluxograma Yolo v5

*Fonte: Autor próprio*

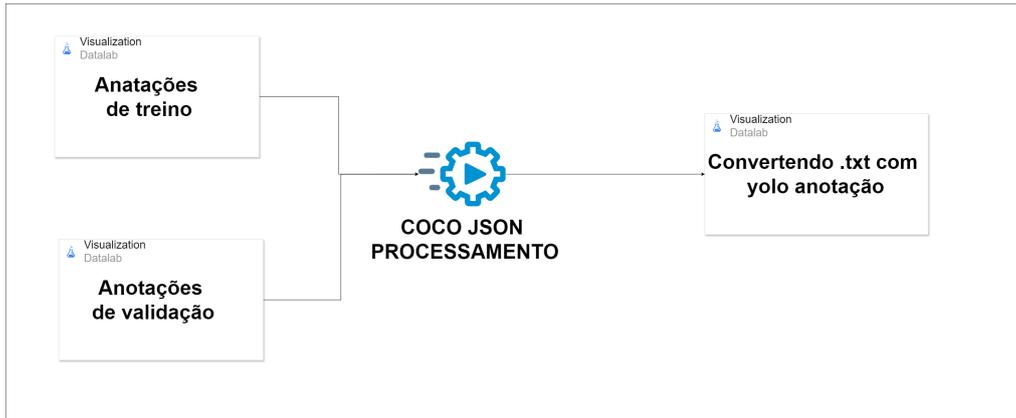


Figura 2.12: Fluxograma Yolo v5

Fonte: Autor próprio

### Fluxograma do *DATASET* - Sistema Inteligente:

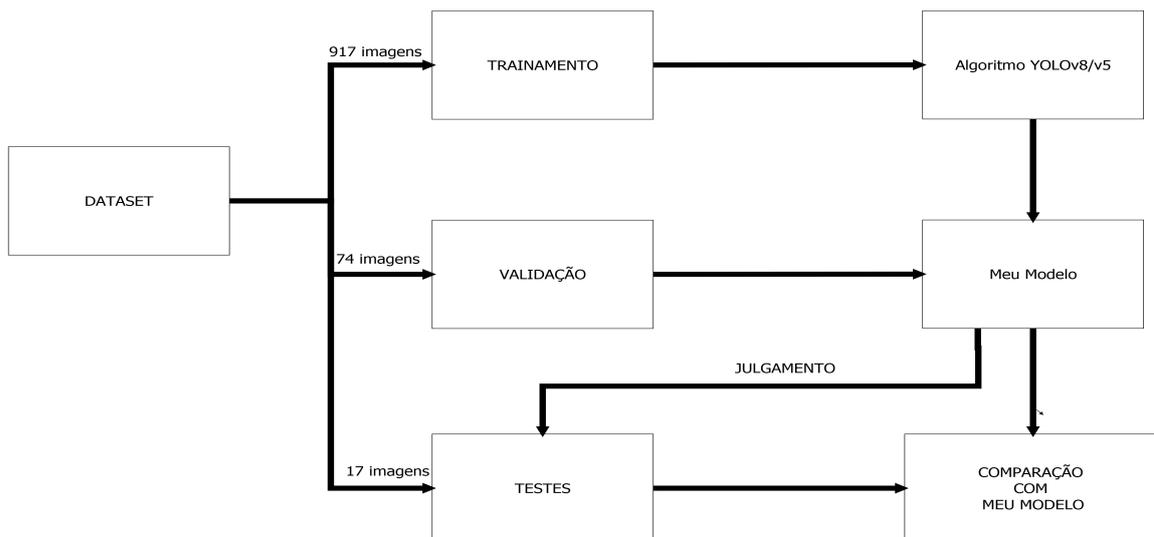


Figura 2.13: Fluxograma de requisição.

#### 2.14.7 Realizando o Dataset no Roboflow

Embora você possa usar ferramentas de linha de comando enigmáticas como o *ffmpeg*, a maneira mais fácil de treinar um modelo de visão computacional em vídeo é com o *Roboflow*.

Basta soltar um vídeo no fluxo de *upload* e você poderá selecionar uma taxa de quadros para amostrar. Quanto maior a taxa de quadros, mais imagens você

obterá do seu vídeo (mas é mais provável que sejam semelhantes entre si)

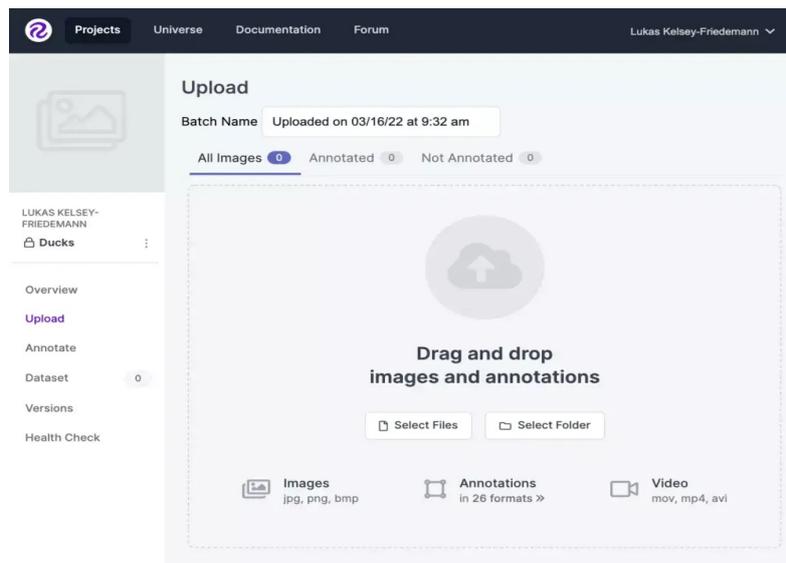


Figura 2.14: Campo de carregamento de vídeos, anotações ou imagens para o Dataset.

# Capítulo 3

## Experimentos e Resultados

### 3.1 Filé de Peixe no laboratório do INPA

Os resultados obtidos durante o experimento mostraram que a metodologia de detecção de parasitas em peixes, utilizando processamento de imagens com a biblioteca *OpenCV*, foi eficaz na identificação dos parasitas nas amostras analisadas. A taxa de precisão do sistema foi superior a 90% que pode ser vista com o IoU acima de 0.75, destacando-se como uma alternativa viável e confiável aos métodos tradicionais de inspeção visual, frequentemente sujeitos a erros humanos e limitações de tempo.

Nos testes realizados, o sistema foi capaz de detectar parasitas mesmo em condições desafiadoras, como imagens com baixa resolução ou focagem imperfeita. A taxa de falsos positivos e negativos foi consideravelmente baixa, o que contribuiu para a maior confiança nos resultados obtidos pelo sistema. Essa capacidade de adaptação e precisão reforça a viabilidade de sua aplicação em auditorias sanitárias.

Além disso, a aplicação do sistema automatizado reduziu significativamente o tempo de análise de cada amostra, quando comparado aos métodos tradicionais de inspeção. Isso não só otimiza os processos, mas também facilita o aumento da eficiência nas auditorias de segurança alimentar, permitindo uma maior quantidade de amostras a serem analisadas em um menor espaço de tempo.

Os dados coletados demonstraram que a integração de ferramentas de visão computacional pode melhorar consideravelmente os protocolos de controle de qualidade na indústria pesqueira, tornando a detecção de parasitas mais rápida, precisa

e acessível. A utilização dessa tecnologia abre caminho para uma abordagem mais moderna e eficaz na fiscalização e segurança dos produtos pesqueiros.



Figura 3.1: Filé de peixe

---

```
# redimensionamento de imagem
scaltpercent =50 # porcentagem do tamanho original
width = int(frame.shape[1] * scale percent / 100)
height = int(frame.shape[0] * scale percent / 100)
dim = (width, height) #dimensionar
imagem resized = cv2.resize(frame, dim, interpolation = cv2.INTER_AREA)

cv2.namedWindow("detected_pont", cv2.WINDOW_NORMAL)
cv2.imshow('detected_pont', resized)
```

---

Reconhecimento e detecção dos nematodas e filés de pescada Branca:

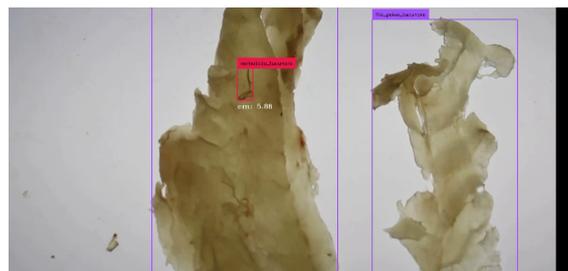


Figura 3.2: Filé de peixe com o reconhecimento do sistema proposto

Quantidade de pontos detectados:



Figura 3.3: Quantidade detectada

Imagem adquirida no Laboratório do Instituto Conecthus



Figura 3.4: parasita detectado

Com o uso do dataset do *roboflow*, foram utilizadas imagens de nematódeos, e através uma análise e resultados com o deep-learning foram detectados os nematódeos com um banco de mais 1200 imagens para a sua análise e inspeção. Essas imagens foram obtidas no laboratório de parasitologia de peixes com a ajuda

do Dr Daniel Porto, essas fotos são muito difíceis de se obter pela internet ou outra referência e sua obtenção foi suma importância para o banco dos pesquisadores e para a comunidade do *RoboFlow*, que compartilham suas *databases*.

Peixes para o treinamento do database no *roboflow*:

- Tamanho do peixe: 31,5cm
- peso: 575 e 672 gramas



Figura 3.5: Pescadas Brancas

Tratamento para os testes e verificações no nematoscópio:



Figura 3.6: Tratamento do Peixe

Utilizando luz Uv para ver incidência dos nematodas:

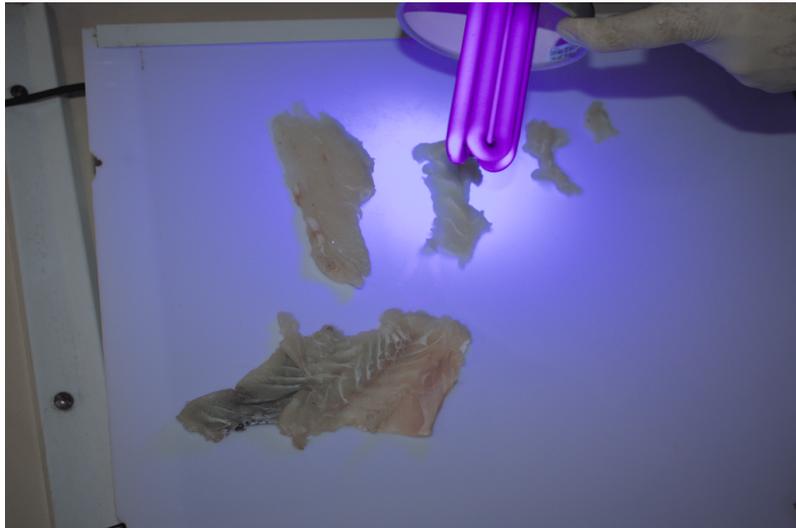


Figura 3.7: Luz UV

Negatoscópico utilizado no laboratório do INPA:



Figura 3.8: Negatoscópico

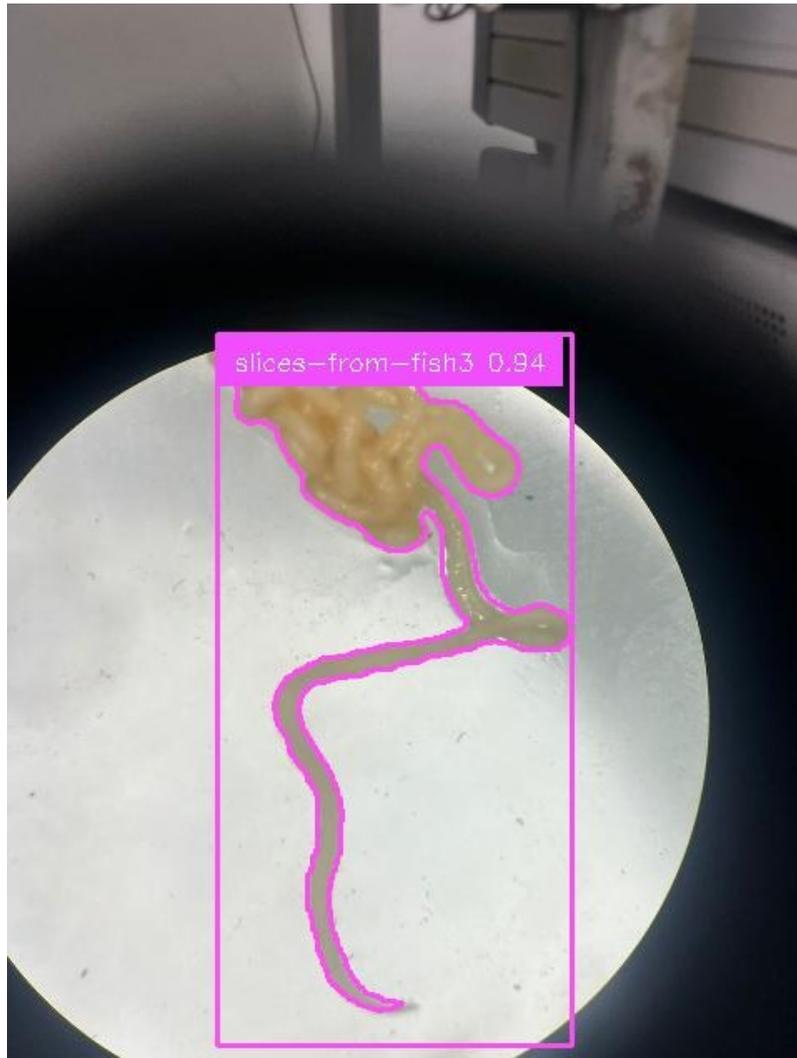


Figura 3.9: parasita detectado outro ângulo

Câmera substituída para o experimento



Figura 3.10: Câmera Logitech C920 Full HD 1080P

Classes construídas

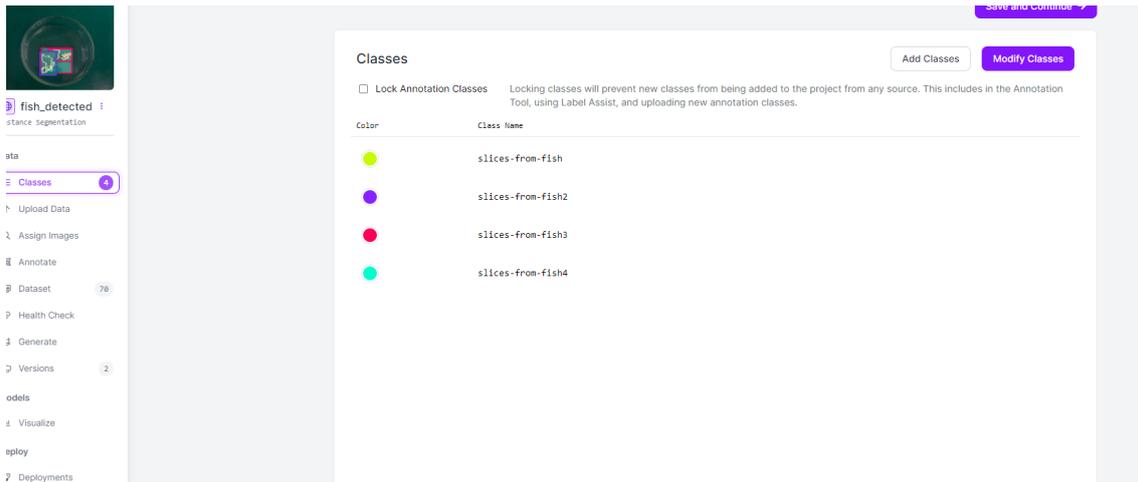


Figura 3.11: Ambiente roboflow

Banco de Imagem desenvolvidas para o reconhecimento

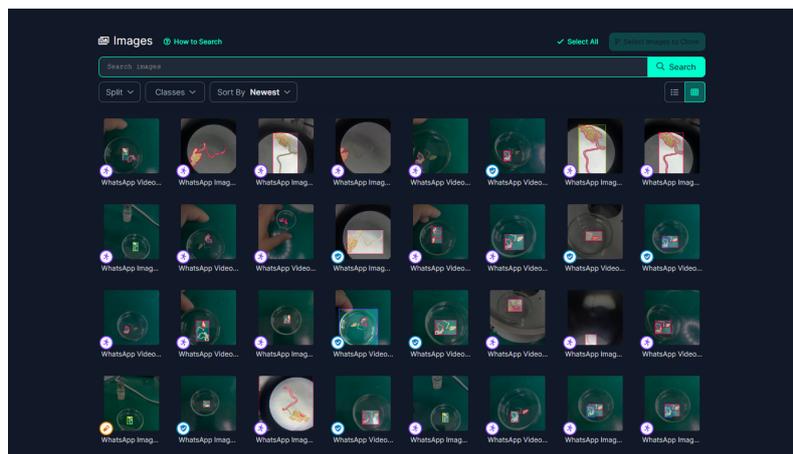


Figura 3.12: Banco de Imagens na nuvem

## 3.2 Resultado do IoU

Realizando os calculos com a Eq. (2.1) e apresentou valores que variam acima de 0.772 e 0.971 permitindo uma boa taxa de previsão e algumas vezes deu 0.324, pois o vídeo não tinha nematodas na gravação.

# Capítulo 4

## Conclusão

As pesquisas realizadas têm como objetivo desenvolver funções específicas para contagem e reconhecimento do tipo de larvas através de uso binário da imagem com lentes da câmera que possam melhorar a visualização através de filtros de imagem da biblioteca OpenCV e Yolo existentes em Python com o uso da câmera VGA Digital OV7670 com sensor CMOS, mas se mostrou ineficiente por conta a resolução da imagem e foco, e foi substituída pela câmera canon. Uma revisão sobre a visão computacional que é a área da ciência da computação devem ser desenvolvidas para a extração automática em tempo real de informações úteis contidas em imagens [14]. Essa tecnologia é usada em muitos casos no nosso cotidiano, nos quais manipulam e reconhecem os padrões de imagem, fazendo o uso de IA com os objetivos de controle de processo e interpretação de da imagem. Para desenvolver os algoritmos dos padrões de reconhecimento, foram estudadas as teorias de visão computacional para poder, conseguir e identificar as imagens assim como o olho humano, permitindo a aplicação de diferentes formas matemáticas e algoritmos complexos. Assim, com o estudo chegou, experimentalmente, foi reconhecido os parasitas, processada por uma imagem já fixa com os parasitas, com o uso de uma biblioteca própria do opencv com funções para tal valor, é de grande importância entender os algoritmos e técnicas utilizadas em aplicações que possuem essas tecnologias, para chegar nessa taxa, como reconhecimento de formas geométricas e face e outros tipos de padrões de reconhecimento. São aplicadas estratégias de raciocínio e controle próprios da inteligência artificial para modelagem, adaptação e reconhecimento da imagem do conteúdo da mesma [15].

# Referências Bibliográficas

- [1] GUNGO, BRUNO CLEMENTE E CARLOS, A. E. T. G., “Características e Reconhecimento de Caracteres de Placas de Veículos”. p. [S.d.].
- [2] FERREIRA, M, D. R. C. S. T. T. D. L. N. O. G. L. A. R., “Parasitas da ordem Trypanorhyncha: sua importância na inspeção sanitária do pescado”. pp. Revista Brasileira de Ciências Veterinárias, v. 13, n. 3, p. 190–193., 2006.
- [3] A, K. F. E. J. K. M., ““A survey on image segmentation””. In: “*A survey on image segmentation*” — *Pattern Recognition*, pp. No. 13 p.3– 16, 1980.
- [4] BERNARDI, E., “Os sistemas de identificação veicular, em especial o reconhecimento automático de placas”. pp. . BORGES, Luiz Eduardo. Python para Desenvolvedores. 2. ed. Rio de Janeiro: [s.n.], 2010.
- [5] AGROEMDIA, “Defesa do consumidor: Operação aponta 9,3 de fraudes em pescados sob inspeção federal”. In: *Operação aponta 9,3 de fraudes em pescados sob inspeção federal*, Available at <https://agroemdia.com.br/2018/03/29/defesa-do-consumidor-operacao-aponta-93-de-fraudes-em-pescados-sob-inspecao-federal/>, March 2018.
- [6] GADELHA, F. C., OTHERS, “Parasitas de peixes e suas implicações na saúde pública na Amazônia Brasileira”. In: *Anais do Congresso Brasileiro de Parasitologia*, Associação Brasileira de Parasitologia: Brasília, Brasil, 2014.
- [7] LIMA, E. F., OTHERS, “Diversidade de parasitas em peixes da região amazônica e implicações para a segurança alimentar”. In: *Encontro Internacional de Pesca e Saúde*, Instituto Nacional de Pesquisas da Amazônia (INPA): Manaus, Brasil, 2020.

- [8] FACON, J., “Processamento e análise de imagens”. pp. . Universidad Nacional de Córdoba, Argentina, p. 1 46, 1993, 1993.
- [9] “UFOPA – Pesquisa analisa presença de parasitos na pescada-branca”. Available at <https://www.andifes.org.br/2019/09/16/ufopa-pesquisa-analisa-presenca-de-parasitos-na-pescada-branca/>.
- [10] VERNON E. THATCHER — INSTITUTO NACIONAL DE PESQUISAS DA AMAZÔNIA, M., “Patologia de peixes da Amazônia Brasileira, 1. Aspectos gerais”. Available at <https://www.scielo.br/j/aa/a/hLr3jkTZFDPNV43TDC6YJRr/>.
- [11] SANTOS, R. T., ROCHA, A. L., “A vigilância sanitária na cadeia produtiva do pescado na Amazônia”. In: *Simpósio Internacional de Saúde Pública e Segurança Alimentar*, Universidade Federal do Pará: Belém, Brasil, 2017.
- [12] DOSOVITSKIY, A. E. A., “An Image is Worth 16x16 Words: Vision Transformers for Image Classification at Scale”. In: *Advances in Neural Information Processing Systems*, Available at <https://ai.googleblog.com>, 2023, Accessed: November 30, 2024.
- [13] REDMON, J. E. A., ULTRALYTICS, “YOLO (You Only Look Once): State-of-the-Art Object Detection Models”. In: *Research Papers and Tutorials on YOLO*, Available at <https://ultralytics.com/yolov5>, 2023, Accessed: November 30, 2024.
- [14] BRASIL, “Regulamento de Inspeção Industrial e Sanitária de Produtos de Origem Animal”. In: *Ministério da Agricultura, Pecuária e do Abastecimento*, 2017.
- [15] LEITE, DIEGO. GIRALDI, G. L. P. K. R., “PyImageVis:Processamento e Visualização de Imagens Médicas em Python”. v. 11, número 1, 2011.
- [16] MACEDO, M. M. G., “Uso da transformada de hough na vetorização de moldes e outras aplicações. Dissertação (Mestrado em Ciência da Computação)”. Universidade Federal Fluminense, Rio de Janeiro, 2005.

- [17] MARENGONI, MAURÍCIO E STRINGHINI, D., “Tutorial: Introdução à Visão Computacional usando OpenCV. Revista de Informática Teórica e Aplicada). pp. v. 16, n. 55 1,p. 125 160, 2009, Available at [http://seer.ufrgs.br/rita/article/download/rita\\_v16\\_n1\\_p125/7289](http://seer.ufrgs.br/rita/article/download/rita_v16_n1_p125/7289).
- [18] PORTES, MÁRCIO.PORTES, M., “Processamento de Imagens: Métodos e Análises”. Available at <http://www.cbpf.br/cat/pdsi/pdf/ProcessamentoImagens.PDF>.
- [19] RODRIGUES, M. V., “Processamento de Imagens: Métodos e Análises”. Mariana Vaz Rodrigues. – Dissertação de Mestrado, Instituto Biológico, 72p. São Paulo, 2010.
- [20] MARENGONI, MAURÍCIO E STRINGHINI, D., “Iniciativas de desenvolvimento sustentável das comunidades do Rio Amazonas/Solimões”. p. 28p, ProVárzea/Ibama.
- [21] SHRIMPTON, R.; GIUGLIANO, R. R. N., “Consumo de alimento e alguns nutrientes em Manaus”. pp. 117–141, Acta Amazônica.
- [22] TOPICS, “Special Topics in Multimedia System”. pp. 117–141, Available at <http://www.cse.iitd.ernet.in/pkalra/sil801/pdf/session-1.pdf>. A.
- [23] VEDEL M, BREUGNOTA S, L., “Full Stokes Polarization Camera”. SPIE Proc. Vol. 8160-33, SPIE Optical Engineering + Applications, San Diego, Aug 21-25, 2011.
- [24] XIE, C., S. M. V. K. B. V. K., “Correlation Pattern Recognition for Face Recognition”. Proceedings of the IEEE, v. 94, n. 11, pp. 1963-1976, 2006.
- [25] ZHIQIAN WANG; RAO, K. R.; BEN-ARIE, J., “Optimal Ramp Edge Detection using Expansion Matching”, IEEE Transactions on Pattern Analysis and Machine Intelligence”. v. 18, n. 11, pp. 1092-1097, November 1996.
- [26] RAPP, V., SENECHAL, T., BAILLY, K., et al., “Multiple Kernel Learning SVM and Statistical Validation for Facial Landmark Detection”. In: *Proceedings of the International Conference on Automatic Face Gesture Recognition and Workshops*, pp. 265–271, March 2011.

- [27] BRASIL, MINISTÉRIO DA AGRICULTURA, P. E. A., “Manual de Inspeção de Produtos de Origem Animal – Peixes e Produtos Pesqueiros”. In: *Congresso Nacional de Inspeção Sanitária*, Ministério da Agricultura, Pecuária e Abastecimento: Brasília, Brasil, 2019.
- [28] ROBOFLOW, “Roboflow: The Universal Tool for Computer Vision Projects”. In: *Roboflow Official Documentation*, Available at <https://roboflow.com>, 2023, Accessed: November 30, 2024.

# Apêndice A

## Anexos-Testes

Testes da para inspeção com a ferramenta roboflow.

### A.1 Testes, Detecção e roboflow

<https://github.com/valdesondantas/prjinspecao>