

UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CENTRO DE AQUICULTURA DA UNESP

**IDENTIFICAÇÃO E DIAGNÓSTICO
AUTOMÁTICO DE ECTOPARASITOS EM PEIXES
UTILIZANDO DEEP LEARNING**

Vinicius Galante Pereira

Jaboticabal, São Paulo

2025

UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CENTRO DE AQUICULTURA DA UNESP

**IDENTIFICAÇÃO E DIAGNÓSTICO
AUTOMÁTICO DE ECTOPARASITOS EM
PEIXES UTILIZANDO DEEP LEARNING**

Vinicius Galante Pereira

Orientadora: Dra. Fabiana Pilarski

Coorientador: Prof. Dr. Érico Tadao Teramoto

Dissertação apresentada ao
Programa de Pós-graduação em
Aquicultura do Centro de Aquicultura
da UNESP - CAUNESP, como parte
dos requisitos para obtenção do
título de Mestre em Aquicultura

Jaboticabal, São Paulo

2025

P436i

Pereira, Vinicius Galante

Identificação e diagnóstico automático de ectoparasitos em peixes utilizando deep learning / Vinicius Galante Pereira. -- Jaboticabal, 2025

84 p.: tabs., fotos

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientadora: Fabiana Pilarski

1. Aquicultura. 2. ectoparasitos. 3. Inteligência Artificial. 4. Automação. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Identificação E Diagnóstico Automático De Ectoparasitos Em Peixes Utilizando Deep Learning

AUTOR: VINICIUS GALANTE PEREIRA

ORIENTADORA: FABIANA PILARSKI

Aprovado como parte das exigências para obtenção do Título de Mestre em Ciências, Área de Aquicultura, pela Comissão Examinadora:

Documento assinado digitalmente
 **FABIANA PILARSKI**
Data: 24/02/2025 10:41:02-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. FABIANA PILARSKI (Participação Virtual)

Laboratório de Microbiologia e Parasitologia de Organismos Aquáticos / CAUNESP Jaboticabal/SP

Documento assinado digitalmente
 **GUILHERME WOLFF BUENO**
Data: 24/02/2025 17:42:19-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. GUILHERME WOLFF BUENO (Participação Virtual)

Departamento de Recursos Pesqueiros e Aquicultura / Faculdade de Ciências Agrárias do Vale do Ribeira do Campus de Registro da Unesp, Registro/SP

Documento assinado digitalmente
 **LINDOMAR DE OLIVEIRA ALVES**
Data: 24/02/2025 10:58:12-0300
Verifique em <https://validar.iti.gov.br>

Dr LINDOMAR DE OLIVEIRA ALVES (Participação Virtual)

Departamento de Genética e Evolução / Universidade Federal de São Carlos - UFSCar, São Carlos/SP

Jaboticabal, 24 de fevereiro de 2025

*"O conhecimento é um meio, enquanto
a sabedoria é o fim"*

Osho

*Este trabalho é dedicado às pessoas que me fizeram quem eu sou,
meus pais Luis Pereira e Rosana Galante,
tudo que eu já fui e ainda serei é uma eterna dívida com vocês*

APOIO FINANCEIRO

CAPES, Processo nº 88887.955700/2024-00, bolsa de mestrado.

CNPq, Processo nº 130781/2023-1, bolsa de mestrado

CNPq Chamada CNPq/MCTI/FNDCT Nº 18/2021 - Faixa B - Grupos Consolidados
(Processo 406591/2021-0) pelo financiamento do projeto.



SUMÁRIO

LISTA DE SIGLAS	iii
LISTA DE FIGURAS	iv
LISTA DE TABELAS	vi
1.	7
2.	10
Capítulo I - Revisão de Literatura	12
REVISÃO ABRANGENTE DA APLICAÇÃO DE VISÃO COMPUTACIONAL NO DIAGNÓSTICO DE DOENÇAS EM PISCICULTURAS	12
GLOBAL REVIEW OF THE APPLICATION OF COMPUTER VISION IN THE DIAGNOSIS OF PARASITIC DISEASES IN FISH FARMS	13
1. INTRODUÇÃO	14
2. CONCEITOS FUNDAMENTAIS	15
2.1 Visão computacional	15
2.2 Redes neurais convolucionais (CNNs)	16
2.2.1 Principais Arquiteturas de CNN	19
2.2.1.1 LeNet	19
2.2.1.2 AlexNet	20
2.2.1.3 VGGNet	20
2.2.1.4 ResNet	21
2.2.1.5 GoogleNet	21
2.2.1.6 MobileNet	22
2.2.1.7 YOLO	22
2.3 Bases de Dados Para Treinamento e Validação	23
2.3.1 Base de dados pré-existent	24
2.4 Critérios para Avaliação da Acurácia	25
2.5 Doenças parasitárias em peixes	26
3. MATERIAL E MÉTODOS	28
4. RESULTADOS E DISCUSSÃO	29
4.1 Desafios, limitações e direções para futuras pesquisas	36
5. CONSIDERAÇÕES FINAIS	38
6. REFERÊNCIAS BIBLIOGRÁFICAS	39

Capítulo II: Elaboração do Banco de Dados	39
COLETA E PROCESSAMENTO DE IMAGENS DE ECTOPARASITOS DE PEIXES PARA TREINAMENTO E VALIDAÇÃO DE REDES NEURAIS CONVOLUCIONAIS	45
COLLECTION AND PROCESSING OF IMAGES OF FISH ECTOPARASITE FOR TRAINING A VALIDATION OF CONVOLUTIONAL NEURAL NETWORKs	46
1. INTRODUÇÃO	47
2.	48
3. METODOLOGIA	49
3.1 Coleta de amostras de ectoparasitos e geração das imagens digitais	49
3.2 Rotulagem e armazenamento	51
3.3 Pré-processamento das imagens	53
4. RESULTADOS E DISCUSSÃO	54
4.1 Qualidade e Diversidade do Conjunto de Dados	54
4.2 Pré-processamento de Imagens	65
4.3 Expansão da base de dados por Data Augmentation	68
5. CONSIDERAÇÕES FINAIS	69
6. CONTINUIDADE NOS ESTUDOS	70
6.1 Ampliação da Base de Dados	70
6.2 Escolha da Arquitetura de CNN para treinamento	70
7. REFERÊNCIAS BIBLIOGRÁFICAS	72

LISTA DE SIGLAS

IA	Inteligência Artificial
ML	Aprendizado de Máquinas
CV	Visão Computacional
GPUs	Unidades de Processamento Gráfico
CNNs	Redes Neurais Convolucionais
DL	Aprendizado Profundo
RNNs	Redes Neurais Recorrentes
GANs	Redes Adversariais Generativas
ReLU	Unidade Linear Retificada
EUS	Síndrome Ulcerativa Epizoótica
SVM	Máquina de vetores de suporte
M-SVMs	Máquina de vetores de suporte multiclasse
mAP	Precisão média
VGB	Vermelho, verde e azul
IDE	Ambiente de desenvolvimento integrado
MPA	Septicemia móvel por Aeromônios

LISTA DE FIGURAS

Figura 01. Etapas envolvidas na solução de problemas baseados em visão computacional.....	10
Figura 02. Representação de uma estrutura padrão de CNN, composta por camadas de neurônios de entrada, convolução, pooling, camadas totalmente conectadas e saída.....	11
Figura 03. <i>Fluxograma do procedimento de obtenção das imagens</i>	49
Figura 04. <i>Rotulagem das imagens com caixas delimitadoras</i>	52
Figura 04. Colônia de <i>Epistylis</i> sp. (A), hifas de <i>Saprolegnia</i> sp. (B), tricodinídeo (C), aparelho de fixação de lerneídeo (D), tomonte de <i>Ichthyophthirius multifiliis</i> (E), monogenético (F).	40
Figura 05. Fluxograma do procedimento de rotulagem dos dados.....	58
Figura 6. Colônia de <i>Epistylis</i> sp. (A), hifas de <i>Saprolegnia</i> sp. (B), tricodinídeo (C), <i>Piscinoodinium</i> sp. (D), trofote de <i>Ichthyophthirius multifiliis</i> (E), monogenético (F).....	61
Figura 07. tricodinídeo no sentido ventro-dorsal (A), tricodinídeo no sentido látero-lateral (B).....	63
Figura 08. tricodinídeo no sentido ventro-dorsal (A), tricodinídeo no sentido oblíquo (B).	63
Figura 09. Registros sequenciais de um monogenético em movimento (A, B, C e D).....	64
Figura 10. Registro original de um tricodinídeo (A). Conversão para tons de cinza (B).....	66
Figura 11. Imagem original (A), imagem limiarizada com limiar de 120 (B), 150 (C) e 170 (D).....	67
Figura 12. Imagem original (A), imagem limiarizada com limiar de 170 (B), 150 (C) e 170 (D).....	68

Figura 13. Alterações observadas em imagens de *Saprolegnia* sp. após a limiarização: imagem original (A), limiar de 120 (B), limiar de 150 (C) e limiar de 170 (D)..... 50

LISTA DE TABELAS

Tabela 1. Relação dos principais estudos verificados na literatura, que exploraram o tema visão computacional ou aprendizado profundo no diagnóstico de doenças em peixes.....30

Tabela 2. Dados das coletas parasitológicas: Data, espécie de peixe, número de exemplares, origem geográfica, fase de desenvolvimento, sinais clínicos, parasitos identificados e grau de infestação.....55

Tabela 3. Características relevantes de cada parasito, que podem ser realçadas para aprimorar a classificação..... 59

1. INTRODUÇÃO GERAL

Compreender processos fundamentais da inteligência humana, como percepção, aprendizado por meio de exemplos, visão, linguagem e tomada de decisão, é um desafio inerente à própria natureza da inteligência. A *Inteligência Artificial* (IA), por sua vez, busca replicar e modelar essas capacidades cognitivas, inspirando-se nos processos cognitivos humanos (LeCun et al., 2015). O cérebro humano, composto por bilhões de neurônios interconectados, atua como o centro da inteligência humana, processando informações complexas e coordenando funções cognitivas essenciais que permitem a adaptação e inovação em ambientes dinâmicos.

Um dos marcos importantes para a IA foi a proposta por Warren McCulloch e Walter Pitts em 1943, do primeiro modelo computacional para redes neurais, que se tornaria a base para muitos desenvolvimentos posteriores (Piccinini, 2004). Porém, a Conferência de Dartmouth, que ocorreu nos EUA em 1956, foi considerada o marco oficial da IA como área de estudo. Nela, John McCarthy descreveu o termo IA (Nilsson, 2010). Desde esse momento, a área da IA passou por momentos de entusiasmo nas décadas de 1950 e 1960, recessão em 1970 e 1980, e renascimento na década de 1990, impulsionada por avanços em hardware, algoritmos e a disponibilidade de grandes volumes de dados (*big data*) (Minsky, 1975; Nilsson, 2010; Russel; Norvig, 2010).

Dentre as subáreas da IA hoje estabelecidas, pode-se destacar o Aprendizado de Máquinas (ML) e a Visão Computacional (CV). De forma sucinta, o ML pode ser definido como a subárea da IA voltada ao desenvolvimento de algoritmos que aprendem padrões a partir de dados, dispensando programação explícita para cada tarefa (Frank et al., 2010). Por sua vez, a Visão Computacional (CV) dedica-se ao desenvolvimento de tecnologias capazes de realizar o reconhecimento, a contagem e a classificação de objetos e entidades detectadas em imagens ou vídeos (Szeliski, 2011).

A rápida popularização das Unidades de Processamento Gráfico (GPUs), que ocorreu nos últimos anos, revolucionaram a visão computacional, tornando-a mais acessível, eficiente e poderosa (Smith et al., 2021). Vale ressaltar que a CV depende diretamente do ML, especialmente quando se considera a utilização de Redes Neurais Convolucionais (CNNs) para os processos de reconhecimento e

classificação de imagens. Essas redes neurais são componentes fundamentais do Aprendizado Profundo (DL), que por sua vez, é considerada uma subárea do ML (Szeliski, 2011).

Atualmente, a IA que antes era restrita aos laboratórios de pesquisa, agora está em nosso cotidiano, desde assistentes virtuais em smartphones a carros autônomos. A popularização da IA impulsionou um crescimento exponencial da pesquisa aplicada em diversas áreas, incluindo a aquicultura, em que mostra grande potencial para otimizar processos em diferentes sistemas produtivos.

A aquicultura, prática dedicada à produção de organismos aquáticos, destaca-se como uma das atividades agropecuárias que mais crescem no mundo, sendo promissora para atender à crescente demanda por proteína animal de qualidade na alimentação humana. Esse setor já desempenha um papel crucial na alimentação mundial, contribuindo significativamente para a segurança alimentar e nutricional, especialmente em regiões com alta demanda por proteína animal (Beveridge et al., 2013).

Em 2022, a produção global de organismos aquáticos atingiu um novo recorde, com 223,2 milhões de toneladas, com aumento de 4,4% em relação a 2020. Pela primeira vez na história, a aquicultura produziu mais do que a pesca de captura, totalizando 94,4 milhões de toneladas, o equivalente a 51% da produção total de pescado. O consumo global de alimentos aquáticos também cresceu, com a média per capita mundial subindo para 20,7 kg em 2022, um aumento significativo desde 1961, quando era de 9,1 kg (FAO, 2024). Esse crescimento reflete a crescente importância da aquicultura para a segurança alimentar global, principalmente em tempos de escassez de recursos e mudanças climáticas, e enfatiza a necessidade de expandir a produção de forma sustentável, sobretudo em regiões em desenvolvimento, como partes da África e América Latina (FAO, 2024).

A demanda por tecnologias avançadas cresce rapidamente na aquicultura devido à limitação dos recursos da pesca extrativa e à necessidade de aumentar a eficiência e sustentabilidade do setor (Biazi; Marques, 2023). Nesse contexto, tecnologias como a IA desempenham um papel essencial na melhoria da produtividade e sustentabilidade na aquicultura (Biazi; Marques, 2023; Zhao et al., 2021). Ela permite a automação de tarefas complexas, reduzindo o tempo de

execução, diminuindo a margem de erro e consequentemente ampliando a escala de produção (Rather et al., 2024). Dessa forma, tem-se a redução de custos e melhoria da qualidade.

O diagnóstico e controle de doenças, em especial das doenças parasitárias, é uma tarefa importante e complexa na aquicultura, pois impacta diretamente a produtividade e a qualidade do produto final, justificando a necessidade de automação e de tecnologias voltadas para esse fim (Mustapha et al., 2021). A rapidez no diagnóstico é essencial para o controle rápido e eficaz de doenças e a prevenção de infestações parasitárias, reduzindo os prejuízos com infecções secundárias e consequente mortalidade. Esse processo envolve ações como a identificação de alterações comportamentais e morfofisiológicas, bem como a determinação precisa do tipo de parasito. Todas essas etapas podem ser automatizadas com o uso de visão computacional (CV), tornando o monitoramento mais rápido e eficiente (Yasruddin et al., 2022).

Estudos como os de Ahmed et al. (2022) e Huang & Khabusi (2023) têm buscado desenvolver ferramentas de visão computacional para monitoramento da condição de saúde dos peixes. No entanto, poucos deles visam a identificação das diferentes doenças parasitárias. Embora Li et al. (2023) tenham desenvolvido com precisão satisfatória um modelo para identificação de três espécies de ectoparasitos de peixes (*Ichthyophthirius multifiliis*, *Gyrodactylus kobayashii* e *Argulus japonicus*), as espécies de ectoparasitos abordadas pelo estudo não incluem grande parte das que acometem a aquicultura brasileira.

Nesse contexto, esse estudo propõe criar uma base de dados estruturada, composta por imagens de ectoparasitos de peixes que possibilite o treinamento de uma rede neural convolucional para identificação automática desses agentes, contribuindo para a sustentabilidade dos sistemas piscícolas ao possibilitar a implementação mais rápida de medidas de controle e prevenção de surtos de etiologia parasitária nos sistemas de produção.

2. REFERÊNCIAS BIBLIOGRÁFICAS

- AHMED, M. S.; AURPA, T. T.; AZAD, M. A. K. Fish disease detection using image based machine learning technique in aquaculture. **The Journal of King Saud University Computer and Information Sciences**, v. 34, p. 5170–5182, 2022.
- BEVERIDGE, M. C.; THILSTED, S. H.; PHILLIPS, M. J.; METIAN, M.; TROELL, M.; HALL, S. J. Meeting the food and nutrition needs of the poor: the role of fish and the opportunities and challenges emerging from the rise of aquaculture. **Journal of Fish Biology**, v. 83(4), p. 1067-1084, 2013.
- BIAZI, V.; MARQUES, C. Industry 4.0-based smart systems in aquaculture: A comprehensive review. **Aquacultural Engineering**, v. 103, p. 102360, 2023.
- BI, Y.; XUE, B.; ZHANG, M. Genetic programming for image classification: An automated approach to feature learning. Vol. 24, Springer Nature, 2021.
- FRANK, E.; WITTEN, I. H.; HALL, M. A. **Data Mining: Practical Machine Learning Tools and Techniques**. 3. ed. Elsevier, Burlington, MA, 2011. 600 p.
- HUANG, Y. P.; KHABUSI, S. P. A CNN-OSELM multi-layer fusion network with attention mechanism for fish disease recognition in aquaculture. **IEEE Access**, v. 11, p. 58729–58744, 2023.
- LE CUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521(7553), p. 436-444, 2015.
- LI, J.; LIAN, Z.; WU, Z.; ZENG, L.; MU, L.; YUAN, Y.; ... & YE, J. Artificial intelligence–based method for the rapid detection of fish parasites (*Ichthyophthirius multifiliis*, *Gyrodactylus kobayashii*, and *Argulus japonicus*). **Aquaculture**, v. 563, p. 738790, 2023.
- MINISKY, M. **A society of minds**. Simon and Schuster, 1975.
- MUSTAPHA, S.; MUSTAPHA, E. M.; SHARIF, M. U. Sustainable aquaculture development: A review on the roles of cloud computing, internet of things and artificial intelligence (CIA). **Journal of Cleaner Production**, v. 280, p. 124-134, 2021.
- NILSSON, N. J. **The Quest for Artificial Intelligence**. Cambridge University Press, 2010.
- PICCININI, G. The first computational theory of mind and brain: A close look at McCulloch and Pitts's "Logical Calculus of Ideas Immanent in Nervous Activity". **Synthese**, v. 141, n. 2, p. 175-215, 2004.

- RATHER, M. A.; AHMAD, I.; SHAH, A.; HAJAN, Y. A.; AMIN, A.; KHURSHEED, S.; AHMAD, I.; RASOOL, S. Exploring opportunities of Artificial Intelligence in aquaculture to meet increasing food demand. **Food Chemistry: X**, v. 22, p. 101309, 2024.
- RUSSELL, S. J.; NORVIG, P. **Inteligência artificial**. 3. ed. Campus, Rio de Janeiro, 2010.
- SMITH, M. L.; SMITH, L. N.; HANSEN, M. F. The quiet revolution in machine vision - a state-of-the-art survey paper, including historical review, perspectives, and future directions. **Computers in Industry**, v. 130, p. 103472, 2021.
- SZELISKI, R. **Computer Vision: Algorithms and Applications**. 2^a ed. Springer, New York, 2011.
- YASRUDDIN, M. L.; ISMAIL, M. A. H.; HUSIN, Z.; TAN, W. K. Feasibility study of fish disease detection using computer vision and deep convolutional neural network (DCNN) algorithm. In: **2022 IEEE 18th International Colloquium on Signal Processing & Applications (CSPA)**, 2022, May. p. 272-276. IEEE.
- ZHAO, S.; ZHANG, S.; LIU, J.; WANG, H.; ZHU, J.; LI, D.; ZHAO, R. Application of machine learning in intelligent fish aquaculture: A review. **Aquaculture**, v. 540, p. 736724, 2021.

Capítulo I - Revisão de Literatura

REVISÃO ABRANGENTE DA APLICAÇÃO DE VISÃO COMPUTACIONAL NO DIAGNÓSTICO DE DOENÇAS NA PISCICULTURA

Resumo: Este estudo apresenta uma revisão sistemática da literatura sobre a aplicação da visão computacional (CV) e aprendizado profundo (DL) no diagnóstico automatizado de doenças parasitárias em peixes. Foram consultadas as bases de dados Google Scholar, Scopus, Web of Science e Wiley Online Library, utilizando combinações de descritores como “inteligência artificial”, “visão computacional”, “diagnóstico automático”, “classificação de ectoparasitos”, “aprendizado profundo” e “redes neurais convolucionais” no contexto da aquicultura. A revisão aborda o estado da arte, destacando as principais técnicas utilizadas, os tipos de parasitos investigados e as bases de dados disponíveis, além de identificar lacunas de conhecimento e propor direções futuras. Para ampliar a acessibilidade do conteúdo, conceitos fundamentais de CV são apresentados, visando facilitar a compreensão e padronizar a terminologia para profissionais de áreas correlatas, como aquicultura, ciências biológicas e medicina veterinária.

Palavras-chave: aquicultura, ectoparasitos, inteligência artificial, automação.

GLOBAL REVIEW OF THE APPLICATION OF COMPUTER VISION IN THE DIAGNOSIS OF DISEASES IN FISH FARMS

Abstract: This study presents a systematic literature review on the application of computer vision (CV) and deep learning (DL) in the automated diagnosis of parasitic diseases in fish. Databases such as Google Scholar, Scopus, Web of Science, and Wiley Online Library were consulted using combinations of descriptors like “artificial intelligence”, “computer vision,” “automatic diagnosis,” “ectoparasite classification,” “deep learning,” and “convolutional neural networks” within the aquaculture context. The review addresses the state-of-the-art, highlighting the main techniques employed, the types of parasites investigated, and the available datasets, while identifying knowledge gaps and proposing future directions. To enhance content accessibility, fundamental CV concepts are introduced, aiming to facilitate understanding and standardize terminology for professionals in related fields such as aquaculture, biological sciences, and veterinary medicine.

Keywords: aquaculture, ectoparasites, artificial intelligence, automation.

1. INTRODUÇÃO

Atualmente, a aquicultura é considerada uma das atividades pecuárias de maior crescimento global, sendo promissora para atender à crescente demanda por proteína animal de qualidade, segurança alimentar e nutricional. Para sustentar esse crescimento, diante de desafios como mudanças climáticas e escassez de recursos, é essencial o aprimoramento contínuo das tecnologias de produção, com foco em aumentar a eficiência e a sustentabilidade.

A automação de tarefas complexas é considerada uma das principais formas de aumentar a eficiência, pois controla o desperdício de insumos, reduz o tempo de execução e amplia a escala de produção (Biazi; Marques, 2023; Zhao et al., 2021). Nesse contexto, as pesquisas sobre o uso de inteligência artificial (IA) aplicada, especialmente em Visão Computacional (CV), têm se intensificado nos últimos anos na aquicultura, alcançando níveis exponenciais. Em relação às soluções baseadas em visão computacional, elas combinam técnicas de processamento de imagens com aprendizado profundo, especialmente através de redes neurais convolucionais (CNNs), para extrair e interpretar padrões visuais de forma automatizada (Bisho; Bishop, 2023; Szeliski, 2010).

A visão computacional (CV) possui diversas aplicações na aquicultura, por sua capacidade de interpretar imagens e vídeos, automatizando processos antes dependentes de supervisão manual. Entre as aplicações mais notáveis estão a identificação automática de espécies (Duhayyim et al., 2022), a estimativa de biomassa com base em imagens subaquáticas (Xue et al., 2023), o controle da qualidade da água através da identificação de partículas em suspensão e o monitoramento do comportamento alimentar e do bem-estar animal através da análise de padrões de movimentação e interação (Aung et al., 2024). Outra aplicação potencial é o uso de CV no controle sanitário, no diagnóstico de doenças em peixes, utilizando imagens de microscopia óptica (Li et al., 2023). Essas aplicações oferecem solução inovadora para diagnosticar e mitigar doenças, permitindo agilizar a tomada de decisão para controlar as infecções e consequente redução nas perdas e prejuízos.

Apesar do avanço das tecnologias, ainda há lacunas significativas no uso de visão computacional aplicada ao diagnóstico de doenças parasitárias em peixes. Isso inclui a falta de bases de dados de imagens representativas, o desafio de classificar parasitos em estágios distintos de desenvolvimento e a necessidade de

adaptar modelos de aprendizado profundo para cenários específicos da piscicultura, especialmente em países tropicais. Assim, estudos que consolidam o estado da arte e identificam oportunidades de avanço nessa área são essenciais para direcionar esforços de pesquisa e desenvolvimento tecnológico.

Diante disso, esta revisão busca responder questões centrais sobre a aplicação da visão computacional no diagnóstico de doenças parasitárias em pisciculturas, incluindo o estado da arte, as principais técnicas para detecção e classificação de parasitos, os tipos mais estudados e as bases de dados de imagens disponíveis. Além disso, a revisão identifica lacunas de conhecimento e sugere direções futuras para pesquisas na área.

Inicialmente, são apresentados os conceitos fundamentais de visão computacional, uma etapa crucial para ampliar o alcance da revisão e torná-la acessível a leitores não especialistas, como profissionais de aquicultura, ciências biológicas, zootecnia e medicina veterinária. Essa abordagem facilita a compreensão do tema, padroniza a terminologia utilizada e fornece uma base sólida para as discussões subsequentes.

2. CONCEITOS FUNDAMENTAIS

2.1 Visão computacional

A visão computacional (CV) é uma subárea da inteligência artificial que se dedica a desenvolver algoritmos capazes de extrair informações significativas a partir de dados visuais, como imagens e vídeos (Szeliski, 2022). Ao complementar a visão humana, a CV busca automatizar tarefas que envolvem a identificação, classificação, contagem e mensuração de objetos ou entidades presentes em imagens ou vídeos.

A abordagem da CV envolve a conversão de dados visuais em representações numéricas, que podem ser processadas por algoritmos de aprendizado de máquina (ML). As CNNs são amplamente utilizadas para essa tarefa, devido à sua capacidade de aprender hierarquias de características visuais, desde bordas simples até objetos complexos (Szeliski, 2022). A Figura 1 ilustra as etapas envolvidas no desenvolvimento de soluções baseadas em CV, que abrangem o entendimento do problema, a aquisição de imagens, e, quando

necessário, o pré-processamento das imagens para adequação e construção de uma base de dados. Essa base é posteriormente utilizada no treinamento e validação dos algoritmos de ML, garantindo a eficácia das soluções propostas.



Figura 1. Etapas envolvidas na solução de problemas baseados em visão computacional.

O treinamento de CNNs exige grandes quantidades de dados rotulados, que servem como exemplos para o modelo aprender a mapear as entradas visuais às saídas desejadas. A qualidade e a diversidade desses dados são cruciais para o desempenho do modelo. Além das CNNs, outras técnicas como Redes Neurais Recorrentes (RNNs) e Redes Adversariais Generativas (GANs) têm sido aplicadas com sucesso em diversas tarefas de CV (Hochreiter; Schmidhuber, 1997; Goodfellow, et al., 2014). O treinamento de modelos de visão computacional pode ser computacionalmente exigente. Unidades de processamento gráfico (GPUs) são amplamente utilizadas para acelerar o treinamento, devido à sua capacidade de realizar cálculos em paralelo (Smith et al., 2021). A disponibilidade de hardware adequado, como GPUs, é fundamental para o desenvolvimento de sistemas de visão computacional eficientes.

2.2 Redes neurais convolucionais (CNNs)

As CNNs são estruturas centrais na área de CV, inspiradas na estrutura hierárquica de neurônios do córtex visual humano que processam informações visuais (Bishop; Bishop, 2023; Goodfellow et al., 2023). São amplamente empregadas em tarefas como classificação de imagens, detecção de objetos e segmentação. Sua arquitetura é composta por múltiplas camadas de neurônios de

convolução, organizadas em uma sequência hierárquica. A Figura 2 ilustra a arquitetura típica de uma rede neural convolucional. A sequência de camadas inclui a camada de entrada, que recebe as imagens, e a camada de saída, que produz a classificação ou detecção final. As camadas intermediárias, compostas por camadas convolucionais e de pooling, são responsáveis por extrair características hierárquicas das imagens, desde as simples até representações mais complexas dos objetos (Bishop; Bishop, 2023).




Figura 2. Representação do processo de coleta de imagens e treinamento de uma estrutura padrão de CNN, composta por camadas de neurônios de entrada, convolução, pooling, camadas totalmente conectadas e de saída.

A convolução nas CNNs é uma operação matemática que aplica filtros numéricos (kernels) a uma imagem de entrada (Goodfellow et al., 2016; Bishop; Bishop, 2023). Esses filtros percorrem a imagem e realizam produtos escalares entre seus valores e os pixels correspondentes da entrada. O resultado dessa operação é um mapa de ativação, que destaca características presentes na imagem, como bordas, texturas e padrões. Tais mapas correspondem a representações da entrada, cada um realçando os padrões específicos detectados por um filtro particular. Durante o treinamento, os filtros são ajustados automaticamente, permitindo que as CNNs aprendam a identificar as características mais relevantes para a tarefa de classificação.

O tamanho do mapa de ativação resultante da operação de convolução é influenciado por hiperparâmetros como *stride* e *padding* (Bishop; Bishop, 2023). O *stride* determina o passo com que o filtro se move sobre a imagem, afetando a resolução espacial do mapa de ativação. O *padding*, por sua vez, consiste na

adição de valores (geralmente zeros) às bordas da imagem, permitindo controlar o tamanho do mapa de saída e preservar informações nas bordas.

Após a convolução, os mapas de ativação são submetidos a uma função de ativação não linear, sendo a ReLU (*Rectified Linear Unit*) uma das mais utilizadas, que introduz não linearidades nas representações apreendidas pela rede (Krizhevsky et al., 2012). Essa não linearidade é crucial para a capacidade das CNNs em modelar relações complexas entre os pixels da imagem.

A combinação de camadas convolucionais e funções de ativação permite que as CNNs extraiam hierarquias de características visuais de forma eficiente. Em aplicações na aquicultura, essa capacidade é fundamental para a identificação precisa de ectoparasitos em imagens de peixes, considerando a diversidade morfológica desses organismos e as variações nas condições de aquisição das imagens.

A função das camadas de pooling é reduzir o tamanho espacial do mapa de ativação, preservando informações mais relevantes e descartando as menos importantes. Esse processo diminui a quantidade de dados e acelera o processamento nas camadas subsequentes da rede (Goodfellow et al., 2016). O pooling é realizado de forma local dentro de cada mapa de ativação, analisando pequenos blocos de pixels, e selecionando o valor mais representativo de cada bloco com base no método escolhido. O *max pooling* é o método mais comum, por ser eficaz em capturar características marcantes e relevantes para o foco da rede (Szeliski, 2010). Além dele, há o *average pooling*, que calcula a média dos valores dentro do bloco, proporcionando uma abordagem mais suavizada para a extração de características.

As camadas totalmente conectadas são componentes essenciais das Redes Neurais Profundas, especialmente nas arquiteturas de redes CNNs. Elas atuam como um classificador, transformando os mapas de características extraídas em probabilidades associadas às classes de saída, ou em valores contínuos para tarefas de regressão (Goodfellow et al., 2016). Portanto, as camadas totalmente conectadas desempenham um papel importante ao agregar e interpretar as informações extraídas pelas camadas convolucionais e de pooling.

Por conectarem cada neurônio a todos os da camada anterior, as camadas totalmente conectadas integram características de forma global, sendo

fundamentais para tarefas de classificação e regressão. Apesar de sua importância, essas camadas apresentam desafios específicos, como o alto custo computacional e a propensão ao sobreajuste (*overfitting*), devido ao grande número de parâmetros treináveis (Goodfellow et al., 2016). O sobreajuste ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, capturando padrões e ruídos, resultando em baixo erro no treinamento, mas alto erro em novos dados (Frank et al., 2011).

Assim, estratégias como regularização, “*dropout*” e a utilização de bases de dados amplas são frequentemente adotadas para melhorar a generalização do modelo e evitar que o aprendizado se restrinja excessivamente aos dados de treinamento. O *dropout* consiste na regularização a partir da desativação aleatória de neurônios durante o treinamento, forçando a rede a aprender padrões mais generalizáveis (Srivastava et al., 2014).

2.2.1 Principais Arquiteturas de CNN

Atualmente, as CNNs abrangem uma ampla variedade de arquiteturas projetadas para realizar tarefas de classificação de imagens e segmentação. Dentre as principais arquiteturas destacam-se a LeNet-5, AlexNet, VGG, ResNet, MobileNet e YOLO, cada uma desenvolvida com características específicas que as tornam adequadas para diferentes aplicações e contextos. A escolha da arquitetura ideal considera o tamanho da base de dados, a complexidade dos padrões e os recursos computacionais disponíveis.

Arquiteturas profundas capturam padrões complexos, mas demandam bases grandes e alto poder de processamento (Ge et al., 2022). Já arquiteturas leves, como a MobileNet, são adequadas para problemas simples ou com restrições de hardware, reduzindo o risco de sobreajuste em bases pequenas. Os subitens a seguir apresentam uma breve descrição das arquiteturas de CNNs mencionadas.

2.2.1.1 LeNet

A LeNet, desenvolvido por Yann LeCun na década de 1990, é considerada uma das primeiras implementações bem-sucedidas de CNN. Projetada para o reconhecimento de dígitos manuscritos, foi um marco na história da visão

computacional, demonstrando a capacidade das CNNs de serem treinadas para tarefas visuais de maneira eficaz (Szeliski, 2022).

A arquitetura LeNet-5 é considerada simples, possuindo sete camadas de neurônios de convolução, sendo cinco para treinamento. Seu treinamento e testes envolveram o uso da base de dados MNIST, composta por 70 mil imagens de dígitos manuscritos, com resolução de 28x28 pixel em escala de cinza (Aggarwal, 2018). Com esse avanço, máquinas puderam alcançar desempenho comparável ou até superior à visão humana em tarefas específicas como a classificação de imagens (Szeliski, 2022).

2.2.1.2 AlexNet

A AlexNet, desenvolvida por Krizhevsky et al. (2012), é considerada um marco na área da CV, por ser a primeira CNN capaz de processar dados em larga escala e alcançar resultados significativos. Sua principal inovação foi o aumento da profundidade da rede, composta por oito camadas treináveis, sendo cinco convolucionais e três totalmente conectadas. Além disso, ela trouxe inovações técnicas significativas, como o uso de funções de ativação ReLU para acelerar o treinamento e a aplicação de dropout para mitigar o sobreajuste. O aumento de dados (*data augmentation*) também foi empregado para melhorar a generalização, aumentando a robustez da rede frente a variações nos dados de entrada.

Entre as vantagens da AlexNet está a sua capacidade de aprendizado hierárquico, permitindo a extração de características mais complexas em níveis mais profundos (Krizhevsky et al., 2012). Tal abordagem possibilitou sua aplicação para solução de problemas de classificação de imagens, detecção de objetos e análise de exames médicos (Litjens et al., 2017). Uma das desvantagens do uso da AlexNet é o seu alto custo computacional, devido à sua profundidade e à necessidade de hardware especializado, como GPUs, para treinamento eficiente.

2.2.1.3 VGGNet

A arquitetura VGGNet, proposta por Simonyan & Zisserman (2014), destacou-se por enfatizar a tendência de aumento na profundidade das CNNs. Projetada com configurações de 11 a 19 camadas, a VGG consolidou-se como uma das arquiteturas mais eficazes para classificação de imagens. Seu diferencial se deve

ao uso de filtros convolucionais menores de 3x3, combinados com o aumento da profundidade, melhorando a extração de características ao capturar padrões mais complexos com menor número de parâmetros (Aggarwal, 2023).

Com cerca de 138 milhões de parâmetros, o VGGNet estabeleceu um novo padrão para a complexidade das CNNs da época. Embora seja uma rede relativamente profunda, o VGGNet demonstrou que a profundidade, aliada a uma arquitetura simples e elegante, pode levar a resultados superiores em tarefas de classificação de imagens. A capacidade do VGGNet de extrair características discriminativas de forma precisa o tornou uma referência para o desenvolvimento de novas arquiteturas de CNNs e continua sendo amplamente utilizado em diversas aplicações de visão computacional, como sistemas de reconhecimento facial (Simonyan e Zisserman, 2014).

2.2.1.4 ResNet

A Residual Network (ResNet) proposta por He et al. (2016), revolucionou o treinamento de redes neurais profundas e se tornou uma das arquiteturas de CNNs mais populares. Sua capacidade de aprendizado multitarefa e a versatilidade para técnicas como transferência de aprendizado (usando modelos pré-treinados, como o ImageNet) permitem melhorar o desempenho, especialmente com dados limitados (Khan, 2018).

As versões mais comuns são ResNet-18, ResNet-34, ResNet-50, ResNet-101 e ResNet-152, diferenciando-se principalmente pela profundidade. Redes mais profundas, como a ResNet-152, oferecem maior capacidade de aprendizado, mas exigem mais recursos computacionais e dados. Tarefas simples, como classificação de imagens com poucas classes, se beneficiam de versões mais rasas, como a ResNet-18, que exigem menos tempo de treinamento e recursos.

2.2.1.5 GoogleNet

Em 2014, a GoogleNet introduziu a inovadora arquitetura contendo módulos inception, caracterizada pela flexibilidade ao processar objetos de diferentes escalas por meio de convoluções paralelas com filtros de diversos tamanhos (1x1, 3x3 e 5x5) (Szegedy et al., 2015). Isso permitiu que a rede capturasse características em diferentes níveis, otimizando o uso de parâmetros. A

implementação dos módulos inception, utiliza a aplicação de filtros 1×1 reduzindo a dimensionalidade do mapa de características antes de aplicar filtros maiores, diminuindo a carga computacional sem diminuir necessariamente o desempenho do modelo (Szegedy et al., 2015). Outra característica diferencial relevante é a substituição das camadas totalmente conectadas por camadas de average pooling, reduzindo significativamente o número de parâmetros, o que torna a GoogleNet mais compacta em comparação a outras arquiteturas, como a VGG.

2.2.1.6 MobileNet

A MobileNet é uma arquitetura de redes neurais convolucionais desenvolvida pela Google, projetada para atender à necessidade de modelos de visão computacional compactos e eficientes, especialmente voltados para dispositivos móveis e aplicações com recursos computacionais limitados, como smartphones e dispositivos IoT (Howard et al., 2017).

A arquitetura da MobileNet baseia-se em duas técnicas principais: convoluções separáveis por profundidade e multiplicadores de largura. Diferentemente das convoluções tradicionais, as convoluções separáveis por profundidade dividem a operação em duas etapas: uma convolução por profundidade, que aplica filtros independentes a cada canal de entrada, seguida de uma convolução ponto a ponto (1×1), que combina os canais resultantes (Howard et al., 2017). Essa abordagem reduz drasticamente o número de parâmetros e operações computacionais, tornando a MobileNet altamente eficiente.

No entanto, uma das principais limitações da MobileNet é sua sensibilidade a ruídos e variações na qualidade das imagens de entrada, o que pode impactar negativamente sua precisão em contextos de baixa qualidade visual ou condições adversas (Howard et al., 2017).

2.2.1.7 YOLO

A YOLO (You Only Look Once), desenvolvida por Joseph Redmon em 2015 (Redmon et al., 2016), é uma arquitetura conhecida pela inovação na detecção de objetos em tempo real. Suas principais vantagens incluem alta velocidade, simplicidade na implementação e treinamento, e boa capacidade de generalização.

A YOLO reformula a detecção como um problema único de regressão, permitindo analisar uma imagem em um único passo, o que a torna extremamente

rápida e adequada para aplicações em tempo real. No entanto, ela tem dificuldades na detecção de objetos pequenos ou em grande quantidade, além de limitações na precisão de localização, especialmente com sobreposição de objetos. A dependência de GPUs também pode restringir seu uso em dispositivos com recursos limitados.

As versões mais conhecidas incluem YOLOv1, YOLOv2, YOLOv3, YOLOv4 e YOLOv5, com melhorias progressivas em precisão e eficiência (ULTRALYTICS, 2024).

2.3 Bases de Dados Para Treinamento e Validação

A construção de uma base de dados robusta é crucial para o desempenho de modelos de aprendizado profundo em visão computacional. O tamanho e a diversidade da base influenciam diretamente a capacidade de generalização do modelo, permitindo classificações precisas em dados não vistos durante o treinamento. Bases de dados que capturam variações significativas nas classes de interesse ajudam a evitar o sobreajuste e aumentam a eficácia dos modelos (Russakovsky et al., 2015).

Além disso, a qualidade das imagens desempenha um papel essencial. Imagens de alta resolução fornecem mais detalhes, sendo especialmente importantes em aplicações que exigem análises precisas, como diagnósticos médicos. No entanto, a resolução deve ser ajustada conforme o propósito, equilibrando qualidade e limitações computacionais. Aplicações em tempo real, por exemplo, podem priorizar resoluções moderadas para garantir eficiência no processamento (Alcaín et al., 2021).

A qualidade das imagens pode ser aprimorada com técnicas de pré-processamento, como equalização de histograma, remoção de ruído, normalização e ajuste de contraste, assegurando maior consistência na base de dados. Estratégias de aumento de dados, como rotações, flips, cortes e ajustes de brilho ou contraste, são essenciais para ampliar a variabilidade das amostras, especialmente quando os dados disponíveis são limitados (Krizhevsky et al., 2012; Burger; Burger, 2022).

Os filtros desempenham um papel crucial no pré-processamento de imagens, cada um atendendo a objetivos específicos. Entre os principais tipos de filtros, destacam-se:

a) Filtro geométrico: permite corrigir distorções causadas por imperfeições na captura (Castleman, 1996).

b) Filtro médio: permite reduzir ruídos ao suavizar a imagem, substituindo cada pixel pela média dos vizinhos (Jain, 1995).

c) Filtro morfológico: realiza operações como dilatação e erosão em imagens binárias, úteis para detecção de padrões (Serra, 1982).

d) Filtro de borda: permite realçar contornos, para facilitar a segmentação e detecção de alvos (Canny, 1986).

e) Filtro de realce: permite aumentar o contraste e a nitidez, destacando detalhes sob condições adversas (Castleman, 1996).

A aplicação desses filtros em conjunto otimiza o desempenho de modelos, como CNNs, em tarefas como classificação e segmentação de imagens.

Outro aspecto crucial é a escolha do sensor para coleta de dados. Essa decisão deve considerar fatores como o tipo de informação necessária, as condições ambientais e os custos envolvidos. Além de câmeras RGB, sensores especializados, como câmeras termográficas, sensores de profundidade (LIDAR ou Time-of-Flight) e sensores multiespectrais e hiperespectrais, podem ser utilizados. Para ambientes de baixa iluminação, sensores infravermelhos são recomendados (Ghassemian, 2016; Kukushkin et al., 2020).

2.3.1 Base de dados pré-existent

A utilização de bases de dados pré-existent é uma prática comum adotada no desenvolvimento e treinamento de modelos, especialmente em visão computacional. Essas bases já foram previamente rotuladas e organizadas, o que reduz significativamente o tempo e os recursos necessários para a coleta e preparo de dados. A seguir, destacam-se algumas das principais bases de dados disponíveis gratuitamente, e amplamente utilizadas pela comunidade científica:

A ImageNet, criada por Li et al. (2009) na Universidade de Stanford, é uma das bases de dados mais reconhecida atualmente. Ela contém mais de 14 milhões de imagens organizadas hierarquicamente com base na taxonomia WordNet,

coabrindo mais de 20.000 categorias. Cada imagem é rotulada com a categoria correspondente, permitindo o treinamento de modelos de classificação de imagens em larga escala. A robustez da ImageNet justifica seu frequente uso na transferência de aprendizado para desenvolvimento de modelos pré-treinados, com possibilidade de aplicação em diversas tarefas de visão computacional (Russakovsky et al., 2015). Ela foi utilizada na resolução de 224x224 pixels por modelos clássicos como o AlexNet, VGG e o Resnet.

A COCO (Common Objects in Context), criada por pesquisadores da Microsoft, é uma base de dados desenvolvida para tarefas complexas de visão computacional, como detecção de objetos, segmentação de instâncias e legendagem de imagens. É composta por mais de 200.000 imagens, com mais de 1,5 milhões de objetos anotados que se distribuem em 80 categorias. As anotações são detalhadas e incluem coordenadas de caixas delimitadoras (bounding boxes), máscaras de segmentação pixel a pixel e legendas textuais que descrevem o conteúdo das imagens (Lin et al., 2014).

A Pascal VOC (Visual Object Classes Challenge), desenvolvida pela equipe da PASCAL (*Pattern Analysis, Statistical Modeling, and Computational Learning*), é uma base de dados que se tornou uma referência importante para avaliar algoritmos de detecção de objetos e segmentação. Ela é composta por imagens de 20 categorias de objetos, com anotações precisas de caixas delimitadoras e rótulos de objetos. Oferece também desafios de segmentação semântica que permitem a avaliação tanto de modelos que identificam objetos quanto modelos que segmentam as regiões de interesse (Everingham et al., 2010).

2.4 Critérios para Avaliação da Acurácia

No desenvolvimento de soluções baseadas em aprendizado de máquina, uma etapa crucial é a validação do modelo de classificação ou regressão desenvolvido (Frank et al., 2011). Durante essa fase, o modelo é testado com uma base de dados distinta daquela usada no treinamento, composta por exemplos inéditos, com o objetivo de avaliar sua capacidade de generalização e garantir que ele não esteja enviesado. Além disso, a seleção criteriosa de indicadores estatísticos para medir a acurácia é fundamental, pois influencia diretamente a interpretação da performance do modelo.

Dentre os diferentes indicadores, pode-se destacar (Hastie et al., 2009): (i) precisão, que corresponde ao percentual de acertos entre as predições corretas em relação ao total de predições positivas realizadas pelo modelo, baseada na matriz de confusão (Maxwell, 2021); (ii) recall, que mede a proporção de exemplos positivos corretamente identificados entre todos os exemplos positivos existentes na base de dados; (iii) F1-score, definido como a média harmônica entre precisão e recall, balanceando os dois indicadores (Aghdam; Heravi, 2017); (iv) Mean Average Precision (mAP), uma métrica utilizada especialmente em tarefas de detecção, que avalia a precisão média em diferentes limiares de confiança; e (v) Intersection over Union (IoU), comumente empregada em segmentação de imagens, que calcula a sobreposição entre a área prevista e a área real dividida pela união dessas áreas.

2.5 Doenças parasitárias em peixes

As doenças parasitárias em peixes de produção são problemas alarmantes especialmente em sistemas intensivos onde fatores como alta densidade populacional e baixa qualidade de água podem favorecer a proliferação de parasitos. Em um estudo realizado por Lafferty et al. (2015) foram analisados 67 surtos em sistemas de produção aquícola, dos quais os agentes parasitários representaram 37% de todos os casos, refletindo o grande impacto e relevância econômica dessas doenças.

As parasitoses podem ser causadas por diversos agentes, incluindo protozoários, helmintos e crustáceos, representando um dos maiores desafios para a aquicultura ao impactar significativamente a saúde dos peixes e a viabilidade econômica das pisciculturas. De acordo com Zhu et al. (2020) as perdas econômicas decorrentes de surtos parasitários podem alcançar até 50% de todos os custos da produção. Embora as lesões diretas sejam impactantes o suficiente para causar tais prejuízos, os parasitos têm mecanismos de ação indiretos ao abrir portas de entrada para agentes infecciosos. O mecanismo de fixação dos ectoparasitos aos peixes, por exemplo, causa uma lesão duradoura no tecido epitelial que comunica o meio externo com tecidos mais profundos e menos protegidos do hospedeiro, abrindo caminhos para infecções bacterianas ou virais mais intensas. Além disso, estudos constataram que oomicetos como os do gênero

Saprolegnia são capazes de infestar peixes em condições de imunossupressão e manter essas condições por um período prolongado, embora essa interação ainda não esteja esclarecida em nível molecular (Earle et al., 2014).

Abaixo estão descritos alguns dos principais ectoparasitos causadores de doenças em pisciculturas brasileiras conforme apontado por Iwashita & Maciel (2013).

As doenças fúngicas em peixes de produção são causadas por organismos oportunistas que frequentemente aproveitam condições de estresse ou lesões pré-estabelecidas. A *Saprolegnia* spp. é um exemplo clássico e frequente, de distribuição mundial, provocando lesões esbranquiçadas semelhantes a algodão na pele e nadadeiras (Noga, 2010). A identificação desse fungo ocorre por inspeção visual e exame microscópico.

As doenças causadas por protozoários têm grande relevância na aquicultura, representando cerca de 21% dos surtos (Lafferty et al., 2015). Protozoários ciliados do gênero *Trichodina* colonizam pele, brânquias e nadadeiras, especialmente sob condições de estresse ambiental e causam lesões que na maioria das vezes são porta de entrada para infecções bacterianas (Rifaat et al., 2021; Noga, 2010). Seu diagnóstico é feito por microscopia óptica, mas a diferenciação de espécies é complexa. Outro agente, o *Piscinoodinium pillulare*, causador da "doença do veludo", manifesta-se por lesões amareladas na pele e brânquias e seu diagnóstico é realizado através de microscopia óptica. O *Ichthyophthirius multifiliis*, causador do "íctio" ou "doença dos pontos brancos", causa lesões graves no epitélio branquial e é detectado por análise microscópica de muco e brânquias.

Os helmintos, como monogenéticos dos gêneros *Dactylogyrus* e *Gyrodactylus*, afetam as brânquias e a pele, provocando irritação e comprometimento respiratório. Algumas espécies, como o *Gyrodactylus salaris*, são de notificação obrigatória e podem causar grande mortalidade nas salmoniculturas. O diagnóstico envolve análise microscópica de brânquias ou raspagens de tegumento, embora a identificação precisa possa exigir técnicas moleculares como PCR.

Crustáceos parasitos são uma preocupação frequente. A *Lernaea* spp., ou "verme-âncora", por exemplo, causa lesões profundas nos tecidos dos hospedeiros e é detectado por inspeção visual e exame microscópico. No entanto, a

manifestação de sinais clínicos geralmente ocorre em estágios avançados, dificultando a intervenção precoce (Thatcher, 2006).

Os métodos tradicionais de diagnóstico em parasitologia de peixes, como inspeção visual e principalmente análise microscópica são amplamente empregados, mas apresentam desafios significativos. Esses métodos frequentemente demandam especialistas treinados para interpretar os resultados e requerem infraestrutura adequada, tornando necessário o envio de amostra para laboratórios especializados. Todos esses fatores encarecem o processo de diagnóstico e desencorajam o monitoramento constante pelo piscicultor, dificultando a profilaxia.

3. MATERIAL E MÉTODOS

A presente revisão sistemática teve como objetivo avaliar a aplicação da visão computacional e aprendizado profundo, que buscaram desenvolver soluções para o diagnóstico automatizado de doenças parasitárias em peixes. Dessa forma, uma busca exaustiva nas bases de dados Google Scholar, Scopus, Web of Science e Wiley Online Library foi realizada, utilizando os termos de busca: “inteligência artificial”, “visão computacional”, “diagnóstico automático”, “classificação de ectoparasitos”, “aprendizado profundo” e “redes neurais convolucionais” no contexto da aquicultura.

Na seleção dos artigos, os critérios de inclusão foram estudos originais que utilizaram técnicas de visão computacional para o diagnóstico de doenças parasitárias em peixes de produção, independentemente do idioma de publicação. Foram excluídos da avaliação os estudos de revisão, artigos de opinião, estudos em modelos animais diferentes de peixes, estudos que não utilizaram técnicas de visão computacional e estudos que não são de livre acesso. Os seguintes dados foram extraídos dos artigos selecionados: autores, ano de publicação, país de origem, espécie de peixe, tipo de doença, técnica de visão computacional utilizada, desempenho da técnica principal e resultados.

4. RESULTADOS E DISCUSSÃO

Estudos recentes têm demonstrado o potencial do uso de visão computacional (CV) e aprendizado profundo para o monitoramento e diagnóstico automático de doenças em pisciculturas, utilizando diferentes arquiteturas e estratégias para a análise de imagens. No entanto, o número de trabalhos verificados ainda é limitado. Na Tabela 1, são apresentados os principais resultados encontrados na literatura, que serão discutidos em detalhes nas seções seguintes.

Tabela 1. Relação dos principais estudos da literatura, que exploraram o tema visão computacional ou aprendizado profundo no diagnóstico de doenças em peixes.

Autores	País de origem	Espécie de peixe	Tipo de doença	Técnica utilizada
Malik et al. (2017)	Índia	Não especificado	<i>Não se aplica</i>	PCA-FAST-NN
Waleed et al. (2019)	Egito	Não especificado	Síndrome ulcerativa epizootica (EUS), <i>Ichthyophthirius multifiliis</i> e columnariose	Arquiteturas ResNet18, ResNet50, ResNet101 e AlexNet.
Zhang et al. (2020)	China	-	Myxosporídeos	Random Forest (RF), Support Vector Machine (SVM) e Multi-layer Perceptron (MLP)
Sikder et al. (2021)	Bangladesh	Não especificado	<i>EUS, podridão de cauda e nadadeiras, branquiomiose e piolho de peixe (Argulus spp.)</i>	M-SVMs
Hasan et al. (2022)	Malásia	Não especificado	<i>Doença dos pontos brancos (I. multifiliis) e doença dos pontos vermelhos (EUS)</i>	CNN não especificada
Gupta et al. (2022)	Noruega	Salmonídeos	<i>Lesões de pele e “piolho de peixe”</i>	VGG-19 adaptado
Ahmed et al. (2022)	Bangladesh	Salmão do Atlântico (<i>Salmo salar</i>)	<i>Não se aplica</i>	SVM com função kernel
Huang & Khabusi (2023)	Taiwan	Não especificado	<i>EUS, Ichthyophthirius multifiliis, Argulus sp., diplostomíase (“doença dos pontos pretos”), hexamitíase</i>	CNN-OSELM com Mecanismo de Atenção
Li et al. (2023)	China	Kinguio (<i>Carassius auratus</i>)	<i>Gyrodactylus kobayashi, Ichthyophthirius multifiliis e Argulus japonicus</i>	YOLOv4 com Transfer Learning

Nadja et al. (2024)	Indonésia	Carpa comum (Cyprinus carpio)	<i>Não se aplica</i>	YOLOv8
Syed et al. (2024)	Noruega	Bacalhau-do- Atlântico (<i>Gadus morhua</i>)	<i>Anisakis simplex e Pseudoterranova decipiens</i>	Arquitetura de Deep Learning (não especificada)
Cai et al. (2024)	China	Peixe-Zebra (<i>Danio rerio</i>)	<i>Viremia Primaveril da Carpa</i>	NAM-YOLOv7
Isaac et al. (2024)	Uganda	-	<i>14 doenças, como hidrodipsia</i>	VGG-16, VGG-19, DenseNet-121 e Vision Transformer
Bonnichsen et al. (2024)	Dinamarca	Truta Arco-íris (<i>Oncorhynchus mykiss</i>)	Diagnóstico precoce de I. multifiliis	Não se aplica

Malik et al. (2017) adaptaram um modelo para detecção da Síndrome Epizootica Ulcerativa (EUS), causada pelo oomiceto *Aphanomyces invadans*, em peixes utilizando um modelo chamado PCA-FAST-NN. O conjunto de imagens utilizou fotos de peixes infectados e elevou a precisão para 86%. Embora o resultado tenha melhorado as medidas de precisão, ainda manteve uma margem de erro elevada, tornando necessários mais estudos para amplificar o conjunto de dados ou aplicar técnicas de aumento de dados para obter melhor desempenho.

No Egito, Waleed et al. (2019) investigaram o uso de diferentes arquiteturas de redes neurais convolucionais (CNNs) no diagnóstico de doenças como síndrome ulcerativa epizootica (EUS), *Ichthyophthirius multifiliis* e columnariose em peixes. O estudo avaliou as arquiteturas ResNet18, ResNet50, ResNet101 e AlexNet, treinando-as com um banco de dados composto por 2160 imagens e testando-as em 314 amostras, considerando diferentes espaços de cor. A AlexNet obteve o melhor desempenho, alcançando uma acurácia de 99,04% no espaço de cor XYZ, enquanto a ResNet50 apresentou a melhor performance, com acurácia de 98,815% no espaço RGB a uma taxa de aprendizado de 0,0001. Esses resultados demonstraram que a escolha do espaço de cor e da arquitetura de CNN influencia

significativamente a acurácia no diagnóstico de doenças de peixes especialmente no treinamento de determinados modelos, como a AlexNet e a ResNet50.

Zhang et al., em 2020, realizaram um estudo sobre o uso de aprendizado de máquina para a identificação automática de diferentes espécies de mixosporídeos em peixes. O trabalho utilizou imagens microscópicas de cinco espécies diferentes de mixosporídeos, aplicando métodos de processamento de imagem para extração de características de forma e textura. Três classificadores foram avaliados: SVM, Random Forest (RF) e Multi-Layer Perceptron (MLP). Após treinamento e testes, o MLP apresentou a maior precisão, alcançando 98,89%. O estudo destacou a relevância da melhoria dos modelos por meio da otimização de hiperparâmetros e do aumento de dados, visando aplicações práticas na aquicultura e experimentos biológicos.

Em 2021, Sikder et al. desenvolveram um modelo baseado em multi vector support machine (M-SVMs) para diagnosticar as doenças Síndrome Epizoótica Ulcerativa (EUS), doença dos pontos vermelhos, *Argulus* sp., erosão de brânquias de origem bacteriana e erosão de cauda e nadadeiras. Obtiveram precisões de 98,4127, 95,2381, 98,4127, 95,2381, 96,8254 e 95,2381, respectivamente, apresentando uma média de precisão de 96,48%. O estudo foi o mais abrangente dentre os relatados nessa revisão, abordando doenças de impacto ecológico regional e global.

Gupta et al. (2022) treinaram um modelo adaptado de VGG-19 com 15 camadas convolucionais divididas em cinco blocos, com um banco de dados de 3289 imagens dividido entre as classes: peixe saudável, peixe acometido por "piolho de peixe" e peixes lesionados. O objetivo era comparar a performance do modelo desenvolvido com os modelos originais VGG-19 e VGG-16. O estudo concluiu que o modelo proposto atingiu métricas de acurácia de 96,7% superando os valores de 91,2% e 92,81% dos modelos VGG-16 e VGG-19.

Neste mesmo ano, Hasan et al. publicaram um estudo que objetivou testar a eficácia do uso de um banco de imagens de peixes acometidos ou não acometidos pela "doença dos pontos brancos" e pela "doença dos pontos vermelhos" no treinamento de redes neurais convolucionais para diagnóstico dessas doenças. Os resultados atingiram uma média de 94,44% de acurácia dentre as diferentes classificações.

Ahmed et al. (2022) focaram na detecção de peixes doentes em salmoniculturas (*Salmo salar*), utilizando técnicas de aprendizado de máquina baseadas em um banco de dados composto por 1208 imagens de salmões infectados (752) ou não infectados (456). O estudo implementou o algoritmo de Support Vector Machine (SVM) com uma função kernel para classificação de doenças. A metodologia incluiu etapas de pré-processamento e segmentação de imagens, destinadas a reduzir o ruído e melhorar a qualidade visual das amostras. A acurácia na detecção de peixes doentes foi de 91,42% sem aumento de dados e 94,12% com o uso de aumento de dados, demonstrando a eficácia do uso da SVM em conjunto com abordagens de pré-processamento de dados na detecção de patologias em peixes, embora sem distinção entre os agentes.

Em 2023, Huang e Khabusi publicaram um estudo que utilizou um banco de dados composto por 649 imagens de baixa resolução de peixes infectados ou não infectados, com imagens de peixes acometidos por diversos agentes patogênicos para o treinamento de CNNs. Eles empregaram uma Rede de Fusão Multicamadas CNN-OSELM com Mecanismo de Atenção para o reconhecimento de doenças, associando diferentes padrões de lesão de pele a agentes patogênicos específicos. O modelo alcançou uma acurácia de 94,28%, precisão de 92,67%, recall de 92,17% e F1-score de 92,42%, evidenciando a eficácia da abordagem para a identificação de doenças em peixes, mesmo em condições desafiadoras. A adição do mecanismo de atenção aprimorou a capacidade do modelo de focar nas características relevantes das imagens, tornando-o adequado para aplicações práticas na aquicultura.

O trabalho de Li et al. publicado em 2023 apresentou um modelo treinado para a detecção rápida de parasitos em peixes, focando em três espécies principais: *Ichthyophthirius multifiliis*, *Gyrodactylus kobayashii* e *Argulus japonicus*. Utilizando o algoritmo de deep learning YOLOv4, os pesquisadores desenvolveram um sistema de visão computacional que consegue identificar e quantificar esses parasitos em imagens, alcançando uma precisão média (mAP) de 95,41%. A pesquisa destaca a importância de um conjunto de dados robusto, composto por 27.930 imagens, e a aplicação de *Transfer Learning*, que permitiu o uso de pesos de um modelo pré-treinado para otimizar o desempenho na detecção. Além disso, o estudo enfatiza a eficiência do sistema, que consegue processar imagens em

apenas 0,13 segundos, contribuindo significativamente para a saúde e segurança na aquicultura ao possibilitar diagnósticos rápidos e precisos de doenças parasitárias.

Em 2024, Nadja et al., infectaram peixes experimentalmente com *Aeromonas hydrophila* com o objetivo de coletar imagens dos sinais clínicos dos peixes e alimentar um banco de dados para treinamento do modelo YOLOv8 com o objetivo de identificar automaticamente a septicemia móvel por aeromônios (MPA). Os pesquisadores incluíram descrições detalhadas das lesões, monitorando a evolução ao longo de três dias. As imagens foram obtidas através de gravações que duraram três horas por dia ao longo dos três dias de ensaio ou até a morte do peixe. Este estudo se destaca ao descrever uma abordagem padronizada de obtenção de imagens que influenciou positivamente o desempenho final. Os resultados mostraram que a metodologia foi eficiente em adquirir imagens que podem ser utilizadas para o treinamento da YOLOv8, que desempenhou uma acurácia de 91,48%. O estudo foi pioneiro ao infectar propositalmente peixes para aquisição de imagens, proporcionando uma fonte consistente para a elaboração do banco de dados.

Em 2024, pesquisadores da Noruega desenvolveram um sistema de detecção automática de nematoides em filés de peixes utilizando imagens hiperespectrais e redes neurais profundas. O estudo foi realizado em filés de bacalhau do Atlântico (*Gadus morhua*), adquiridos de uma unidade de processamento de pescado em Portugal. O sistema utiliza o equipamento Maritech Eye para capturar imagens hiperespectrais e o modelo LinkNet com um decodificador DenseNet-121. Com uma taxa de detecção de 73%, o método supera a eficiência de inspeções manuais (50%), oferecendo uma solução prática e rápida para uso em linhas de processamento industrial, melhorando a segurança e qualidade do pescado (Syed et al., 2024).

Em 2024, foi desenvolvido na China um sistema de detecção rápida para identificar sinais clínicos da viremia primaveril da carpa (Spring Viremia of Carp, SVC) em peixes utilizando visão computacional combinada com o modelo híbrido NAM-YOLO v7. O estudo envolveu o treinamento de uma rede neural convolucional baseada em imagens de peixes infectados e saudáveis em aquários experimentais. O modelo utilizou o algoritmo Auto-MSRCR para aprimorar a qualidade das

imagens, destacando diferenças sutis nos sinais clínicos. Com uma precisão de 97,3% e recall de 93,8%, o sistema demonstrou ser rápido (172 ms por imagem) e eficiente em condições experimentais, sendo aplicável a pequenas fazendas aquícolas como ferramenta acessível para detecção precoce e contenção de surtos (Cai et al., 2024).

Em 2024, em Uganda, África, um estudo sobre técnicas de visão computacional explicável para detecção de doenças em peixes utilizando aprendizado profundo com transferência de aprendizado (*transfer learning*) foi realizado. O trabalho incluiu o desenvolvimento e avaliação de cinco modelos de aprendizado profundo (CNN, DenseNet121, Vision Transformer, VGG16 e VGG19) em um conjunto de dados contendo imagens de 14 doenças, incluindo Hidropsia, Doença branquial (Gill Disease), *Lernaea* (verme-âncora), tumores e deformidades, infestações por fungos, parasitos na boca, *Ichthyophthirius multifiliis* ("doença dos pontos brancos"), monogenose por *Gyrodactylus* sp., buracos na cabeça (Holes in the Head), Erosão de nadadeiras. Com a aplicação de técnicas como LIME, Grad-CAM e integração de gradientes, os pesquisadores identificaram as características das imagens usadas pelos modelos para suas previsões. Entre os modelos avaliados, o Vision Transformer obteve o melhor desempenho, com uma acurácia de 95,05%. O estudo destaca a aplicabilidade de técnicas de IA para melhorar a compreensão e a confiança dos aquicultores no uso dessas tecnologias em sistemas de aquicultura (Ssekitto Isaac et al., 2024).

Outro estudo foi realizado com o objetivo de desenvolver um sistema de monitoramento em tempo real baseado em inteligência artificial (IA) para detectar sinais precoces de infecção por *Ichthyophthirius multifiliis* em trutas arco-íris (*Oncorhynchus mykiss*). O experimento comparou dois tanques de peixes, um infectado e outro não infectado, utilizando análise de vídeo para monitorar alterações comportamentais e de posicionamento dos peixes. Os peixes que apresentavam sinais clínicos eram retirados do tanque para confirmação do diagnóstico e, após confirmação, os frames do vídeo eram avaliados em busca de alterações de comportamento precoce. Os resultados demonstraram que peixes infectados alteraram seu posicionamento no tanque, movendo-se para áreas de maior fluxo de água a partir de 4 a 5 dias pós-infecção, antes da manifestação de sinais clínicos mais avançados. A abordagem sugere que o uso contínuo de IA pode

antecipar o diagnóstico, otimizando medidas de intervenção na produção comercial de peixes (Bonnichsen et al., 2024).

4.1 Desafios, limitações e direções para estudos futuros

Com base na revisão de literatura, é possível identificar algumas lacunas importantes no campo do diagnóstico de doenças em peixes usando visão computacional, especialmente no contexto da aquicultura tropical. Primeiramente, observa-se que a literatura sobre o uso de técnicas de visão computacional para o diagnóstico de doenças em peixes é ainda limitada, com poucos estudos abordando essa temática de forma abrangente. Além disso, entraves importantes no diagnóstico de doenças parasitárias em peixes foram relatados, como a falta de sinais clínicos patognomônicos, i.e., que indiquem precisamente a etiologia da lesão manifestada.

A concentração dos estudos retratados, na maioria asiáticos, pode resultar em uma falta de representatividade e aplicabilidade dos modelos para sistemas aquícolas de outras regiões. Embora o Brasil seja representativo no cenário mundial da piscicultura continental, especialmente na produção de espécies de peixes tropicais, não foram encontrados na literatura estudos realizados no país sobre o tema. A seguir, detalham-se as principais lacunas identificadas:

1. Concentração geográfica dos estudos: A grande maioria dos estudos foi conduzida em países do Oriente, com nenhuma pesquisa focando especificamente em sistemas aquícolas no continente americano. Essa concentração geográfica reduz a relevância e a generalização dos resultados para outros contextos.

2. Não uso de imagens microscópicas detalhadas para a identificação precisa de parasitos: Apenas um deles utilizou imagens obtidas por microscopia de raspados tegumentares ou de brânquias como base para a identificação precisa de espécies ou gêneros de parasitos.

3. Carência de bases de dados de imagens extensas e de qualidade: A maioria dos estudos relataram a dificuldade tanto em relação a extensão da base de dados de imagens disponível quanto sobre a qualidade das imagens. Tais

limitações prejudicam a generalização dos modelos para condições reais de campo, em que a obtenção de imagens de alta qualidade pode ser desafiadora devido à iluminação, movimento dos peixes e outros fatores ambientais. Outro ponto crítico é a ausência de bases de dados públicas de imagens voltadas para a verificação de sinais clínicos ou identificação de parasitos em espécies de peixes predominantes em sistemas aquícolas tropicais, como a tilápia-do-Nilo (*Oreochromis niloticus*) e tambaqui (*Colossoma macropomum*). A falta dessa base de dados dificulta o treinamento e a validação de modelos para essas espécies, limitando a aplicabilidade de tecnologias de diagnóstico parasitológico em cenários como a aquicultura brasileira.

4. Dificuldades na obtenção de imagens de qualidade: A turbidez da água e a consequente variação na transmissão de luz interferem na qualidade das imagens e vídeos subaquáticos, com flutuações significativas tanto espaciais quanto temporais. A iluminação insuficiente associada a outros fatores, como os movimentos imprevisíveis dos peixes, resulta na geração de imagens de baixa qualidade, condição que compromete a precisão e a acurácia dos modelos de diagnóstico.

Essas lacunas ressaltam a necessidade urgente de mais pesquisas direcionadas às condições específicas da aquicultura tropical e à construção de bases de dados robustas nesse contexto. Para superar as limitações e lacunas identificadas na literatura, algumas abordagens podem ser adotadas em estudos futuros, como:

- Desenvolvimento de bases de dados de imagens focadas em espécies de peixes relevantes para a aquicultura tropical, com imagens de qualidade adequada, abrangendo tanto sinais clínicos de doenças quanto parasitos.
- Integração de sensores IoT e técnicas de visão computacional para monitoramento contínuo da saúde dos peixes, reduzindo a dependência de imagens capturadas manualmente, o que pode facilitar o diagnóstico precoce e a prevenção de doenças.
- Aprimoramento de arquiteturas de CNNs para a detecção de características difíceis de visualizar, como pequenas lesões ou parasitos em imagens microscópicas, possibilitando a identificação mais precisa de agentes patológicos.

- Estudos destinados à validação da eficácia dos modelos em condições reais de aquicultura, considerando ambientes heterogêneos, diferentes espécies e a variabilidade das condições de manejo.

5. CONSIDERAÇÕES FINAIS

As ferramentas de visão computacional mostram grande potencial para otimizar a produção aquícola, especialmente no monitoramento da qualidade da água, análise do comportamento dos peixes e diagnóstico de doenças, entre outros. Contudo, um dos principais desafios é a criação de bancos de dados robustos e representativos, necessários para treinar e validar modelos de aprendizado profundo, principalmente para a piscicultura em escala comercial.

Embora haja avanços em modelos de classificação de imagens para a aquicultura, aplicados ao diagnóstico de doenças em peixes, a maioria dos estudos foi realizada no Oriente e apresenta limitações para aplicação em outras regiões tropicais, como o Brasil. É essencial desenvolver ferramentas diagnósticas para os parasitos que afetam a piscicultura brasileira, considerando a importância da atividade produtiva no país e as particularidades das espécies e desafios sanitários locais.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- AGGARWAL, C. C. **Neural networks and deep learning**. v. 10, n. 978, p. 3. Cham: Springer, 2018.
- AHMED, M. S.; AURPA, T. T.; AZAD, M. A. K. Fish disease detection using image based machine learning technique in aquaculture. **Journal of King Saud University-Computer and Information Sciences**, 34(8), 5170-5182, 2022.
- AHMED, M. S.; JEBA, S. M. SalmonScan: A novel image dataset for machine learning and deep learning analysis in fish disease detection in aquaculture. **Data in Brief**, 54, 110388, 2024.
- ALCAÍN, E.; FERNÁNDEZ, P. R.; NIETO, R.; MONTEMAYOR, A. S.; VILAS, J.; GALIANA-BORDERA, A.; MARTINEZ-GIRONES, P. M.; PRIETO-DE-LA- LASTRA, C.; RODRIGUEZ-VILA, B.; BONET, M.; RODRÍGUEZ-SÁNCHEZ, C.; YAHYAOU, I.; MALPICA, N.; BORROMEO, S.; MACHADO, F.; TORRADO-CARVAJAL, A. Hardware architectures for real-time medical imaging. **Electronics**, v. 10, n. 24, p. 3118, 2021. Disponível em: <https://doi.org/10.3390/electronics10243118>.
- BANNO, K.; KALAND, H.; CRESCITELLI, A. M.; TUENE, S. A.; AAS, G. H.; GANSEL, L. C. A novel approach for wild fish monitoring at aquaculture sites: wild fish presence analysis using computer vision. **Aquaculture Environment Interactions**, 14, 97-112, 2022.
- BISHOP, C. M.; BISHOP, H. **Deep learning: foundations and concepts**. 2ª ed. Springer, 2023.
- BONNICHSEN, L., HAUGEN, S., NGUYEN, T. L., & BIRKEVOLD, J. (2024). AI-Driven Realtime Monitoring of Early Indicators for Ichthyophthirius multifiliis in Rainbow Trout. **Journal of Fish Diseases**, 47(1), 45-54. <https://doi.org/10.1111/jfd.13976>
- BURGER, Wilhelm; BURGE, Mark J. **Digital image processing: an algorithmic introduction**. 3rd ed. Cham: Springer, 2022. 945 p.
- CAI, L., HE, Q., & XUE, Y. (2024). Detection of Spring Viremia of Carp in Zebrafish Using Hyperspectral Imaging and Deep Learning. **Aquaculture Research**, 55(1), 120-132. <https://doi.org/10.1111/are.15726>
- CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, (6), p. 679-698, 1986.

- CASTLEMAN, K. R. **Digital image processing**. Upper Saddle River: Prentice Hall Press, 1996.
- Duhayyim, M. A., Alshahrani, H. M., Al-Wesabi, F. N., Alamgeer, M., Hilal, A. M., & Hamza, M. A. **Intelligent deep learning based automated fish detection model for UWSN**. *Computers, Materials & Continua*, 70, 5871–5887, 2022.
- EARLE, G.; HINTZ, W. New approaches for controlling *Saprolegnia parasitica*, the causal agent of a devastating fish disease. ***Tropical Life Sciences Research***, v. 25, n. 2, p. 101, 2014.
- EVERINGHAM, M.; VAN GOOF, D.; ZISSERMAN, A.; WILDE, B.; SINGH, P.; NAYAR, S.; WU, Z.; SHI, J.; WEI, Y.; GOOI, M.; CHENG, S. The Pascal Visual Object Classes (VOC) Challenge. ***International Journal of Computer Vision***, 2010.
- FRANK, E.; WITTEN, I. H.; HALL, M. A. **Data Mining: Practical Machine Learning Tools and Techniques**. 3^a ed. Elsevier, Burlington, MA, 2011. 600 p.
- GE, H.; ZHU, Z.; DAI, Y.; WANG, B.; WU, X. Facial expression recognition based on deep learning. ***Computer Methods and Programs in Biomedicine***, v. 215, 106621, mar. 2022.
- GHASSEMIAN, H. Hyperspectral imaging and dimensionality reduction: An overview. ***Advances in Remote Sensing***, v. 5, n. 3, p. 66-76, 2016.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. 2^a ed. Cambridge: MIT Press, 2016. 800 p.
- GOODFELLOW, I.; POMERLEAU, D.; CHOUDHURY, D.; ZHANG, L. Generative adversarial nets. ***Advances in Neural Information Processing Systems***, v. 27, 2014.
- HABIBI AGHDAM, H., & JAHANI HERAVI, E. **Convolutional neural networks**, Springer, 2017.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The elements of statistical learning: data mining, inference, and prediction. 2^a ed. Corr. 9th Printing. New York: Springer, 2009. 745 p.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. ***Neural Computation***, v. 9, n. 8, p. 1735-1780, 1997.
- HOWARD, A. G.; ZHU, M.; CHEN, B.; LIU, L.; ZHU, Y.; KUNISAWA, A.; LEE, M. L. MobileNets: efficient convolutional neural networks for mobile vision applications.

- arXiv preprint**, arXiv:1704.04861, 2017. Disponível em: <https://arxiv.org/abs/1704.04861>. Acesso em: 16 nov. 2024.
- HUANG, Y. P.; KHABUSI, S. P. A CNN-OSELM multi-layer fusion network with attention mechanism for fish disease recognition in aquaculture. **IEEE Access**, 11, 58729-58744, 2023.
- IWASHITA, M. K. P., & MACIEL, P. O. Princípios básicos de sanidade de peixes. In: **Piscicultura de água doce: Multiplicando conhecimentos**. Editores Técnicos, Ana Paula O. Rodrigues...[et al.]. Brasília, DF: Embrapa, 2013.
- JAIN, R.; KASTURI, R.; SCHUNCK, B. G. **Machine vision**. v. 5, p. 309-364. New York: McGraw-Hill, 1995.
- KHAN, S.; RAHMANI, H.; SHAH, S. A. A.; BENNAMOUN, M.; MEDIONI, G.; DICKINSON, S. **A guide to convolutional neural networks for computer vision**. 2018.
- KUKUSHKIN, A.; SOKOLOVA, E.; ZHAROV, I. Sensors for low-light imaging: Applications and limitations. **Journal of Sensor Technology**, v. 9, n. 2, p. 45-58, 2020.
- LAFFERTY, K.D.; HARVELL, C.D.; CONRAD, J.M.; FRIEDMAN, C.S.; KENT, M.L.; KURIS, A.M.; POWELL, E.N.; RONDEAU, D.; SAKSIDA, S.M. Infectious diseases affect marine fisheries and aquaculture economics. In: CARLSON, C.A.; GIOVANNONI, S.J. (Eds.). **Annual Review of Marine Science**. San Mateo, CA: Annual Review of Marine Science, 2015. v. 7, p. 471–496.
- LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep learning**. **Nature**, v. 521, n. 7553, p. 436-444, 2015. Disponível em: <https://doi.org/10.1038/nature14539>.
- LI, J.; LIAN, Z.; WU, Z.; ZENG, L.; MU, L.; YUAN, Y.; ...; YE, J. Artificial intelligence–based method for the rapid detection of fish parasites (*Ichthyophthirius multifiliis*, *Gyrodactylus kobayashii*, and *Argulus japonicus*). **Aquaculture**, 563, 738790, 2023.
- LIN, T.-Y.; MAA, D. A.; HARTLEY, T. J. Microsoft COCO: Common Objects in Context. In: **EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV)**, 2014.
- LITJENS, GEERT; KOOI, THIJS; EHTESHAMI BEJNORDI, Babak; SETIO, Arnaud Arindra Adiyoso; CIOMPI, Francesco; GHAFOORIAN, Mohsen; LAK, Jeroen A.W.M. van der; GINNEKEN, Bram van; SÁNCHEZ, Clara I. A survey on deep

- learning in medical image analysis. **Medical Image Analysis**, v. 36, p. 60-88, 2017. DOI: 10.1016/j.media.2017.07.005.
- MAXWELL, A. E., WARNER, T. A., & GUILLÉN, L. A. (2021). **Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review**. *Remote Sensing*, 13(13), 2450.
- NOGA, E. J. **Fish Disease: Diagnosis and Treatment**. Wiley-Blackwell, 2. ed. St. Louis: Elsevier, 2010. 560 p.
- PICCININI, G. The first computational theory of mind and brain: A close look at McCulloch and Pitts's "Logical Calculus of Ideas Immanent in Nervous Activity". **Synthese**, v. 141, n. 2, p. 175-215, 2004.
- RANJAN, R.; TSUKUDA, S.; GOOD, C. MortCam: An Artificial Intelligence-aided fish mortality detection and alert system for recirculating aquaculture. **Aquacultural Engineering**, v. 102, 102341, 2023.
- REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. In: **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2016.
- RIFAAT, M.; ALCAÍN, E.; FERNÁNDEZ, P. R.; NIETO, R.; MONTEMAYOR, A. S.; VILAS, J.; GALIANA-BORDERA, A.; MARTINEZ-GIRONES, P. M.; PRIETO-DE-LA-LASTRA, C.; RODRIGUEZ-VILA, B.; BONET, M.; RODRÍGUEZ-SÁNCHEZ, C.; YAHYAOU, I.; MALPICA, N.; BORROMEO, S.; MACHADO, F.; TORRADO-CARVAJAL, E. Trichodina spp. as protozoan parasites in fish: a comprehensive review of their occurrence, impact and control measures. **Journal of Aquatic Animal Health**, v. 33, n. 4, p. 213-227, 2021. DOI: 10.1016/j.jaah.2021.04.002.
- RUSSAKOVSKY, O.; SU, H.; ZHOU, W.; YANG, L.; HSU, Y.; JIA, Y.; LEE, S.; NG, A. Y.; KOSER, J.; MA, S.; PERONA, P.; DOLLAR, P.; KRAUSE, J.; MURPHY, K. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, 2015.
- SERRA, J. Image Analysis and Mathematical Morphology. **New York: Academic Press**, 1982.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **International Conference on Learning Representations (ICLR)**, 2015. Disponível em: <https://arxiv.org/abs/1409.1556>. Acesso em: 19 nov. 2024.

- SRIVASTAVA, N.; HINTON, G. E.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: a simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, v. 15, n. 1, p. 1929-1958, 2014.
- SSEKITTO, I., KIGOZI, J., & KYOMUHANGI, T. (2024). Explainable Machine Vision Techniques for Fish Disease Detection with Deep Transfer Learning. **Artificial Intelligence in Aquaculture**, 9(1), 101-115. <https://doi.org/10.1016/j.aia.2024.00111>
- SYED, S., ORTEGA, S., ANDERSSSEN, K. E., NILSEN, H. A., & HEIA, K. (2024). Hyperspectral Imaging and Deep Learning for Parasite Detection in White Fish under Industrial Conditions. **Scientific Reports**, 14(1), 27426. <https://doi.org/10.1038/s41598-024-76808-w>
- SZEGEDY, C.; ZHU, Y.; YANG, J.; LIU, S.; SINHA, S.; SHI, H.; KANAZAWA, A.; KAY, B.; BA, J.; LE, Q. V. **Going deeper with convolutions**. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**, 2015. p. 1-9.
- SZELISKI, R. **Computer Vision: Algorithms and Applications**. 2^a ed. Springer, 2010.
- THATCHER, V. E. (2006). **Amazon fish parasites (Vol. 1)**. Pensoft Publishers.
- TEOH, T. T. **Convolutional neural networks for medical applications**. Springer, 2023.
- ULTRALYTICS. **YOLOv5**. Disponível em: <https://github.com/ultralytics/yolov5>. Acesso em: 16 nov. 2024.
- WOO, P. T. K.; BUCHMANN, K. **Fish Parasites: Pathobiology and Protection**. CABI Publishing, 2012.
- XUE, Y., BASTIAANSEN, J. W. M., KHAN, H. A., & KOMEN, H. **An analytical framework to predict slaughter traits from images in fish**. *Aquaculture*, 566, 739175, 2023.
- YANG, Z., ZHANG, T., & WANG, J. (2021). Advances in Computer Vision for Smart Aquaculture: A Review of Technologies and Applications., 30(4), 102-117. <https://doi.org/10.1186/s12345-020-09486-2>

- ZHANG, X., LI, Y., & ZHAO, Q. (2020). Application of Machine Learning in the Automatic Identification of Fish Parasitic Viscera Species. **International Journal of Aquatic Biology**, 7(3), 142-151. <https://doi.org/10.22034/ijab.v7i3.123>
- ZHENG, X.; LIANG, Y.; LIU, W. Applications of artificial intelligence in intelligent aquaculture: A review. **Aquaculture**, v. 529, 735778, 2020.
- ZHU, Z.; DUAN, C.; DONG, C.; WENG, S.; HE, J. Epidemiological situation and phylogenetic relationship of *Vibrio harveyi* in marine-cultured fishes in China and Southeast Asia. **Aquaculture**, v. 529, p. 735652, 2020.

Capítulo II: METODOLOGIA PARA COLETA E PROCESSAMENTO DE IMAGENS DE ECTOPARASITOS DE PEIXES PARA TREINAMENTO E VALIDAÇÃO DE REDES NEURAI CONVOLUCIONAIS

Resumo: A identificação precisa de ectoparasitos em peixes é essencial para o seu controle e mitigação dos impactos negativos na produção aquícola. Este estudo propõe uma metodologia para coleta de amostras, bem como a captura e preparo de imagens como etapa inicial para a construção de uma base de dados para treinamento e validação de ferramentas automatizadas de diagnóstico de doenças parasitárias na aquicultura baseadas na visão computacional. Amostras de ectoparasitos foram coletadas em diferentes espécies de peixes provenientes de pisciculturas nos estados de São Paulo e Goiás e fixadas em lâminas para captura de imagens em laboratório. As imagens obtidas em formato .tiff foram preparadas para uso em diferentes arquiteturas de rede neural artificial convolucional (CNN). A metodologia proposta abrange desde o processo de coleta de amostras, captura das imagens e rotulagem dos dados até o pré-processamento das imagens, com ajuste para a resolução padrão de 224x224 pixels e conversão de RGB para escala de cinza, além da limiarização aplicada através da técnica `cv.THRESH_TOZERO_INV` da biblioteca OpenCV, com limiares de 120, 150 e 170, visando melhorar a visualização e extração das características dos parasitos. Como etapa final, a aplicação da técnica de *data augmentation* aumenta o número de imagens, expandindo a quantidade de exemplos disponíveis.

Palavras-chave: aquicultura, banco de dados, inteligência artificial, automação.

COLLECTION AND PROCESSING OF IMAGES OF FISH ECTOPARASITE FOR TRAINING A VALIDATION OF CONVOLUTIONAL NEURAL NETWORKs

Abstract: The accurate identification of ectoparasites in fish is essential for their control and mitigation of their negative impacts on aquaculture production. This study proposes a methodology for sample collection, as well as image capture and preparation as an initial step in building a database for training and validating automated diagnostic tools for parasitic diseases in aquaculture based on computer vision. Ectoparasite samples were collected from different fish species in fish farms in the states of São Paulo and Goiás, Brazil, and fixed on slides for laboratory image capture. The images obtained in .tiff format were prepared for use in different convolutional neural network (CNN) architectures. The proposed methodology covers the entire process from sample collection, image capture, and data labeling to image preprocessing, including resizing to a standard resolution of 224x224 pixels, conversion from RGB to grayscale, and thresholding applied using the OpenCV library's `cv.THRESH_TOZERO_INV` technique with thresholds of 120, 150, and 170, aimed at improving the visualization and extraction of parasite features. As a final step, the application of data augmentation techniques increases the number of images, expanding the quantity of available examples

keywords: aquaculture, database, artificial intelligence, automation.

1. INTRODUÇÃO

Atualmente, a Inteligência Artificial (IA) tem se consolidado como um tema central em diversas áreas de estudo, com o objetivo de desenvolver ferramentas para automação e apoio à tomada de decisão. Os resultados dessas pesquisas têm se tornado cada vez mais evidentes em nosso cotidiano, por meio de diferentes inovações, sendo os carros autônomos e os assistentes virtuais dois dos exemplos notáveis. Dentro dessa ampla área, a Visão Computacional (CV) se destaca como uma subárea dedicada ao desenvolvimento de soluções para o reconhecimento, contagem e classificação de objetos em imagens ou vídeos (Frank et al., 2010). Utilizando algoritmos de aprendizado de máquinas, como as Redes Neurais Convolucionais (CNNs), a CV permite que sistemas interpretem e processem informações visuais de maneira eficaz (Szeliski, 2011).

O uso da visão computacional (CV) tem crescido significativamente em aplicações voltadas para a análise automatizada de imagens, com foco no desenvolvimento de soluções inovadoras para a sanidade animal. Essa abordagem traz a perspectiva de reduções no tempo e os esforços para o diagnóstico de doenças, bem como na elaboração de planos de tratamento e prognósticos (Xu et al., 2024). Contudo, o desenvolvimento dessas soluções depende da disponibilidade de bases de dados de imagens que sejam não apenas amplas em números de exemplos, mas também de qualidade suficiente para identificar padrões relevantes e permitir o treinamento eficaz de modelos baseados em aprendizado profundo (DL) (Szeliski, 2011). Um dos principais desafios nesse contexto é o *overfitting* (sobreajuste), que é frequentemente causado pela disponibilidade limitada de imagens para o treinamento dos modelos (Brigato et al., 2022). Mesmo em cenários em que existam bases de dados mais abrangentes, problemas relacionados à qualidade das imagens, como baixa resolução e falta de padronização nos processos de aquisição, podem comprometer a eficiência das soluções envolvidas (Zhang et al., 2023).

Uma das formas de ampliar as bases de dados disponíveis são as chamadas operações de aumento de dados (*data augmentation*). No contexto da CV, o aumento de dados refere-se à aplicação de transformações controladas e semanticamente consistentes nas imagens originais para expandir a quantidade e a diversidade dos dados de treinamento (Shorten; Khoshgoftaar, 2019). Quanto à qualidade das imagens, a aplicação de filtros pode ajudar a eliminar ruídos,

melhorar a resolução (*super-resolution*) e realçar detalhes importantes, facilitando a extração de características relevantes pelo modelo de DL (Burger; Burger, 2022). Outra estratégia importante consiste na conversão do espaço de cores VGB (vermelho, Verde e Azul) para a escala de cinza, mantendo as informações de intensidade. Essa transformação é vantajosa quando variações cromáticas não são cruciais (Burger; Burger, 2022).

Diversos estudos sobre o uso de visão computacional (CV) para a automação do diagnóstico de doenças na aquicultura têm mostrado resultados significativos, comprovando a viabilidade de tornar esse processo mais ágil e preciso (Waleed et al., 2019; Ahmed et al., 2022; Huang; Khabusi, 2023; Li et al., 2023). Contudo, essas pesquisas também apontam lacunas importantes que devem ser abordadas, sugerindo novas direções para investigações futuras. Entre as principais lacunas, destaca-se a escassez de bases de dados de imagens de alta qualidade e abrangentes, especialmente aquelas voltadas ao diagnóstico de doenças parasitárias em peixes tropicais e neotropicais de interesse comercial. O Brasil, como um país tropical e um dos maiores produtores de pescado no cenário global (FAO, 2024), possui grande interesse em tecnologias aplicadas à sanidade de peixes, visando garantir o crescimento sustentável e a segurança dos alimentos da aquicultura. Dessa forma, este estudo pretende oferecer ferramentas metodológicas que possibilitem a criação de novas bases de dados para elaboração de modelos de diagnóstico automático baseados em sistemas de redes neurais convolucionais (CNNs).

2. OBJETIVOS

Este estudo teve como objetivo desenvolver uma metodologia para a elaboração de bases de dados robustas contendo imagens de alta qualidade de agentes parasitários de peixes obtidas através de microscopia óptica. Essas bases de dados podem servir como fundamento para pesquisas futuras voltadas ao desenvolvimento de tecnologias baseadas em CV para o diagnóstico automático de doenças parasitárias em peixes.

3. METODOLOGIA

3.1 Coleta de amostras de ectoparasitos e geração das imagens digitais

A etapa de coletas das amostras de brânquias e tegumento é um processo técnico que deve ser realizado por uma equipe qualificada e seguir critérios que otimizem o achado parasitológico para registro das imagens.

A Figura 3 apresenta um fluxograma que ilustra tomadas de decisões durante o processo de coleta das amostras de ectoparasitos de peixes até a captura de imagens digitais, com critérios que evitam a desafixação dos parasitos nos tecidos e a redução do número de parasitos capturados pelo procedimento de raspagem tecidual.




Figura 3. Fluxograma do procedimento de amostragem e obtenção de imagens

Neste estudo, as amostras de ectoparasitos foram coletadas de peixes com sinais clínicos sugestivos de parasitose, como letargia, prurido, isolamento social e natação errática. Os espécimes foram obtidos no Centro de Aquicultura da UNESP em Jaboticabal, a partir de peixes moribundos que seriam destinados à eutanásia e em pisciculturas comerciais localizadas no estado de Goiás.

A coleta dos ectoparasitos seguiu a metodologia adaptada descrita por Jerônimo et al. (2011), que consistiu em raspados de tegumento e brânquias. Para isso, os peixes foram anestesiados por aspersão branquial com solução de benzocaína em água na dosagem de 180mg/L de solução (DA ROCHA et al. 2012). A escolha deste método de anestesia foi baseada na descrição de Treves-Brown (2000), que sugere a aspersão branquial como uma alternativa ao método de imersão, que pode reduzir o número de parasitos aderidos à pele e brânquias dos animais, uma vez que a imersão pode causar o desprendimento dos parasitos durante a exposição, dificultando sua coleta.

Após a anestesia, as superfícies corporais dos peixes foram examinadas quanto à presença de lesões cutâneas indicativas de parasitose.. O raspado do tegumento foi realizado com lâminas de vidro no sentido craniocaudal, e as amostras das brânquias foram obtidas do lado direito do animal, onde não foi aplicada a anestesia. Cada amostra foi depositada em lâminas de vidro, coberta com lamínulas para preservar os parasitos em uma fina camada de fluido, o que facilitou a observação microscópica. Após a coleta, os peixes foram eutanasiados por aprofundamento do plano anestésico e a morte confirmada pela completa ausência de batimentos operculares e de reflexo de suspensão observado através da suspensão horizontal do animal.

As lâminas foram analisadas imediatamente após a confecção e as imagens capturadas com microscópio óptico (Leica DM 2500), com câmera acoplada (Flexacam C3 12MP), utilizando o software Leica Application Suite versão 3.8. As ampliações utilizadas foram de 40x e 100x sob condições variadas de iluminação para assegurar diversidade visual no conjunto de dados, fator importante para o aprendizado do modelo (Mallat, 2016). Para obter diferentes perfis dos parasitos, as amostras já registradas foram mecanicamente manipuladas, possibilitando a exploração de características tridimensionais e morfológicas.

A escala de leitura das imagens capturadas é uma informação crucial para garantir a compreensão do modelo de CNN que será desenvolvido, pois permite a diferenciação padronizada do tamanho dos parasitos. Essa informação deve estar explícita em cada uma das imagens armazenadas no banco de dados.

Parasitos macroscópicos identificados durante o exame físico, como os crustáceos dos gêneros *Argulus* e *Dolops*, podem ser analisados e fotografados com o auxílio de uma lupa parasitológica equipada com câmera acoplada, especialmente quando seu tamanho excede a capacidade de visualização no menor aumento do microscópio. Essa abordagem assegura a captura de detalhes morfológicos importantes para a identificação e análise precisa desses organismos.

3.2 Rotulagem e divisão do banco de dados

O processo de rotulagem é uma etapa fundamental no desenvolvimento de modelos de Redes Neurais Convolucionais (CNNs), especialmente em aplicações de diagnóstico parasitológico de peixes. A rotulagem deve ser realizada por equipes especializadas, compostas por parasitologistas com ampla experiência no diagnóstico de parasitos de peixes. A precisão nessa etapa é crucial, pois erros ou inconsistências na rotulagem podem comprometer a eficiência do modelo, levando a previsões incorretas e reduzindo a confiabilidade do sistema.

Cada imagem do banco de dados deve ser cuidadosamente analisada e rotulada de acordo com a presença ou ausência de parasitos, bem como com a identificação das espécies, quando aplicável. A rotulagem pode incluir anotações detalhadas, como caixas delimitadoras (Figura 4) para indicar a localização exata dos parasitos nas imagens, ou segmentação semântica para destacar áreas específicas de interesse. Esse procedimento pode ser realizado com auxílio de ferramentas como o Computer Vision Annotation Tool (CVAT). Além disso, é importante que os parasitologistas sigam protocolos padronizados para garantir a consistência das anotações, evitando ambiguidades ou interpretações subjetivas.




Figura 4. Rotulagem das imagens com caixas delimitadoras

Após a rotulagem, o banco de dados deve ser dividido em conjuntos de treinamento, validação e teste. A divisão deve ser feita de forma estratificada, preservando a proporção de cada espécie de parasitos em todos os subconjuntos. Isso é especialmente importante em aplicações médicas, em que algumas classes de parasitas são menos prevalentes que outras. A estratificação garante que o modelo seja exposto a uma distribuição mais representativa das classes durante o treinamento e seja avaliado de forma justa durante a validação e o teste.

Além disso, é recomendável que imagens complexas, como aquelas que contêm múltiplos parasitos ou casos ambíguos, sejam destinadas exclusivamente aos conjuntos de validação e teste. Essas imagens representam cenários desafiadores que avaliam a capacidade do modelo de generalizar para situações reais, em que a presença de múltiplos parasitos ou condições atípicas é comum. Essa abordagem não apenas melhora a robustez do modelo, mas também fornece uma avaliação mais precisa de seu desempenho em condições práticas. O processo de subdivisão do banco de dados é demonstrado através da Figura 5.




Figura 5. Fluxograma do procedimento de rotulagem dos dados

3.3 Pré-processamento das imagens

O pré-processamento das imagens foi realizado no ambiente integrado de desenvolvimento (IDE) gratuito Spyder, amplamente utilizado por cientistas de dados e desenvolvedores para aplicações em Python (Spyder, 2024). As funções utilizadas pertencem à biblioteca Python OpenCV.

Inicialmente, as imagens digitais obtidas foram redimensionadas para 224x224 pixels, a partir da função `cv2.resize()`, uma resolução comumente utilizada em diversas arquiteturas de redes neurais convolucionais (CNNs) em tarefas de classificação de imagens, sendo exemplos: AlexNet, VGG, ResNet e MobileNet.

As imagens digitais das classes *Ichthyophthirius multifiliis*, tricodinídeos e monogenéticos foram convertidas do espaço de cores RGB para a escala de cinza. Essa transformação foi realizada com o objetivo de reduzir o custo computacional, mantendo as informações relevantes, como texturas, contraste e formas, que são fundamentais para a identificação dos parasitos, mas retirando o espaço de cores que não é essencial para a diferenciação dessas classes. A conversão para escala

de cinza simplifica as imagens ao eliminar as informações cromáticas, sem comprometer os aspectos estruturais necessários para o processamento e análise eficientes.

Outra abordagem testada, em condição paralela à alteração direta do espaço de cores RGB para a escala de cinza, foi a limiarização. Esse processo de transformação de imagens tem como objetivo segmentar e realçar características específicas, convertendo uma imagem em uma versão binária (preto e branco) (Gonzalez; Woods, 2019). Nesse processo, os pixels com intensidade abaixo de um valor específico de limiar são definidos como preto, enquanto os pixels com intensidade acima desse valor são atribuídos à cor branca. Dessa maneira, é possível destacar bordas e contornos, reduzir o ruído e segmentar as regiões de interesse, facilitando a análise automática e melhorando a eficiência dos processos subsequentes. No presente estudo, foram testados os limiares 120, 150 e 170 a partir da função `cv.THRESH_TOZERO_INV`.

Com o objetivo de expandir o conjunto de imagens digitais e tornar a base de dados mais robusta para modelos de CNNs, foram aplicadas técnicas de aumento de dados (*data augmentation*) antes da limiarização ou da conversão direta do espaço de cores RGB para a escala de cinza. Essas técnicas incluíram a geração de variações nas imagens, como rotação, ajuste de brilho e contraste, espelhamento (horizontal e vertical) e cortes aleatórios. Essas transformações auxiliam o modelo a reconhecer os parasitos em diversas orientações e condições de captura, simulando um ambiente microscópico real (Perez; Wang, 2017). Por último, as imagens pré-processadas foram rotuladas manualmente, para serem utilizadas no treinamento de modelos de CNNs.

4. RESULTADOS E DISCUSSÃO

4.1 Qualidade e Diversidade do Conjunto de Dados

Durante o processo da coleta de amostras, foi possível identificar e registrar imagens dos principais agentes associados a doenças parasitárias nesses peixes, como *Epistylis* sp., *Saprolegnia* sp., *Ichthyophthirius multifiliis*, *Piscinoodinium* sp., tricotodídeos, lerneídeos e monogenéticos. Após o registro das imagens em laboratório, foram obtidas 1009 imagens de parasitos, que constituíram o banco de dados de imagens inicial deste estudo, além de 9.737 frames obtidos através da

gravação de vídeos curtos (de dez segundos a um minuto) dos parasitos ainda vivos e em movimento na lâmina.

A distribuição das classes no banco de dados reflete a prevalência dos parasitos na região de coleta, bem como o esforço para documentar as diferentes morfologias parasitárias. A classe Tricodinídeos foi a mais representativa, compondo 56,79% do total com 524 imagens, seguida por Monogenea (157 imagens, 17,14%). Outras classes presentes no conjunto de dados são *Epistylis* (90 imagens, 9,82%), *Saprolegnia* (83 imagens, 9,06%), *Piscinoodinium* (57 imagens, 3,05%) e *Ichthyophthirius multifiliis* (17 imagens, 1,85%). Esses resultados refletem as prevalências específicas dessas espécies nas regiões de origem dos peixes que consta na tabela 2.

1 **Tabela 2.** Dados das coletas parasitológicas: Data, espécie de peixe, número de exemplares, origem geográfica, fase de desenvolvimento, sinais clínicos,
2 parasitos identificados e grau de infestação.

Data	Espécie	Animais	Origem	Fase	Sinais Clínicos	Parasitos Identificados	
11/03/24	Tilápia	5	Sales de Oliveira (São Paulo)	Adulto	Isolamento social, erosão de nadadeiras	Tricodinídeos	-
12/03/24	Tilápia	8	Sales de Oliveira (São Paulo)	Adulto	Não observado	Tricodinídeos	-
14/03/24	Tilápia	7	Sales de Oliveira (São Paulo)	Adulto	Isolamento social	Tricodinídeos	-
15/03/24	Tilápia	5	Sales de Oliveira (São Paulo)	Adulto	Hiperpigmentação de pele	Tricodinídeos	Tricodinídeos
19/03/24	Tilápia	5	Indiaporã (São Paulo)	Adulto	Não observado	Tricodinídeos	-
20/03/2024	Tilápia	8	Sales de Oliveira (São Paulo)	Juvenil e Adulto	Não observado	Tricodinídeos	-
22/03/24	Tilápia	6	Sales de Oliveira (São Paulo)	Adulto	Hipopigmentação de pele	Tricodinídeos	Tricodinídeos
25/03/24	Tilápia	6	Passos (Minas Gerais)	Alevinos	Não observado	Tricodinídeos	Tricodinídeos e monogenéticos
28/03/24	Tilápia	7	Sales de Oliveira (São Paulo)	Adulto	Petéquias, malformação de boca	Tricodinídeos	-
29/03/24	Tilápia	5	Indiaporã (São Paulo)	Adulto	Petéquias e lesões cutâneas de espessura total com padrão multifocal, orifícios na cabeça e linha lateral	Epistylis sp., tricodinídeos	Tricodinídeos e monogenéticos
31/03/2024	Tilápia	10	Indiaporã (São Paulo)	Adulto	Petéquias, lesão cutânea de espessura total, erosão de nadadeiras, orifícios na cabeça e linha lateral	Epistylis sp., tricodinídeos, Saprolegnia sp.	Tricodinídeos e monogenéticos
Data	Espécie	Animais	Origem	Fase	Sinais Clínicos	Parasitos Identificados	

02/04/2024	Tilápia	5	Indiaporã (São Paulo)	Adulto	Petéquias e lesões cutâneas de espessura total com padrão multifocal orifícios na cabeça e linha lateral	Epistylis sp., tricodinídeos	Tricodinídeos e monogenéticos
03/04/2024	Tilápia	4	Indiaporã (São Paulo)	Adulto	Lesões semelhantes a "tufos de algodão" com coloração amarronzada, opacidade corneal	Saprolegnia sp., tricodinídeos	Monogenéticos
04/04/2024	Tilápia	3	Indiaporã (São Paulo)	Adulto	Erosão de nadadeiras, lesões semelhantes a tufos de algodão, orifícios na cabeça e linha lateral	Saprolegnia sp., tricodinídeos	Monogenéticos
05/04/2024	Tilápia	3	Indiaporã (São Paulo)	Adulto	Erosão de nadadeiras, lesões semelhantes a tufos de algodão, opacidade corneal, petéquias e orifícios na cabeça e linha lateral	Saprolegnia sp., tricodinídeos	-
07/04/2024	Tilápia	3	Sales de Oliveira (São Paulo)	Juvenil e Adulto	abscesso esbranquiçado de aspecto macio ao toque na face lateral da nadadeira peitoral, malformação de boca e orifícios na cabeça e linha lateral	Tricodinídeos	Tricodinídeos e monogenéticos
Data	Espécie	Animais	Origem	Fase	Sinais Clínicos	Parasitos Identificados	
08/04/2024	Tilápia	5	Sales de Oliveira (São Paulo)	Juvenil e Adulto	Hiperpigmentação de pele e prurido	Tricodinídeos	Tricodinídeos e monogenéticos

09/04/2024	Tilápia	5	Sales de Oliveira (São Paulo)	Juvenil e Adulto	Hiperpigmentação de pele e prurido	Tricodinídeos	Tricodinídeos e monogenéticos
10/04/2024	Tilápia	5	Sales de Oliveira (São Paulo)	Juvenil e Adulto	Hiperpigmentação de pele e prurido	Tricodinídeos	Tricodinídeos e monogenéticos
18/04/24	Lambari	7	Jaboticabal (São Paulo)	Adulto	Petéquias	Lernaea cyprinacea	-
23/04/24	Lambari	5	Jaboticabal (São Paulo)	Adulto	Petéquias	Lernaea cyprinacea	-
26/04/24	Lambari	5	Jaboticabal (São Paulo)	Adulto	Petéquias	Lernaea cyprinacea	-
03/05/24	Lambari	5	Jaboticabal (São Paulo)	Adulto	Petéquias	Lernaea cyprinacea	-
03/06/24	Coridora	3	Jundiaí (São Paulo)	Adulto	Lesões semelhantes a "veludo" de aspecto amarronzado no dorso e abdome	Tricodinídeos e piscinoodinium sp.	-
17/06/24	Tilápia	5	Jaboticabal (São Paulo)	Adulto	Hipopigmentação de pele	Tricodinídeos	Tricodinídeos
18/06/24	Tilápia	5	Jaboticabal (São Paulo)	Adulto	Hipopigmentação de pele	Tricodinídeos	Tricodinídeos
27/06/24	Lambari	3	Jundiaí (São Paulo)	Adulto	petéquias, erosão de nadadeiras, erosão de brânquias	Ichthyophthirius multifiliis	-
Data	Espécie	Animais	Origem	Fase	Sinais Clínicos	Parasitos Identificados	
05/09/24	Tambaqui	5	Rio Verde (Goiás)	Adulto	-	Tricodinídeos, piscinoodinium	-

						sp. e monogenéticos	
17/09/24	Pirarucu	6	Rio Verde (Goiás)	Juvenil	-	Tricodinídeos	-
26/09/24	Pirarara	3	Rio Verde (Goiás)	Adulto	Natação errática, permanência na superfície, boquejamento, erosão de brânquias	-	Monogenéticos
10/10/24	Patinga	4	Rio Verde (Goiás)	Adulto	Lesões semelhantes a "veludo" de aspecto amarronzado no lado direito	Tricodinídeos e piscinoodinium sp.	Piscinoodinium sp.
23/10/24	Patinga	7	Rio Verde (Goiás)	Adulto	Erosão de nadadeiras	Tricodinídeos	-
07/11/24	Patinga	10	Rio Verde (Goiás)	juvenil	Erosão de nadadeiras	Tricodinídeos	-
11/11/24	Tilápia	10	Indianópolis (Goiás)	juvenil	Prurido, hiperpigmentação de pele, perda de escamas	Tricodinídeos	-
21/11/24	Tilápia	12	Indianópolis (Goiás)	juvenil	Prurido, perda de escamas	Tricodinídeos	-
04/12/24	Tilápia	10	Niquelândia (Goiás)	juvenil	Boquejamento na superfície, anorexia	-	Monogenéticos
Total		218					

4 A classificação padronizada dos sinais clínicos garante a reprodutibilidade,
5 comparabilidade e precisão dos resultados, permitindo que diferentes estudos
6 utilizem terminologias uniformes. Essa abordagem é essencial para o
7 desenvolvimento de protocolos diagnósticos na aquicultura. A tabela 3 abaixo
8 descreve detalhadamente os sinais clínicos observados durante o período das
9 coletas ictioparasitológicas.

Sinal Clínico	Descrição
Isolamento social	Peixes afastados do cardume e que permanecem em áreas menos movimentadas do tanque
Erosão de nadadeiras	Processo degenerativo caracterizado por desgaste progressivo do tecido das nadadeiras, podendo resultar em bordas irregulares e necrosadas
Hiperpigmentação da pele	Aumento na deposição de melanina na epiderme que resulta no escurecimento da pele
Petéquias	Pequenos pontos hemorrágicos subcutâneos.
Malformação de boca	Anomalia que acomete a estrutura da boca e resulta em irregularidade
Lesões cutâneas de espessura total com padrão multifocal	Úlceras profundas que envolvem a epiderme, derme e, em casos graves, camadas musculares
Orifícios na cabeça e linha lateral	Lesões ulcerativas perfurantes associadas a infestações parasitárias, como as causadas por <i>Spironucleus spp.</i>
Lesões semelhantes a "tufos de algodão"	Crescimento filamentoso branco acinzentado, tipicamente em áreas previamente lesionadas.

Opacidade corneal	Perda de transparência da córnea
Abscesso	Acúmulo de pus em tecidos profundos que se manifesta superficialmente por aumento de volume. Pode ser macio ao toque ou rígido.
Lesões semelhantes a "veludo"	Crescimento filamentoso amarronzado sobre a superfície da pele.
Erosão de brânquias	Degeneração e destruição progressiva do tecido branquial
Natação errática	Movimentos descoordenados e perda do controle hidrodinâmico
Permanência na superfície	
Boquejamento	Respiração acelerada e abertura em frequência exagerada da boca
Prurido	Comportamento de fricção contra objetos ou substrato, indicativo de irritação cutânea por ectoparasitos
Perda de escamas	Exfoliação da epiderme com desnudamento do tecido subjacente
Anorexia	Perda progressiva de massa muscular ocasionada por doenças crônicas

10

11

12

13

14

15

16

17

18

19

Embora a diversidade e a qualidade das imagens seja elemento chave para o sucesso do treinamento, a distribuição desbalanceada entre as classes pode afetar a performance do modelo de CNN, que pode erroneamente reconhecer melhor as classes mais representativas (Shorten; Khoshgoftaar, 2019), como os tricodinídeos comparada as classes menos numerosas, como o *Ichthyophthirius multifiliis*. Esse problema ressalta a necessidade da aplicação de técnicas que visem equalizar a quantidade de exemplos entre as classes, como o *data augmentation* (Perez; Wang, 2017).




Figura 6. Colônia de *Epistylis* sp. (A), hifas de *Saprolegnia* sp. (B), tricodinídeo (C), *Piscinoodinium* sp. (D), trofote de *Ichthyophthirius multifiliis* (E), monogenético (F).

A partir da Figura 6, é possível visualizar as diferenças morfológicas entre os parasitos identificados, características essas que precisam ser realçadas para que as arquiteturas de CNNs possam identificá-las corretamente na classificação. Essas variações morfológicas, como a textura, forma e proporção entre comprimento e largura, são essenciais para a diferenciação entre as classes. Com base nessas características, é possível adotar estratégias de pré-processamento, aplicando técnicas que aumentem a visibilidade dos padrões relevantes. Uma das abordagens eficazes é a limiarização, que permite destacar bordas e formas. A Tabela 3 a seguir traz referências dessas características.

Tabela 3. Características relevantes de cada parasito, que podem ser realçadas para aprimorar a classificação.

Parasito	Formato	Textura	Organização
<i>Epistylis</i> sp. (A)	“Cachos de uva”	Lisa	Colônias interligadas por filamentos, Dispersos
<i>Saprolegnia</i> sp.	Filamentoso	Rugosa	Hifas
Tricodinídeo	Discoidal, possuem estrutura citoesquelética circular com bordas denticuladas	Rugosa e ciliada	Dispersos
Piscinoodinium sp.	Formato elíptico e cor amarronzada	Lisa	Agregados ou dispersos
<i>Ichthyophthirius multifiliis</i>	Esférico com núcleo em “formato de ferradura”	Lisa	Dispersos
Monogenético	Corpo alongado com alta capacidade de extensão e contração	Rugosa	Dispersos

Por exemplo, o *Epistylis* sp., conforme Figura 6A, apresenta morfologia elíptica, com uma base fixa e uma extremidade superior mais estreita. A superfície pode ser lisa ou ligeiramente rugosa, e a extremidade superior é repleta de cílios (Wu et al., 2023). Além disso, apresentam organização em colônias, com estruturas de fixação semelhantes a hifas que formam colônias com aspecto de “cachos de uva”. A técnica de raspagem pode destruir as estruturas que mantêm as colônias, resultando na observação de indivíduos dispersos na lâmina. Para realçar suas características, é importante registrar as fotos do organismo em perspectivas que mostram tanto sua extensão lateral quanto a base, além de ajustar o contraste e foco para destacar a textura e as bordas dos cílios, quando possível.

Já a *Saprolegnia* sp. apresenta hifas ramificadas, não septadas e alongadas, podendo apresentar textura granulosa, formando uma rede densa (Pavić et al., 2022). A identificação dessa estrutura pode ser complexa e desafiadora para as CNNs, especialmente na presença de ruídos. No entanto, a combinação de ajustes no contraste e limiarização pode ser testada para destacar as hifas e suas ramificações.

Os tricodinídeos possuem formato discoidal e estrutura circular. Seu disco adesivo é marcado por dentículos dispostos em anel, uma característica central

para sua identificação, enquanto o citoplasma apresenta textura granulada (Attia et al. 2021). Essas características podem ser destacadas em imagens por técnicas de pré-processamento, como limiarização, para facilitar a identificação pelos modelos de CNNs.

Os monogenéticos possuem corpo alongado e estreito, com um aparelho de fixação na extremidade. Sua textura é lisa e a relação comprimento/largura pode variar (Dickerson, 2012). Técnicas de aumento de contraste e ajustes de resolução podem ajudar a realçar o aparelho de fixação, facilitando sua identificação.

A seguir são apresentados alguns exemplos de fotos capturadas em diferentes ângulos e condições de iluminação, com o objetivo de criar exemplos que permitam realçar melhor a diferença entre os parasitos, conforme mencionado anteriormente. Além disso, essas imagens simulam diferentes formas de registro. As Figuras 7 e 8 apresentam fotos de um *tricodinídeo* registradas a partir de diferentes perspectivas e variações de luminosidade.




Figura 7. *Tricodinídeo no sentido ventro-dorsal (A), tricodinídeo no sentido látero-lateral (B).*




Figura 8. *Tricodinídeo no sentido ventro-dorsal (A), tricodinídeo no sentido oblíquo (B).*

A variabilidade nas condições de obtenção das imagens de parasitos, como os monogenéticos, em diferentes estados de extensão e contração é essencial para o treinamento eficaz de redes neurais convolucionais (CNNs) destinadas à classificação de imagens. Essas variações refletem as mudanças morfológicas que os parasitos podem apresentar devido a fatores como estresse osmótico, manipulação mecânica, ou resposta a agentes fixadores. Assim, um banco de dados com imagens que capturem essas diferenças proporciona à CNN uma base mais ampla e realista para aprender a identificar os padrões estruturais característicos dos parasitos, independentemente de sua forma no momento da coleta. Além disso, essa abordagem reduz a probabilidade de enviesar o modelo, aumentando sua capacidade de generalização e permitindo que ele identifique os parasitos em condições não previamente observadas durante o treinamento.




Figura 9. Registros sequenciais de um monogenético em relaxamento (A e B) e contração (C e D).

Ao incluir imagens de parasitos em diferentes estados de contração e extensão, também se aprimora a robustez do modelo, pois a CNN é desafiada a distinguir características relevantes mesmo em condições de deformação. Isso é particularmente crítico para a identificação de monogenéticos, cuja morfologia pode ser influenciada por fatores externos, mas ainda apresenta características específicas, como ganchos e barras haptorais, que são essenciais para o diagnóstico. Dessa forma, a diversidade de imagens não só melhora a acurácia do modelo, mas também reflete mais fielmente a variabilidade encontrada em

103 amostras reais de laboratório ou de campo, contribuindo para o desenvolvimento
104 de uma ferramenta confiável e amplamente aplicável para o diagnóstico
105 parasitológico.

106 O pré-preparo das imagens é uma etapa crítica no uso de redes neurais
107 convolucionais (CNNs), especialmente para a classificação de imagens de
108 parasitos. Aplicar filtros de contraste e brilho é fundamental para destacar
109 características morfológicas importantes, como estruturas haptorais, ganchos e
110 barras, que são essenciais para a identificação precisam de parasitos
111 monogenéticos. Em amostras microscópicas, essas estruturas podem ser difíceis
112 de serem visualizadas devido à baixa qualidade das imagens ou à interferência
113 de artefatos. Ajustes no contraste aumentam a separação entre o parasito e o
114 fundo da imagem, facilitando a segmentação e a detecção dos elementos
115 relevantes pela CNN. Da mesma forma, a modificação do brilho pode ressaltar
116 detalhes sutis que, de outra forma, poderiam passar despercebidos, melhorando
117 a representatividade das características nas imagens fornecidas ao modelo.

118 Além disso, o uso desses filtros contribui para a uniformização do banco de
119 dados, compensando variações causadas por condições de captura, como
120 diferenças na iluminação microscópica ou na qualidade das amostras. Isso
121 resulta em um conjunto de dados mais consistente, que permite à CNN focar no
122 aprendizado das características intrínsecas dos parasitos, sem ser influenciada
123 por ruídos ou inconsistências irrelevantes. Com uma melhor definição das
124 regiões de interesse, o modelo consegue extrair features mais significativas,
125 levando a uma maior acurácia e confiabilidade na classificação. Portanto, o pré-
126 processamento adequado das imagens é indispensável para maximizar o
127 desempenho do modelo e garantir sua aplicabilidade em cenários práticos de
128 diagnóstico parasitológico.

129 Essas variações podem ser vantajosas para identificar estruturas
130 tridimensionais complexas, cujas características morfológicas aparecem de formas
131 distintas dependendo do perfil de captura. As imagens em sentido látero-laterais ou
132 oblíquas revelaram contornos e projeções que não eram visíveis em capturas
133 ventro-dorsais.

134

4.2 Pré-processamento de Imagens

Duas técnicas foram testadas para redução da dimensionalidade dos dados e realce de características relevantes para a identificação dos parasitos. A primeira foi a conversão de imagens RGB para escalas de cinza, que reduziu a estrutura da imagem de três para uma única camada. Essa abordagem preserva nuances e gradientes de textura, mantendo detalhes importantes como variações sutis de sombreamento. No entanto, sua eficácia foi menor em cenários com altos níveis de ruídos. A Figura 10 abaixo permite visualizar o resultado dessa técnica sobre a imagem de um tricodinídeo.




FIGURA 10. Registro original de um tricodinídeo (A). Conversão para tons de cinza (B)

A segunda técnica, a limiarização, transformou a imagem em um formato binário, destacando regiões específicas de interesse, como bordas e contornos. Ambas as abordagens simplificaram os dados de forma distinta, auxiliando o modelo a concentrar-se nos elementos essenciais para a identificação dos parasitos. Além de reduzir a complexidade da imagem, tornando-a mais leve para o processamento durante o treinamento da CNN, o diferencial dessa técnica é minimizar interferências e ruídos, realçando o parasito de forma mais evidente. Aqui, foram testados os limiares de 120, 150 e 170 (Gonzalez; Woods, 2019).

De modo geral, observou-se uma melhoria significativa nas imagens com o uso do limiar de 120 durante o processo de limiarização. Entretanto, valores superiores a 120 demonstraram baixa eficácia em destacar o parasito em relação ao fundo, especialmente na presença de excesso de ruídos. Como exemplo, a figura 11 demonstra as alterações em uma imagem de tricodinídeo com baixo ruído de fundo, utilizando os limiares de 120, 150 e 170.




Figura 11. Imagem original (A), imagem limiarizada com limiares de 120 (B), 150 (C) e 170 (D).

Com o limiar de 120, houve uma supressão considerável de detalhes, o que resultou na perda de informações finas do parasito. Embora o fundo tenha sido minimizado de forma eficiente, o nível elevado de simplificação prejudicou a identificação de características importantes. Por outro lado, o limiar de 150 apresentou o melhor desempenho, oferecendo um equilíbrio ideal entre a preservação dos detalhes relevantes e a exclusão de ruídos. Esse valor realçou os contornos do parasito com precisão, melhorando a separação entre o objeto e o fundo. Já o limiar de 170 permitiu a retenção de mais detalhes, incluindo áreas de baixa intensidade. Contudo, essa configuração também intensificou a interferência de ruídos, reduzindo a clareza na definição dos contornos do parasito.

A figura 12 demonstra as alterações em uma imagem de tricodinídeo com intensa interferência de ruídos, utilizando os limiares de 120, 150 e 170. Embora a técnica de limiarização tenha se mostrado limitada para este caso específico, ela foi capaz de ressaltar detalhes importantes com o limiar de 150. Esse valor destacou algumas características relevantes do parasito, mesmo diante da significativa presença de ruídos, evidenciando seu potencial em situações desafiadoras.





Figura 12. Imagem original (A), imagem limiarizada com limiares de 120 (B), 150 (C) e 170 (D).

Outro caso particular a ser destacado refere-se às imagens de *Saprolegnia* sp. e à aplicação da técnica de limiarização. Nesse contexto, o pré-processamento não foi eficaz em evidenciar o parasito em nenhum dos limiares testados, mesmo em condições de baixa interferência de ruídos. Pelo contrário, as imagens originais permitiram uma melhor percepção dos detalhes do parasito em comparação com as imagens limiarizadas, sugerindo que a técnica não é adequada para este tipo de imagem. Isso pode ser observado na Figura 13, onde as imagens limiarizadas (B, C e D) apresentam um contraste reduzido dos detalhes do parasito em comparação à imagem original (A).

197



198

199

200

201

Figura 13. Alterações observadas em imagens de *Saprolegnia* sp. após a limiarização: imagem original (A), limiar de 120 (B), limiar de 150 (C) e limiar de 170 (D).

202

4.3 Expansão da base de dados por Data Augmentation

203

204

205

206

207

208

209

210

211

212

213

214

215

216

217

218

219

220

Foram aplicadas as técnicas de rotação, espelhamento, ajuste de brilho e contraste para aumentar o conjunto de imagens. A rotação ajustou as imagens em diferentes ângulos (45°, 90° e 120°), simulando diversas orientações dos parasitos. O espelhamento foi realizado nos eixos horizontal e vertical, criando novas imagens invertidas. O ajuste de brilho e contraste foi utilizado para simular variações na iluminação e melhorar a distinção entre os parasitos e o fundo da imagem. Para o ajuste de brilho, foram aplicadas alterações nos valores de +50 e -50, o que simulou condições de iluminação mais intensa e mais fraca, respectivamente. Quanto ao contraste, os níveis foram ajustados em +30 e -30, ampliando a diferença entre as estruturas do parasito e o fundo, e, em seguida, reduzindo essa diferença para simular condições de menor visibilidade. Essas técnicas resultaram em um aumento de até 188% no número de exemplos em cada classe, ampliando a base de dados para as seguintes quantidades de imagens: 560 de tricotinídeos, 392 de Monogenea, 260 de *Epistylis*, 216 de *Saprolegnia*, 52 de *Piscinoodinium* e 22 de *Ichthyophthirius multifiliis*. No total, a base de dados passou a contar com 1.532 imagens. No entanto, apesar do aumento considerável, não foi possível alcançar um equilíbrio no número de exemplos entre as diferentes classes.

221 5. CONSIDERAÇÕES FINAIS

222 Após o processo de aumento de dados, utilizando técnicas de rotação,
223 espelhamento e ajuste de brilho e contraste, a base de dados-teste foi expandida
224 para 1.532 imagens, com a classe de tricotrídeos alcançando 560 imagens,
225 seguida por Monogenea (392 imagens) e *Epistylis* (260 imagens). Essa técnica se
226 mostrou eficaz em reduzir a disparidade entre o número de imagens das diferentes
227 classes de ectoparasitos registradas, resultando em um banco de dados mais
228 equilibrado e consistente para o treinamento de modelos de CNNs.

229 Embora tenha ocorrido um aumento significativo no número de imagens e
230 uma redução no desbalanceamento, ainda não foi alcançado um equilíbrio ideal
231 entre as diferentes classes de parasitos deste estudo, como evidenciado pelas
232 classes com menor representação, como *Piscinoodinium* (52 imagens) e
233 *Ichthyophthirius multifiliis* (22 imagens).

234 As técnicas de pré-processamento, como a limiarização, foram testadas,
235 mas não conseguiram realçar consistentemente as características dos parasitos
236 em algumas imagens, como no caso da *Saprolegnia* sp., onde as imagens
237 limiarizadas apresentaram menor contraste e detalhes. Em geral, para a maioria
238 dos parasitos, o uso de limiar de 150 permitiu destacar o parasito nas imagens. Por
239 outro lado, o método de conversão para tons de cinza demonstrou uma
240 aplicabilidade mais ampla aos diferentes tipos de parasitos e para os diferentes
241 tipos de imagens (com mais ruído ou menos).

242 A metodologia utilizada nesse estudo foi bem-sucedida ao basear a
243 elaboração de uma base de dados com imagens de qualidade. Por outro lado, os
244 gargalos encontrados, estes intrínsecos à prevalência regional das diferentes
245 espécies de parasitos, como o número pequeno de registros de algumas classes,
246 foram a principal barreira para se atingir um banco de dados equilibrado e
247 consistente, ressaltando a necessidade da colaboração de equipes de diferentes
248 regiões para reforçar o número de imagens das classes de parasitos menos
249 representadas, possibilitando a criação de um modelo eficiente e aplicável no
250 diagnóstico de doenças parasitárias em peixes.

251

252 6. CONTINUIDADE DOS ESTUDOS

253 6.1 Ampliação da Base de Dados

254 A base de dados elaborada para avaliar a eficiência da metodologia, embora
255 numerosa, apresenta um desbalanceamento significativo entre as classes de
256 ectoparasitos. Este desbalanceamento pode comprometer a eficácia do modelo de
257 aprendizado de máquina, favorecendo classes mais representadas em detrimento
258 das sub-representadas.

259 Em função do desbalanceamento observado entre as classes de
260 ectoparasitos, é essencial a continuação da coleta de imagens, com foco específico
261 nas classes menos representadas. Isso não só aumentará a diversidade do banco
262 de dados, mas também garantirá uma melhor representatividade das classes sub-
263 representadas, essencial para um treinamento mais equitativo do modelo. Além
264 disso, a expansão geográfica das coletas pode reduzir o desbalanceamento. Ao
265 incluir amostras de parasitos provenientes de diferentes regiões geográficas, é
266 possível não apenas reduzir a disparidade no número de imagens entre as classes,
267 mas também aumentar a variabilidade morfológica e ambiental do conjunto de
268 dados. Essa maior diversidade contribui para um modelo mais robusto, capaz de
269 generalizar melhor e identificar corretamente os parasitos em diferentes condições,
270 melhorando a precisão e a aplicabilidade do sistema de classificação em diferentes
271 cenários.

272

273 6.2 Escolha da Arquitetura de CNN para treinamento

274 A escolha de uma arquitetura de CNN para uma tarefa de classificação de
275 imagens deve considerar as características do banco de dados, como tamanho,
276 balanceamento e a complexidade das classes. Para bancos de dados pequenos ou
277 moderados, o uso de arquiteturas pré-treinadas em grandes conjuntos de dados,
278 como a ResNet-50 ou a VGG-16, por meio de *transfer learning*, pode trazer
279 melhores resultados. Essas arquiteturas carregam um aprendizado anterior de
280 características de baixo e alto nível, permitindo que o treinamento seja adaptado às
281 particularidades das imagens de parasitos com menor custo computacional e
282 menor risco de *overfitting* (Shahin et al., 2020).

283 Outro fator importante é o desbalanceamento das classes no banco de dados.
284 Redes como a InceptionV3 podem ser vantajosas devido à sua habilidade de

285 capturar características detalhadas de objetos pequenos ou pouco representados
286 em um conjunto de dados desbalanceado. O ajuste fino (*fine tuning*) da arquitetura,
287 como a modificação de camadas totalmente conectadas para adaptar o número de
288 classes ou o uso de técnicas como *data augmentation*, pode ajudar a compensar a
289 diferença de representatividade (Krizhevsky et al., 2012). A escolha deve ser guiada
290 também por testes experimentais utilizando métricas como acurácia, *precision*,
291 *recall* e *F1-score*, para avaliar a performance e garantir a robustez do modelo.

292

293 **7. REFERÊNCIAS BIBLIOGRÁFICAS**

- 294 AKHLOUFI, M. A.; ALI, K.; BOUAMRANI, A.; MAO, Y.; MAZLOUMI, S.; ZHOUMI, M.;
295 KACHOUH, M.; EL AZZOUZ, S.; HASSAN, I.; ALKHATEEB, S.; IDRIS, S.; ZHENG,
296 J.; CHEBLI, Y.; AHMED, E. Machine learning for real-time detection of aquatic
297 animal diseases in aquaculture systems. **Aquaculture International**, v. 32, p. 415-
298 431, 2024.
- 299 Attia, M. M., Elgendy, M. Y., Prince, A., El-Adawy, M. M., & Abdelsalam, M. (2021).
300 Morphomolecular identification of two trichodinid coinfections (Ciliophora:
301 Trichodinidae) and their immunological impacts on farmed Nile Tilapia.
302 **Aquaculture Research**, 52(9), 4425-4433.
- 303 AVENANT-OLDEWAGE, A. (2012). *Lernaea cyprinacea* and related species. In: E.
304 WOO & K. BRUNO (Eds.), **Fish parasites: Pathobiology and protection** (pp.
305 337–349). Wallingford, UK: CABI.
- 306 ALI, S.; KHAN, M. A.; AHMED, R.; RASHID, M.; MAHMOOD, T.; NASEER, M. I.; ALI,
307 F.; QURSHI, M. Z.; MURTHY, C.; SAJID, M. An enhanced technique of skin cancer
308 classification using deep convolutional neural network with transfer learning models.
309 **Journal of Skin Research**, 2021.
- 310 ALI, F.; KHAN, M. A.; NAZ, S.; SHAFIQUE, M. A.; RASHID, M.; AHMED, I.; JAVED,
311 A.; NASEER, M. I.; JAMIL, M.; ZAFAR, A.; MURTHY, C.; SAJID, M. Transfer
312 learning for skin lesion classification using CNNs. **Computers in Biology and**
313 **Medicine**, v. 133, p. 104430, 2021.
- 314 BASSON, L.; VAN AS, J. G. Trichodinidae and other ciliophorans (Ciliophora:
315 Peritrichia) as fish parasites: A review. **South African Journal of Science**, v. 87,
316 n. 5, p. 233–235, 1991.
- 317 BRIGATO, L., BARZ, B., IOCCHI, L., & DENZLER, J. (2022). **Image classification**
318 **with small datasets: Overview and benchmark**. IEEE Access, 10, 49233-49250.
- 319 BURGER, Wilhelm; BURGE, Mark J. **Digital image processing: an algorithmic**
320 **introduction**. 3rd ed. Cham: Springer, 2022. 945 p.
- 321 DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. ImageNet: A Large-
322 Scale Hierarchical Image Database. In: **Proceedings of the IEEE Conference on**
323 **Computer Vision and Pattern Recognition**. IEEE, 2009. p. 248-255.
324 doi:10.1109/CVPR.2009.5206848.

- 325 DICKERSON, H. W. (2012). *Ichthyophthirius multifiliis*. In: E. WOO & K. BRUNO
326 (Eds.), **Fish parasites: Pathobiology and protection** (pp. 55–72). Wallingford,
327 UK: CABI.
- 328 ESTEVA, A.; KESSLER, P.; WEISS, M.; GOLDBERG, H.; SIEGEL, M.; ELIAS, L.;
329 LEBRUN, J.; LING, C.; HARIS, M.; ALFANO, L.; RUIZ, P. A guide to deep learning
330 in healthcare. **Nature Medicine**, v. 25, n. 1, p. 24-29, 2019.
- 331 ESTEVA, A.; KESSLER, P.; WEISS, M.; GOLDBERG, H.; SIEGEL, M.; ELIAS, L.;
332 LEBRUN, J.; LING, C.; HARIS, M.; ALFANO, L.; RUIZ, P. Deep learning-enabled
333 medical computer vision. **Nature Medicine**, v. 25, n. 1, p. 37-44, 2019.
- 334 FAO. **The State of World Fisheries and Aquaculture 2018: Meeting the sustainable**
335 **development goals**. FAO, 2018.
- 336 FAO. **The State of World Fisheries and Aquaculture 2024**. Food and Agriculture
337 Organization of the United Nations, 2024.
- 338 GOMES, A. L.; LIMA, F. P.; SILVA, C. M.; PEREIRA, M. P.; ALMEIDA, J. R.; COSTA,
339 T. S.; PIMENTEL, D. E. Sustainable aquaculture: Strategies for parasite control in
340 fish farming. **Aquaculture Research**, v. 52, n. 12, p. 6215-6230, 2021.
- 341 GOMES, A. R.; PEREIRA, C. M.; SILVA, M. J. Sustainable aquaculture and the role of
342 AI in disease control. **Journal of Aquatic Science and Technology**, v. 13, n. 2, p.
343 23-38, 2021.
- 344 GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 4^a ed. Pearson India,
345 2019. 216 p.
- 346 GÓRRIZ, J. M.; GARCÍA, R. D.; PÉREZ, A. C.; ALVAREZ, S. F.; RAMÍREZ, D. U. U-
347 Net for segmentation of Leishmania parasites. **Journal of Parasitology Research**,
348 2019.
- 349 HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep Residual Learning for Image Recognition.
350 In: Proceedings of the IEEE **Conference on Computer Vision and Pattern**
351 **Recognition**. IEEE, 2016. p. 770-778. doi:10.1109/CVPR.2016.90.
- 352 HOLMSTRÖM, O.; BENGTSSON, A. J.; LARSSON, K. M.; NYSTRÖM, P. J. CNN for
353 malaria diagnosis in blood smears. **Biomedical Central Parasitology**, 2019.
- 354 HOLMSTRÖM, O.; HEDLUND, S.; GORDON, D.; SÖDERBERG, S.; BENGTSSON,
355 A.; JORGE, R.; HELLAND, M.; LINDBERG, A.; PELLEGRINI, C.; NORÉN, L.;
356 GABRIEL, C.; JAGNEFELT, J.; SÖDERSTEDT, S.; BÜNGEN, A.; KLEIN, A. Deep
357 learning models for malaria detection in thick blood smears. **IEEE Transactions on**

358 **Medical Imaging**, v. 38, n. 4, p. 1044-1055, 2019.
359 KORIAL, A. E.; ABD EL-GHANY, M.; HASSAN, M. F.; ZAKY, M. I.; MOHAMED, H.
360 A.; RAMZY, M.; EL-HAWI, N. H. An improved ensemble-based cardiovascular
361 disease detection system with chi-square feature selection. **Computers**, 2024.
362 KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet Classification with Deep
363 Convolutional Neural Networks. **Advances in Neural Information Processing**
364 **Systems**, v. 25, p. 1097-1105, 2012.
365 LITJENS, GEERT; KOOI, THIJS; EHTESHAMI BEJNORDI, Babak; SETIO, Arnaud
366 Arindra Adiyoso; CIOMPI, Francesco; GHAFOORIAN, Mohsen; LAK, Jeroen
367 A.W.M. van der; GINNEKEN, Bram van; SÁNCHEZ, Clara I. A survey on deep
368 learning in medical image analysis. **Medical Image Analysis**, v. 36, p. 60-88, 2017.
369 DOI: 10.1016/j.media.2017.07.005.
370 LIU, Y.; WANG, L.; ZHANG, J.; LI, Z.; LIU, X.; LI, J.; ZHANG, Q. Automated detection
371 and classification of fish parasites in gill tissues using convolutional neural networks.
372 **Aquaculture**, v. 524, p. 735178, 2020.
373 LIU, Y.; ZHANG, J.; FAN, X. Diagnosis of parasitic diseases in aquaculture: Current
374 status and future perspectives. **Aquaculture Reports**, v. 17, p. 100-112, 2020.
375 LOM, J.; DYKOVÁ, I. Protozoan Parasites of Fishes. **Elsevier Science Publishers**,
376 1992.
377 MALLAT, S. Understanding Deep Convolutional Networks. Philosophical Transactions
378 of the Royal Society A: Mathematical, **Physical and Engineering Sciences**, v. 374,
379 n. 2065, p. 20150203, 2016. doi:10.1098/rsta.2015.0203.
380 MARTINS, M. L.; COSTA, L. G.; SANTOS, F. A.; PEREIRA, R. A.; FONSECA, M. L.;
381 ALMEIDA, F. A.; OLIVEIRA, R. J.; SOUSA, C. A. Parasitic diseases in cultured fish
382 in Brazil: Pathology and control. **Journal of Fish Diseases**, v. 43, n. 3, p. 231-244,
383 2020.
384 MARTINS, M. L.; MORAES, F. R.; MIYAZAKI, D. M. Y. Parasitoses em peixes de
385 cultivo no Brasil. **Revista Brasileira de Medicina Veterinária**, v. 42, n. 1, p. 1-10,
386 2020.
387 NAJI AL-AZZWI, Z. H.; NAZAROV, A. N. Medical image classification using transfer
388 learning: Convolutional neural network models approach. **Journal of Medical**
389 **Imaging**, 2024.

- 390 NOWAK, B. F. Parasitic diseases in marine cage culture - An example of experimental
391 evolution of parasites? **International Journal for Parasitology**, v. 37, n. 6, p. 581-
392 588, 2007.
- 393 OZTURK, Ş.; BAYRAM, F.; AYDEMIR, E.; KILIÇ, N.; TUNCAY, G. Comparison of
394 Human Intestinal Parasite Ova Segmentation Using Machine Learning and Deep
395 Learning Techniques. **Applied Sciences**, v. 9, n. 5, p. 1017, 2019. Acesso em: 08
396 de novembro de 2024. Disponível em: <https://doi.org/10.3390/app9051017>.
- 397 PAN, S. J.; YANG, Q. A. **Survey on Transfer Learning. IEEE Transactions on**
398 **Knowledge and Data Engineering**, v. 22, n. 10, p. 1345-1359, 2010.
- 399 Pavić, D., Grbin, D., Hudina, S., Prosenc Zmrzljak, U., Miljanović, A., Košir, R., ... &
400 Bielen, A. (2022). Tracing the oomycete pathogen *Saprolegnia parasitica* in
401 aquaculture and the environment. **Scientific reports**, 12(1), 16646.
- 402 PEREZ, L.; WANG, J. **The Effectiveness of Data Augmentation in Image**
403 **Classification using Deep Learning**. arXiv preprint arXiv:1712.04621, 2017.
404 Acesso em: 08 de novembro de 2024. Disponível em:
405 <https://arxiv.org/abs/1712.04621>.
- 406 QIU, T.; WEI, C.; WEI, Q.; ZHANG, H.; WANG, Z. Parasite Detection and Classification
407 Based on Machine Learning and Image Processing. **Aquaculture**, v. 525, p.
408 735006, 2020.
- 409 RAJARAMAN, S.; RAY, S.; SINGH, R.; RAMAN, R.; SINGH, S.; ANAND, P.;
410 RATHORE, A. Transfer learning for malaria parasite detection. **PeerJ**, 2018.
- 411 RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for
412 Biomedical Image Segmentation. In: **International Conference on Medical Image**
413 **Computing and Computer-Assisted Intervention**. Springer, Cham, 2015. p. 234-
414 241.
- 415 SHAH, D.; GUPTA, S.; KUMAR, A.; SINGH, R.; YADAV, A.; SINGH, R. K.; SHARMA,
416 D.; NAIR, A. A lightweight deep learning architecture for malaria parasite-type
417 classification and life cycle stage detection. **Neural Computing and Applications**,
418 2024.
- 419 SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for
420 deep learning. **Journal of Big Data**, v. 6, n. 1, p. 1–48, 2019.
- 421 **SPYDER**. *Spyder: The Scientific Python Development Environment*. Versão 5.x.
422 Disponível em: <https://www.spyder-ide.org/>. Acesso em: 12 nov. 2024.

- 423 TREVES-BROWN, K. M. Anaesthetics. In: **Applied Fish Pharmacology**. Springer,
424 Dordrecht, 2000. v. 3, p. 207.
- 425 VAN AS, J. G.; BASSON, L. A further contribution to the taxonomy of Trichodinidae
426 (Ciliophora: Peritrichia and a review of the taxonomic status of some fish
427 ectoparasitic trichodinids. **Systematic Parasitology**, v. 14, n. 3, p. 157–179, 1989.
- 428 VIET, V. Q.; NGUYEN, D. H.; PHAM, T. T.; TRUONG, T. P.; NGUYEN, H. T.; TRAN,
429 S. T.; NGUYEN, D. M.; NGUYEN, T. H.; TONG, S. M. Faster R-CNN for detection
430 of parasite eggs in microscopic images of feces. **Computer Methods in**
431 **Biomechanics and Biomedical Engineering**, 2020.
- 432 XU, Z.; WANG, S.; XU, G.; LIU, Y.; YU, M.; ZHANG, H.; LUKASIEWICZ, T.; GU, J.
433 Automatic data augmentation for medical image segmentation using Adaptive
434 Sequence-length based Deep Reinforcement Learning. **Computers in Biology**
435 **and Medicine**, v. 169, p. 107877, 2024.
- 436 Waleed, A., Medhat, H., Esmail, M., Osama, K., Samy, R., & Ghanim, T. M. (2019,
437 December). **Automatic recognition of fish diseases in fish farms**. 14th
438 International Conference on Computer Engineering and Systems (ICCES) (pp. 201-
439 206).
- 440 WANG, Z.; LI, X.; WANG, F.; WANG, L.; ZHOU, Z.; JIN, L.; LIU, W.; SHI, J.; ZHANG,
441 H.; XU, Y.; LIU, Y.; ZHU, J.; WANG, J. PKU-I2IQA: **An Image-to-Image Quality**
442 **Assessment Database for AI Generated Images**, 2023.
- 443 Wu, T., Li, Y., Zhang, T., Hou, J., Mu, C., Warren, A., & Lu, B. (2021). Morphology and
444 molecular phylogeny of three Epistylis species found in freshwater habitats in China,
445 including the description of E. foissneri n. sp.(Ciliophora, Peritrichia). **European**
446 **Journal of Protistology**, 78, 125767.
- 447 YANONG, R. P. (2003). Fungal diseases of fish. *Veterinary Clinics of North America:*
448 *Exotic Animal Practice*, 6(2), 377–400.
- 449 YAZDANPARAST, E.; MOHAMMADI, F.; RAZAVI, M.; HASHEMI, S. S.; GHAFFARI,
450 S.; DABIRI, S.; MOHAMMADI, S. A. A deep learning-based model for detecting
451 Leishmania amastigotes in microscopic slides: a new approach to telemedicine.
452 **BMC Infectious Diseases**, 2023.
- 453 ZARE, M.; FADAEE, M.; MIRZA, S.; MOHAMMADI, H.; KHOSRAVI, A.; RAHIMI, M.;
454 HAJIALI, A.; JABERI, M.; ASGARI, A. DeepLeish: a deep learning-based support

455 system for the detection of Leishmaniasis parasites from Giemsa-stained
456 microscope images. **BMC Medical Imaging**, 2023.