



Universidade Federal do Pará – UFPA  
Campus Universitário de Altamira  
**PROGRAMA DE PÓS-GRADUAÇÃO  
EM BIODIVERSIDADE E  
CONSERVAÇÃO - PPGBC**



Felipe de Luca dos Santos Nogueira

**MONITORAMENTO INTELIGENTE DE PEIXES AMAZÔNICOS:  
DETECÇÃO E CLASSIFICAÇÃO COM APRENDIZADO PROFUNDO  
EM PASSAGENS DE PEIXES**

Orientador: Prof. Dr. Tommaso Giarrizzo

Coorientador: Prof. Dr. Eurico Noleto

ALTAMIRA - PA  
MARÇO, 2025

FELIPE DE LUCA DOS SANTOS NOGUEIRA

**MONITORAMENTO INTELIGENTE DE PEIXES AMAZÔNICOS:  
DETECÇÃO E CLASSIFICAÇÃO COM APRENDIZADO PROFUNDO  
EM PASSAGENS DE PEIXES**

Orientador: Prof. Dr. Tommaso Giarrizzo

Coorientador: Prof. Dr. Eurico Noletto

Dissertação apresentada à Universidade Federal do Pará, como parte das exigências do Programa de Pós-graduação em Biodiversidade e Conservação para obtenção do título de Mestre em Biodiversidade e Conservação.

ALTAMIRA - PA

MARÇO, 2025

FELIPE DE LUCA DOS SANTOS NOGUEIRA

**MONITORAMENTO INTELIGENTE DE PEIXES AMAZÔNICOS:  
DETECÇÃO E CLASSIFICAÇÃO COM APRENDIZADO PROFUNDO  
EM PASSAGENS DE PEIXES**

Data da Aprovação: \_\_\_\_/\_\_\_\_/\_\_\_\_

**Banca Examinadora:**

---

**Prof. Dr. Leandro Melo de Sousa**  
**Universidade Federal do Pará**  
(Avaliador Interno)

---

**Prof. Dr. Friedrich Wolfgang Keppeler**  
**Universidade Federal do Ceará**  
(Avaliador Externo)

---

**Prof. Dr. Paulo Lilles Jorge Drews Junior**  
**Universidade Federal do Rio Grande**  
(Avaliador Externo)

## Agradecimentos

A Deus, por me conceder força, sabedoria e perseverança para enfrentar cada desafio desta caminhada acadêmica. Sua graça e bondade foram fundamentais em todas as etapas deste processo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Fundação Amazônia de Amparo a Estudos e Pesquisas (Fapespa), pela concessão da bolsa de estudos que tornou possível a realização e o desenvolvimento deste projeto.

À minha família, pelo apoio incondicional, pelo carinho e pelas palavras de incentivo nos momentos mais difíceis. Vocês são a base sobre a qual construo minha trajetória e a minha maior fonte de inspiração.

Em especial, à minha namorada, Helen, pelo amor, paciência e compreensão ao longo desta jornada. Seu apoio constante foi essencial para que eu seguisse adiante com determinação e confiança. Obrigado por acreditar em mim e estar ao meu lado em cada passo.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO GERAL</b>	<b>8</b>
<b>2</b>	<b>OBJETIVOS</b>	<b>11</b>
2.1	Objetivo Geral . . . . .	11
2.2	Objetivos Específicos . . . . .	11
<b>1</b>	<b>Introdução</b>	<b>16</b>
<b>2</b>	<b>Material e Métodos</b>	<b>17</b>
2.1	Caracterização da área de estudo . . . . .	17
2.2	Fluxograma . . . . .	19
2.3	Coleta de dados . . . . .	19
2.4	Retirada de quadros e Anotação manual de dados . . . . .	20
2.5	O Conjunto de Dados . . . . .	21
2.6	Treinamento da Rede Neural Convolucional (RNC) . . . . .	21
2.7	Parâmetros de Treinamento . . . . .	22
2.8	Métricas de avaliação Utilizadas . . . . .	23
2.8.1	Precisão . . . . .	23
2.8.2	Recall . . . . .	24
2.8.3	F1-Score . . . . .	24
2.9	mAP (mean Average Precision) . . . . .	24
2.10	Regressão Linear . . . . .	24
2.11	Avaliação do Impacto do Porte das Espécies sobre o Desempenho do Modelo . . . . .	25
<b>3</b>	<b>Resultados</b>	<b>25</b>
3.1	Métricas de Desempenho por Espécie . . . . .	25
3.2	Relação entre o Número de Instâncias e o F1-Score . . . . .	26
3.3	Curvas de Aprendizado . . . . .	27
3.4	Exemplos de Detecções . . . . .	27
<b>4</b>	<b>Discussão</b>	<b>29</b>
4.1	Limitações . . . . .	30

## RESUMO GERAL

A Bacia Amazônica possui um dos maiores potenciais hidrelétricos do mundo, sendo responsável por uma parcela significativa da geração de energia no Brasil. A construção de empreendimentos hidrelétricos na região, como o Complexo Hidrelétrico Belo Monte, visa atender à crescente demanda energética, mas também pode impactar a dinâmica migratória e a conservação da ictiofauna amazônica. Diante disso, torna-se essencial o desenvolvimento de sistemas de monitoramento automatizados para avaliar a efetividade das estruturas de mitigação, como as passagens de peixes. Este estudo apresenta o desenvolvimento de um sistema de monitoramento automatizado para a detecção e classificação de espécies de peixes na passagem de peixes da barragem do sitio Pimental, que integra o Complexo Hidrelétrico Belo Monte. A pesquisa foi conduzida no sistema de transposição de peixes (STP) da barragem do sitio Pimental, utilizando técnicas de visão computacional. Para a construção do conjunto de dados, quadros foram extraídos de vídeos subaquáticos capturados pelo STP, sendo posteriormente anotados manualmente na plataforma Darwin V7. O banco de dados resultante foi composto por 1000 imagens, divididas em conjuntos de treinamento (700), validação (150) e teste (150). As dezenove espécies foram selecionadas com base na frequência de ocorrência e importância migratória, sendo destacadas *Phractocephalus hemioiopterus* e *Cichla melaniae*, entre outras. A modelagem foi realizada utilizando Redes Neurais Convolucionais (RNCs), implementadas no modelo YOLO v8, conhecido por sua eficiência em tarefas de detecção de imagens. A técnica de aumento de dados (data augmentation) foi aplicada para expandir a diversidade do conjunto de treinamento, introduzindo transformações como rotações, translações, escalonamento e ajustes de brilho. O treinamento foi conduzido na plataforma Google Colab PRO, utilizando uma GPU NVIDIA A100, garantindo alto desempenho no processamento das imagens. Durante o processo, foram ajustados parâmetros como learning rate (0,01), momentum (0,937) e weight decay (0,0005), visando minimizar o overfitting e melhorar a generalização do modelo. A avaliação do modelo foi realizada por meio de métricas como precisão, recall, F1-score e mean Average Precision (mAP). Os resultados indicaram um desempenho superior para espécies mais representadas no conjunto de dados, como *Phractocephalus hemioiopterus* (F1-score de 91%) e *Cichla melaniae* (87%). Espécies menos frequentes apresentaram menor precisão na classificação, como *Leporinus frederici* (52%) e *Leporinus sp2* (55%). As curvas de aprendizado demonstraram redução progressiva das perdas de treinamento e validação, evidenciando a capacidade do modelo de reconhecer padrões visuais das espécies. O modelo manteve desempenho consistente em diferentes condições ambientais, incluindo alta turbidez e reflexos de iluminação artificial, reforçando seu potencial para o monitoramento contínuo da biodiversidade aquática. Entretanto, algumas limitações foram identificadas, como a variabilidade sazonal na qualidade das imagens e a baixa representatividade de certas espécies, o que pode comprometer a generalização do modelo. Além disso, o tempo de processamento e a necessidade de infraestrutura computacional robusta são fatores a serem considerados. A implementação deste sistema no STP, dentro do Complexo Hidrelétrico Belo Monte, representa um avanço na avaliação de estruturas mitigadoras de impactos ambientais, fornecendo informações fundamentais para o manejo sustentável da fauna aquática em grandes empreendimentos hidrelétricos.

**Palavras-chave:** Redes Neurais Convolucionais, Monitoramento automatizado, Migração de peixes, Ictiofauna Amazônica

## ABSTRACT

The Amazon Basin has one of the largest hydroelectric potentials in the world and is responsible for a significant portion of energy generation in Brazil. The construction of hydroelectric projects in the region, such as the Belo Monte Hydroelectric Complex, aims to meet the growing energy demand but may also impact migratory dynamics and the conservation of Amazonian fish fauna. Therefore, the development of automated monitoring systems to assess the effectiveness of mitigation structures, such as fish passages, becomes essential. This study presents the development of an automated monitoring system for the detection and classification of fish species in the fish passage at the Pimental dam, which is part of the Belo Monte Hydroelectric Complex. The research was conducted in the fish transposition system (FTS) of the Pimental dam, using computer vision techniques. To build the dataset, frames were extracted from underwater videos captured by the FTS and subsequently manually annotated on the V7 platform. The resulting database consisted of 1000 images, divided into training (700), validation (150), and test (150) sets. Species were selected based on their frequency of occurrence and migratory importance, with emphasis on *Phractocephalus hemioliopus* and *Cichla melaniae*, among others. Modeling was performed using Convolutional Neural Networks (CNNs), implemented in the YOLO v8 model, known for its efficiency in image detection tasks. Data augmentation techniques were applied to expand the diversity of the training set, introducing transformations such as rotations, translations, scaling, and brightness adjustments. Training was conducted on the Google Colab PRO platform using an NVIDIA A100 GPU, ensuring high performance in image processing. During the process, parameters such as learning rate (0.01), momentum (0.937), and weight decay (0.0005) were adjusted to minimize overfitting and improve model generalization. The model was evaluated using metrics such as precision, recall, F1-score, and mean Average Precision (mAP). The results indicated superior performance for species more represented in the dataset, such as *Phractocephalus hemioliopus* (F1-score of 91%) and *Cichla melaniae* (87%). Less frequent species showed lower classification accuracy, such as *Leporinus friderici* (52%) and *Leporinus sp2* (55%). Learning curves showed a progressive reduction in training and validation losses, demonstrating the model's ability to recognize visual patterns of the species. The model maintained consistent performance under different environmental conditions, including high turbidity and artificial lighting reflections, reinforcing its potential for continuous monitoring of aquatic biodiversity. However, some limitations were identified, such as seasonal variability in image quality and the low representativeness of certain species, which may compromise model generalization. Additionally, processing time and the need for robust computational infrastructure are factors to be considered. The implementation of this system at the Pimental dam, within the Belo Monte Hydroelectric Complex, represents an advancement in the evaluation of environmental impact mitigation structures, providing essential information for the sustainable management of aquatic fauna in large hydroelectric projects.

**Keywords:** Convolutional Neural Networks, Automated monitoring, Fish migration, Amazonian ichthyofauna

## 1. INTRODUÇÃO GERAL

A bacia Amazônica é um dos maiores sistemas hidrográficos do mundo, desempenhando um papel importante na regulação climática global, na manutenção da biodiversidade e no suprimento de recursos hídricos. Além de sua importância ecológica, a região possui um imenso potencial energético, sendo considerada estratégica para a matriz elétrica do Brasil, que historicamente tem na geração hidrelétrica sua principal fonte de energia renovável (Flecker et al., 2022, Winemiller et al., 2016). A grande quantidade de rios com significativo volume de água e elevada vazão torna a Amazônia um ambiente propício para a implantação de usinas hidrelétricas, as quais desempenham um papel essencial no fornecimento de energia limpa e renovável para o país (Chaudhari e Pokhrel, 2022).

A expansão de empreendimentos hidrelétricos na Amazônia visa atender à crescente demanda por eletricidade. Um dos exemplos mais expressivos dessa iniciativa é o Complexo Hidrelétrico de Belo Monte (UHE BM), localizado no rio Xingu, no estado do Pará. A UHE BM é a maior usina 100% brasileira, com uma capacidade instalada de 11.233,1 MW e uma garantia física média de 4.571 MW. Sua operação é capaz de atender à demanda de aproximadamente 60 milhões de pessoas (Norte Energia, 2024). A usina é composta por diferentes estruturas, incluindo o Sítio Pimental, onde foi implantado um Sistema de Transposição de Peixes (STP) para permitir a migração de espécies aquáticas afetadas pela barragem.

A implantação de passagens para peixes, como o STP do sítio Pimental, é uma das principais estratégias para mitigar possíveis impactos da fragmentação fluvial sobre a fauna aquática. Essas passagens são projetadas para permitir que os peixes migrem entre diferentes trechos dos rios, garantindo o acesso a áreas de alimentação e reprodução. Entre os principais tipos de passagens para peixes, destacam-se as escadas de peixes, que funcionam como canais artificiais compostos por uma sequência de degraus ou piscinas, criando uma corrente d'água controlada que facilita a subida dos peixes.

O design das escadas pode variar de acordo com a espécie-alvo e as condições hidrodinâmicas do rio, incluindo escadas em formato de rampa, com defletores de fluxo, ou sistemas de passagens semi-naturais que buscam imitar as características ambientais originais do curso d'água (Noonan et al., 2012). Além das escadas, outras soluções incluem elevadores de peixes e bypasses, que desviam os peixes ao redor da barragem, permitindo sua passagem sem grandes interferências (Bunt et al., 2012).

A eficiência dessas passagens pode variar conforme a espécie, o design estrutural e as condições ambientais. Algumas espécies apresentam maior capacidade de natação e salto, enquanto outras necessitam de fluxos mais moderados para conseguir realizar a travessia. Estudos indicam que, apesar dos esforços para otimizar essas estruturas, o monitoramento contínuo é essencial para avaliar seu desempenho e possibilitar ajustes necessários para garantir a efetiva migração dos peixes (Silva et al., 2018, Xu et al., 2022). No entanto, métodos tradicionais de monitoramento, como observação visual e armadilhas subaquáticas, podem ser ineficazes devido à turbidez da água e ao alto custo operacional (Bizzotto et al., 2009, Strelnikova et al., 2020).

Neste estudo, o foco recai sobre o monitoramento do Sistema de Transposição de

Peixes do sitio Pimental, uma das estruturas que compõem a UHE BM. O sitio Pimental possui um STP projetado para permitir a migração de espécies que necessitam transpor a barragem para acessar áreas de alimentação e reprodução. O monitoramento tradicional dessas estruturas envolve métodos como observação direta, armadilhas subaquáticas e marcação de peixes, que podem ser limitados em termos de cobertura espacial e temporal, além de demandarem alto esforço humano e tempo para análise dos dados coletados (Strelnikova et al., 2020). Diante desses desafios, novas abordagens tecnológicas têm sido exploradas para aprimorar a eficácia do monitoramento, incluindo o uso de inteligência artificial para automação e análise de imagens subaquáticas (Rathi et al., 2017).

Nos últimos anos, técnicas de aprendizado profundo têm se destacado na análise de imagens e vídeos subaquáticos, permitindo a detecção e classificação automática de espécies de peixes. Redes Neurais Convolucionais (RNCs) são amplamente utilizadas para tarefas de visão computacional e têm demonstrado alta precisão na identificação de espécies em ambientes de baixa visibilidade (Deneu et al., 2021, Kandimalla et al., 2022). Essas redes funcionam através de camadas convolucionais que extraem características visuais importantes, como padrões de cores, texturas e formas, permitindo a diferenciação entre diferentes espécies de peixes (Deneu et al., 2021).

No contexto do monitoramento do STP do sitio Pimental, a aplicação de arquiteturas avançadas de RNCs, como YOLO (You Only Look Once), Faster R-CNN e EfficientNet, podem oferecer uma abordagem inovadora e eficiente para avaliar a eficácia das passagens de peixes e fornecer informações detalhadas sobre as espécies que utilizam essa estrutura (Yadav et al., 2020). Essas arquiteturas são capazes de processar imagens em tempo real e realizar classificações rápidas e precisas, permitindo a automação do monitoramento sem necessidade de intervenção humana constante.

A aplicação de aprendizado profundo no monitoramento de passagens de peixes tem potencial para aprimorar significativamente a eficiência das análises, possibilitando a detecção automatizada, a classificação. Isso permite não apenas um maior controle sobre a eficiência das passagens, mas também fornece subsídios para a formulação de estratégias de conservação da biodiversidade aquática (Antonelli et al., 2023). Além disso, a coleta automatizada de dados possibilita a construção de bancos de dados robustos que podem auxiliar em estudos ecológicos e na gestão sustentável dos recursos pesqueiros da região amazônica. A capacidade desses modelos de processar grandes quantidades de dados e identificar padrões complexos torna-os uma ferramenta essencial para a análise e a conservação da fauna aquática.

Diante desse contexto, este estudo tem como objetivo desenvolver um sistema de monitoramento automatizado baseado em visão computacional e aprendizado profundo para a detecção e classificação de peixes no Sistema de Transposição de Peixes do sitio Pimental, do complexo hidrelétrico Belo Monte. Ao empregar técnicas avançadas de inteligência artificial, busca-se fornecer uma ferramenta confiável para a gestão e conservação dos recursos aquáticos, contribuindo para o aprimoramento das estratégias de sustentabilidade e manutenção da conectividade ecológica na região Amazônica. O uso dessas tecnologias pode representar um avanço importante no monitoramento da fauna aquática, proporcionando maior precisão, eficiência e confiabilidade na obtenção

de dados essenciais para a preservação da biodiversidade e a otimização das passagens para peixes em sistemas hidrelétricos.

## **2. OBJETIVOS**

### *2.1. Objetivo Geral*

Desenvolver e avaliar um modelo de visão computacional para a detecção e classificação de espécies de peixes amazônicos, utilizando aprendizado profundo e vídeos subaquáticos do sistema de transposição de peixes (STP) do sitio Pimental, que integra o UHE BM.

### *2.2. Objetivos Específicos*

- Identificar e classificar as espécies de peixes que atravessam o canal de transposição através de vídeos capturado no STP.
- Treinar e validar um modelo de Rede Neural Convolutiva (RNC) utilizando o conjunto de dados anotados manualmente.
- Avaliar a precisão e eficiência do modelo desenvolvido.

## REFERÊNCIAS

- ANTONELLI, A.; DHANJAL-ADAMS, K. L.; SILVESTRO, D. *Integrating machine learning, remote sensing and citizen science to create an early warning system for biodiversity*. *Plants, People, Planet*, v. 5, n. 3, p. 307–316, 2023. Disponível em: <https://doi.org/10.1002/ppp3.10337>. Acesso em: 10 jul. 2023. DOI: 10.1002/ppp3.10337.
- BIZZOTTO, P. M.; GODINHO, A. L.; VONO, V.; KYNARD, B.; GODINHO, H. P. *Influence of seasonal, diel, lunar, and other environmental factors on upstream fish passage in the Igarapava Fish Ladder, Brazil*. *Ecology of Freshwater Fish*, v. 18, p. 461-472, 2009. Disponível em: <https://doi.org/10.1111/j.1600-0633.2009.00361.x>. Acesso em: 22 ago. 2023. DOI: 10.1111/j.1600-0633.2009.00361.x.
- BUNT, C. M.; CASTRO-SANTOS, T.; HARO, A. *Performance of fish passage structures at upstream barriers to migration*. *River Research and Applications*, v. 28, n. 4, p. 457-478, 2012. Disponível em: <https://doi.org/10.1002/rra.1565>. Acesso em: 5 set. 2023. DOI: 10.1002/rra.1565.
- CHAUDHARI, S. N.; POKHREL, Y. *Alteration of river flow and flood dynamics by existing and planned hydropower dams in the Amazon River Basin*. *Water Resources Research*, v. 58, n. 5, 2022. Disponível em: <https://doi.org/10.1029/2021wr030555>. Acesso em: 15 out. 2023. DOI: 10.1029/2021wr030555.
- DENEU, B. et al. *Convolutional neural networks improve species distribution modelling by capturing the spatial structure of the environment*. *PLOS Computational Biology*, v. 17, n. 4, p. e1008856, 2021. Disponível em: <https://doi.org/10.1371/journal.pcbi.1008856>. Acesso em: 28 nov. 2023. DOI: 10.1371/journal.pcbi.1008856.
- FLECKER, A. S. et al. *Impacts of hydropower development on Amazonian aquatic biodiversity: A review*. *Science Advances*, v. 8, n. 15, p. eabm4796, 2022. Disponível em: <https://doi.org/10.1126/sciadv.abm4796>. Acesso em: 6 dez. 2023. DOI: 10.1126/sciadv.abm4796.
- KANDIMALLA, V. et al. *Automated detection, classification and counting of fish in fish passages with deep learning*. *Frontiers in Marine Science*, p. 2049, 2022. Disponível em: <https://doi.org/10.3389/fmars.2021.823173>. Acesso em: 14 jan. 2024. DOI: 10.3389/fmars.2021.823173.
- NOONAN, M. J.; GRANT, J. W. A.; THOMAS, A. S. *A quantitative assessment of fish passage efficiency*. *Fish and Fisheries*, v. 13, n. 4, p. 450-464, 2012. Disponível em: <https://doi.org/10.1111/j.1467-2979.2011.00445.x>. Acesso em: 5 mar. 2024. DOI: 10.1111/j.1467-2979.2011.00445.x.
- NORTE ENERGIA. *A Usina Hidrelétrica Belo Monte*. 2024. Disponível em: <https://www.norteenergiasa.com.br>. Acesso em: 12 abr. 2024.
- RATHI, D.; JAIN, S.; INDU, S. *Underwater fish species classification using convolutional neural network and deep learning*. In: 2017 Ninth International Conference on Advances in Pattern Recognition (ICAPR). Bengaluru: IEEE, 2017. p. 1–6.

- SILVA, A. T. et al. *The future of fish passage science, engineering, and practice*. Fish and Fisheries, v. 19, n. 2, p. 340-362, 2018. Disponível em: <https://doi.org/10.1111/faf.12258>. Acesso em: 7 jun. 2024. DOI: 10.1111/faf.12258.
- STRELNIKOVA, D. et al. *Drone-Based Optical Measurements of Heterogeneous Surface Velocity Fields around Fish Passages at Hydropower Dams*. Remote Sensing, v. 12, n. 3, p. 384, 2020. Disponível em: <https://doi.org/10.3390/rs12030384>. Acesso em: 19 jun. 2024. DOI: 10.3390/rs12030384.
- WINEMILLER, K. O. et al. *Balancing hydropower and biodiversity in the Amazon, Congo, and Mekong*. Science, v. 351, n. 6269, p. 128-129, 2016. Disponível em: <https://doi.org/10.1126/science.aac7082>. Acesso em: 30 jun. 2024. DOI: 10.1126/science.aac7082.
- XU, X. et al. *Advances in fish passage technologies and monitoring techniques: A systematic review*. Water, v. 14, n. 6, p. 875, 2022. Disponível em: <https://doi.org/10.3390/w14060875>. Acesso em: 10 jul. 2024. DOI: 10.3390/w14060875.
- YADAV, A. K. et al. *Automated fish species recognition using deep convolutional neural networks*. Aquacultural Engineering, v. 91, p. 102110, 2020.

Este capítulo está formatado nas normas da revista “Ecological Informatics”  
disponível em: <https://www.sciencedirect.com/journal/ecological-informatics>

# Monitoramento Inteligente de Peixes Amazônicos: Detecção e Classificação com Aprendizado Profundo em Passagens De Peixes

Felipe de Luca dos Santos Nogueira<sup>a</sup>, Eurico Mesquita Nôleto Filho<sup>a</sup>, Tommaso Giarrizzo<sup>b</sup>

<sup>a</sup> *Universidade Federal do Pará, , Altamira, 68372040, Pará, Brazil*

<sup>b</sup> *Universidade Federal do Ceará., , Fortaleza, 60165081, Ceará, Brazil*

---

## Abstract

The Amazon Basin, a global epicenter of freshwater biodiversity, faces significant ecological challenges due to hydroelectric development, exemplified by the Belo Monte Hydroelectric Plant. While these projects address energy demands, they disrupt aquatic ecosystems, necessitating precise and scalable monitoring solutions. Traditional methods, reliant on manual observation, fail to capture the behavioral complexity and migration patterns of fish species in hydroelectric fish passages. This study leverages deep learning techniques, specifically YOLOv8, to automate fish detection and classification in underwater video data from Belo Monte's fish passages. A meticulously curated dataset of 1,000 images, annotated with 19 Amazonian fish species, was augmented using transformations such as rotation ( $\pm 5^\circ$ ), translation (10%), and HSV adjustments (saturation  $\pm 70\%$ , brightness  $\pm 40\%$ ) to enhance model efficiency. Trained on an NVIDIA A100 GPU via Google Colab Pro, the model achieved exceptional performance for species like *Phractocephalus hemiliopterus* (F1-score: 91%) and *Cichla melaniae* (F1-score: 87%). Challenges persisted for morphologically similar species (e.g., *Leporinus spp.*), highlighting the impact of dataset imbalance and intraclass variability. The model demonstrated resilience to environmental adversities, including turbidity and low visibility, maintaining consistent accuracy across diurnal and nocturnal conditions. These results underscore the potential of computer vision to revolutionize aquatic biodiversity monitoring, offering a scalable framework for conservation and sustainable management in hydropower-impacted ecosystems. By reducing reliance on invasive methods and enabling real-time reporting, this approach supports adaptive strategies for mitigating ecological impacts while balancing energy production needs in the Amazon Basin.

*Keywords:* Amazon Basin; Fish detection; YOLOv8; Convolutional neural networks; Biodiversity conservation; Hydroelectric ecosystems.

---

## 1. Introdução

A bacia Amazônica é reconhecida como um dos biomas de maior importância ecológica no mundo, abrigando a maior diversidade de espécies de água doce globalmente [6]. A vasta e complexa rede de rios presentes na Amazônia não apenas sustenta essa biodiversidade, mas também oferece um imenso potencial para a geração de energia hidrelétrica [7]. É considerada uma das regiões mais ricas em potencial hidrelétrico do mundo, esse potencial é visto como uma solução viável para atender à crescente demanda por energia no país. Entretanto, o desenvolvimento de empreendimentos hidrelétricos na região tem causado alterações consideráveis nos padrões naturais dos rios e nos ecossistemas aquáticos, resultando em impactos negativos para a fauna e flora locais [16].

O Complexo Hidrelétrico de Belo Monte, situada no rio Xingu, no estado do Pará, destaca-se como um dos maiores empreendimentos de infraestrutura já realizados no Brasil. Com uma capacidade instalada de 11.233,1 MW, Belo Monte é a maior usina hidrelétrica inteiramente brasileira e ocupa o terceiro lugar no ranking mundial em termos de capacidade instalada [14]. No entanto, as atividades antropogênicas relacionadas a esse tipo de empreendimento têm causado impactos ambientais recorrentes, como a perda e degradação de habitats, fragmentação de populações, alterações na qualidade da água e interferências nos padrões migratórios de diversas espécies de peixes. [12]. Diante desse cenário, o monitoramento da frequência e abundância das espécies de peixes torna-se essencial para embasar iniciativas de conservação e regulamentação que visam assegurar a integridade dos ecossistemas e a sustentabilidade dos recursos pesqueiros [5][9].

Uma das estratégias adotadas para mitigar os impactos das barragens hidrelétricas sobre a migração dos peixes é a construção de escadas para peixes. Essas estruturas são projetadas para facilitar o movimento dos peixes através de barreiras artificiais, como barragens e diques, promovendo sua migração, sobrevivência e a manutenção de populações aquáticas saudáveis, além de contribuir para a preservação dos ecossistemas em bacias hidrográficas. Para isso, as escadas para peixes funcionam como corredores artificiais que permitem que os peixes subam ou desçam o rio, garantindo a conectividade entre habitats essenciais para sua reprodução e alimentação. Dependendo das características do rio e das espécies migratórias, essas estruturas podem ser construídas ao redor ou através das barragens, com diferentes formatos e mecanismos para reduzir o impacto do fluxo d'água e facilitar a passagem dos peixes [23]. De forma complementar, [17] exploraram o impacto das escadas para peixes na sobrevivência de várias espécies, destacando a importância de monitoramentos contínuos para adaptar as estruturas às necessidades específicas das espécies-alvo. [21] reforçam a importância dessas estruturas para garantir a conectividade dos habitats aquáticos em regiões de barragens hidrelétricas.

Entretanto, o monitoramento nas passagens de peixes em represas hidrelétricas enfrenta certas limitações. Os métodos tradicionais de monitoramento, como observações visuais, muitas vezes não fornecem informações detalhadas sobre padrões e frequência de aparições de todas as espécies, dificultando a compreensão do comportamento dos peixes e a eficiência das passagens [18]. Além disso, esses métodos podem ser demorados e trabalhosos, o que dificulta a coleta de dados de forma contínua e prolongada [4].

Algoritmos de Redes Neurais Convolucionais (RNCs) têm sido amplamente utilizados em tarefas de visão computacional, como a classificação de imagens e a detecção de objetos, demonstrando alta eficiência na análise de grandes volumes de dados visuais [8][11]. Nesse contexto, esses avanços possibilitam a criação de sistemas automatizados capazes de detec-

tar, classificar e monitorar espécies de peixes em vídeos subaquáticos com precisão, sendo uma alternativa aos métodos tradicionais. Além disso, a integração de algoritmos avançados de processamento de imagem viabiliza o monitoramento não invasivo, eliminando a necessidade de intervenções que podem ser onerosas, ilegais ou inviáveis para determinadas espécies, como aquelas em risco de extinção [11]. Dessa forma, essas tecnologias possibilitam a análise contínua e eficiente de um grande volume de dados.

Considerando esse avanço, os algoritmos de aprendizado de máquina vêm se consolidando como estratégias eficazes para a conservação e o estudo da biodiversidade, especialmente diante das aceleradas mudanças climáticas que afetam o planeta [3]. Para alcançar resultados precisos, os modelos de classificação de aprendizado profundo requerem grandes quantidades de dados de treinamento rotulados, ou seja, imagens com caixas delimitadoras ou "máscaras" regionais desenhadas em torno de objetos de interesse, permitindo sua correta identificação [11].

Nesse sentido, a diversidade de espécies na bacia amazônica, aliada às variações na coloração das águas e à complexidade do regime hídrico, evidencia a importância de abordagens complementares para o monitoramento dos ecossistemas aquáticos. Tendo em vista isso as técnicas de visão computacional, fundamentadas em algoritmos de aprendizado profundo, oferecem uma alternativa que possibilita a análise automatizada e contínua de vídeos subaquáticos, ampliando a compreensão dos padrões de comportamento e da distribuição das espécies.

O objetivo deste estudo é desenvolver e avaliar um modelo de visão computacional para a detecção e classificação de espécies de peixes amazônicos, utilizando aprendizado profundo e vídeos subaquáticos do sistema de transposição de peixes (STP) do sitio Pimental, que integra o complexo hidrelétrico Belo Monte, situado no rio Xingu, na bacia amazônica.

## 2. Material e Métodos

### 2.1. Caracterização da área de estudo

O Complexo hidrelétrico Belo Monte está localizado no sudoeste do Pará, na bacia hidrográfica do Rio Xingu, que é um importante afluente da Bacia Amazônica [13]. Sua área de influência engloba os municípios de Altamira, Anapu, Brasil Novo, Senador José Porfírio e Vitória do Xingu. O empreendimento é composto por duas unidades principais: a Usina Hidrelétrica Belo Monte e o sitio Pimental, ambas situadas em Vitória do Xingu. Com 1.200 metros de extensão, o canal de transposição cria uma corrente direcionadora que atrai os peixes, mitigando parte dos impactos da barragem sobre a fauna ao restabelecer a conectividade entre os trechos a montante e jusante [14](Figura 1).

### USINA HIDRELÉTRICA PIMENTAL: MAPA DE LOCALIZAÇÃO

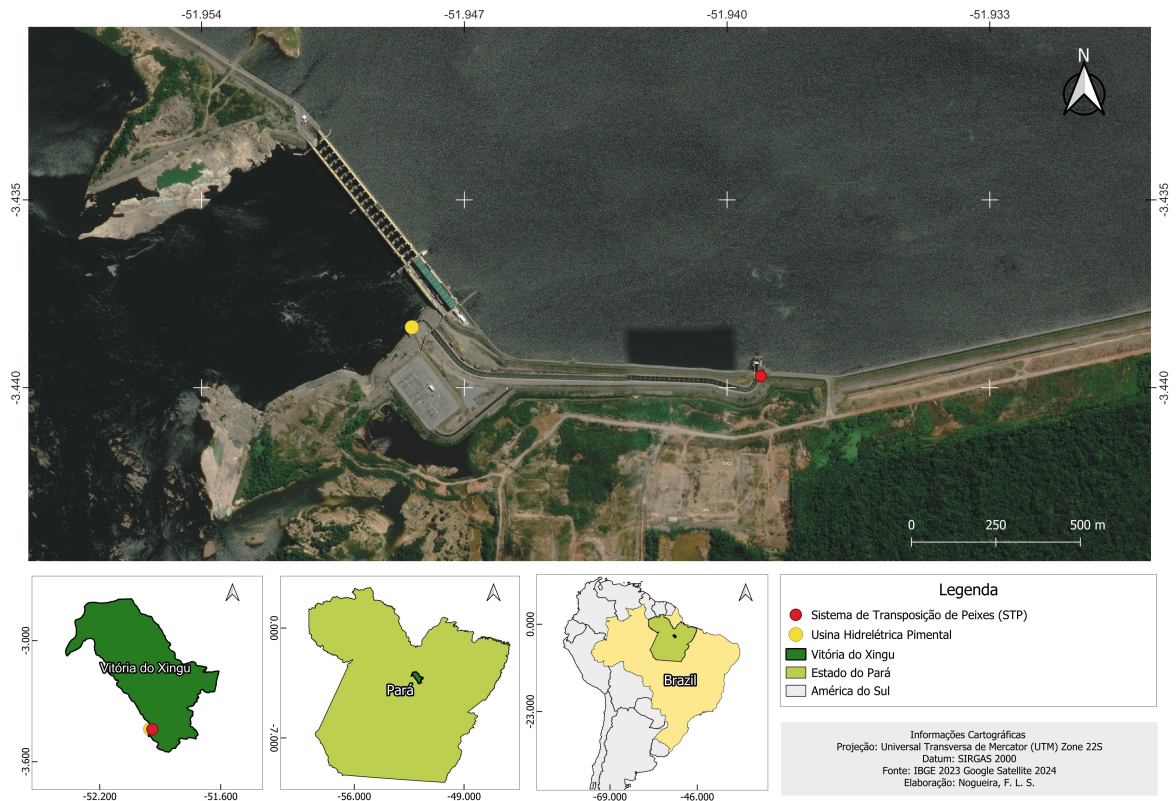


Figura 1: Mapa de localização da Área de Estudo

## 2.2. Fluxograma

O fluxograma abaixo (Figura 2) resume as etapas principais do sistema de monitoramento proposto, desde a coleta dos vídeos subaquáticos até a etapa final do processo.

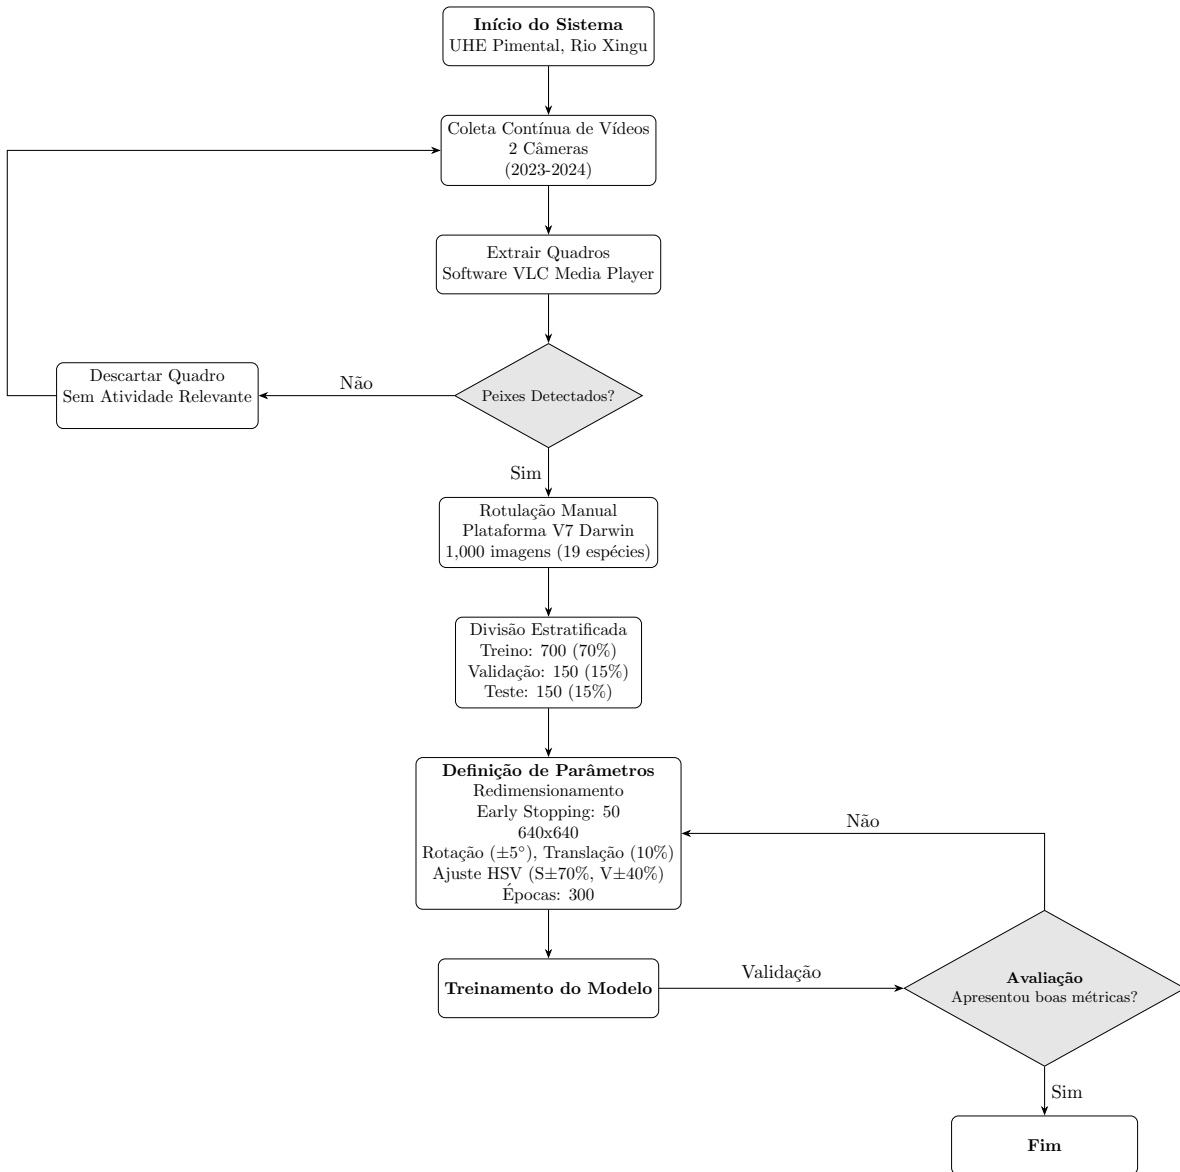


Figura 2: Fluxograma hierárquico do sistema de monitoramento, integrando todas as etapas do processo.

## 2.3. Coleta de dados

A coleta de dados foi conduzida no Sistema de Transposição de Peixes (STP) do Sítio Pimental (Figura 3A). O sistema utiliza câmeras de alta resolução instaladas em agosto de 2023. Essas câmeras, integradas a um sistema de gravação digital (DVR), foram posicionadas para capturar vídeos subaquáticos por meio de um visor de vidro com dimensões de 2 x 2 metros, que permite a observação detalhada e contínua da passagem dos peixes que utilizam o canal construído (Figura 3B). As câmeras operam ininterruptamente (24 horas por dia, 7 dias por semana) (Figura 3C). Dos vídeos capturados foram gerados as imagens que serviram como

dados de entrada para o treinamento e validação de um modelo de visão computacional. As imagens destinadas ao treinamento foram selecionadas em períodos distintos de 2023 a 2024 contemplando intervalos diurnos, noturnos e em diferentes períodos hidrológicos, a fim de abranger a maior gama possível de variações nas condições de visibilidade subaquática. Oferecendo ao modelo uma base ampla e detalhada para a interpretação das diferentes condições ambientais.



Figura 3: Vista externa do STP (A), Visor e sala de monitoramento do STP(C) e canal do STP (B)

#### 2.4. Retirada de quadros e Anotação manual de dados

Para extrair os quadros dos vídeos obtidos do STP, utilizou-se o software de reprodução de vídeos VLC que é um reprodutor multimídia livre, de código aberto, multiplataforma [20] e que permite a remoção de quadros específicos do vídeo, mantendo a resolução original, por se tratar de um grande volume de imagens em que muitas dessas não possuem nenhuma atividade no sentido de passagem de peixes através do visor, as imagens foram selecionadas com o critério de que, seriam selecionadas as que fossem possíveis realizar com certeza a identificação manual. Os quadros capturados foram rotulados manualmente usando a plataforma V7, que aplica o aprendizado de máquina ao processo de anotação, permitindo uma alta velocidade de marcação mais rápida.[19] Foram realizadas a identificação e a anotação das espécies de peixes presentes em cada quadro dos vídeos como exemplificado na Figura 4, estas anotações serviram como referência para o treinamento e a validação do modelo, após concluído o processo de desenho dos polígonos ao redor dos corpos dos peixes o conjunto de dados é exportado no formato utilizado no treinamento do modelo.

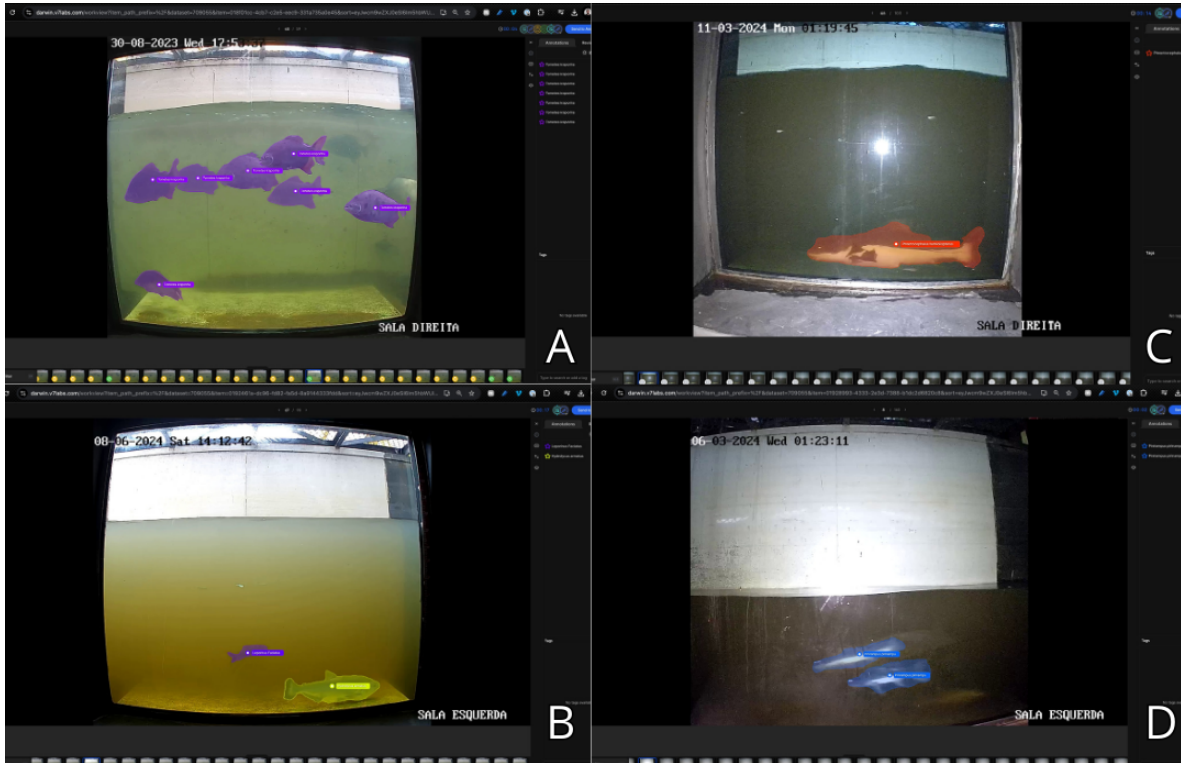


Figura 4: Rotulação das imagens no V7.

### 2.5. O Conjunto de Dados

O conjunto de dados utilizado foi composto por 1000 imagens, das quais 700 foram destinadas ao treinamento, 150 para a validação e 150 para os testes. Todas as imagens foram rotuladas com diferentes espécies, previamente selecionadas com base na tabela de monitoramento da equipe responsável pelo sistema de monitoramento do STP. O critério de escolha dessas espécies considerou a maior frequência de aparição nos registros e sua relevância como espécies migratórias, como por exemplo o bagre migrador *Phractocephalus hemiliopterus*. O número de instâncias de algumas espécies é relativamente menor, pois em determinados quadros, uma espécie como *Cichla melanie* poderia aparecer com mais frequência do que, por exemplo, um *Leporinus friderici*. Assim, mesmo que ambas fossem capturadas no mesmo quadro, a espécie *Cichla melanie* era identificada com maior recorrência, justificando a diferença na quantidade de registros.

### 2.6. Treinamento da Rede Neural Convolutiva (RNC)

Para a detecção e classificação das espécies de peixes nos vídeos subaquáticos, foram utilizadas Redes Neurais Convolucionais (RNCs), implementadas através do modelo YOLO v8 [10], reconhecido por sua eficácia em tarefas de detecção de imagens. O treinamento das RNCs foi conduzido utilizando o conjunto de dados previamente rotulados. Um passo essencial antes do treinamento, foi a aplicação da técnica de data augmentation (aumento de dados) [24], realizada automaticamente pelo próprio YOLO v8 através do uso de hiperparâmetros. A técnica de data augmentation foi utilizada para gerar variações de imagens a partir do conjunto de dados original, aplicando transformações como rotação, translação, escalonamento, dessa forma, o modelo foi exposto a diferentes ângulos de captura e variações de iluminação, com o

intuito de aprimorar sua capacidade de generalização e seu desempenho em condições variadas, como as encontradas no ambiente natural. Durante o treinamento, ajustaram-se também parâmetros como o número de épocas e o valor de patience para maximizar o desempenho do modelo e evitar o overfitting — situação em que o modelo apresenta desempenho adequado apenas nas condições específicas do treinamento, com pouca capacidade de generalização para novos dados [2].

O treinamento foi conduzido na plataforma Google Colab, que suporta a execução da linguagem de programação Python, que foi utilizada na implementação do modelo YOLO v8. A plataforma oferece acesso a GPUs (Unidades de Processamento Gráfico), que aceleram consideravelmente o tempo de processamento em tarefas de visão computacional, sendo esse recurso fundamental para o processamento de grandes volumes de imagens de alta resolução. Utilizou-se a GPU NVIDIA A100, associada ao plano PRO do Google Colab, devido ao tamanho e complexidade do modelo.

### *2.7. Parâmetros de Treinamento*

Os parâmetros de treinamento foram ajustados para garantir um bom resultado de treinamento pelo modelo, a Tabela 1 apresenta os principais parâmetros utilizados, abrangendo desde o número de épocas e critérios de parada antecipada até os ajustes relacionados ao tamanho das imagens, tamanho do batch, e configurações de regularização. O número de épocas foi definido em 300, enquanto o critério de early stopping foi configurado com uma paciência de 50 épocas, permitindo a interrupção do treinamento caso não houvesse um progresso notável, neste cenário o modelo encerrou o treinamento em 119 épocas. As imagens de entrada foram redimensionadas para 640 x 640 pixels, e cada iteração do treinamento processou um batch de 16 imagens, compatível com a capacidade de memória da GPU utilizada.

Tabela 1: Parâmetros de treinamento e suas descrições.

Parâmetro	Descrição	Valor
Epochs	Número total de épocas de treinamento	300
Train	Tipo de treinamento utilizado	Segment
Early Stopping Patience	Número de épocas sem melhora antes de interromper	50
Image Size	Dimensões das imagens de entrada (pixels)	640 x 640
Batch Size	Número de imagens processadas por iteração	16
Learning Rate (Initial)	Taxa de aprendizagem inicial para atualização dos pesos	0.01
Momentum	Fator de estabilidade para atualização dos pesos	0.937
Weight Decay	Regularização para evitar overfitting	0.0005
Degrees	Rotação aleatória máxima aplicada nas imagens	5.0°
Translate	Translação máxima aplicada horizontal/verticalmente	0.1 (10%)
Scale	Varição máxima aplicada ao tamanho das imagens	0.5 (50%-150%)
Fliplr	Probabilidade de inversão horizontal das imagens	0.5 (50%)
HSV_s	Varição máxima na saturação (espaço HSV)	0.7 ( $\pm 70\%$ )
HSV_v	Varição máxima no brilho (espaço HSV)	0.4 ( $\pm 40\%$ )
Mosaic	Probabilidade de uso da técnica Mosaic	1.0 (100%)
GPU	Hardware utilizado para treinamento	NVIDIA A100

A estratégia de data augmentation foi configurada para aumentar a diversidade do conjunto de treinamento, aplicando transformações automáticas, como rotações de até 5 graus, translações horizontais e verticais de até 10%, escalonamento entre 50% e 150% do tamanho original, e espelhamento horizontal em 50% das imagens. A taxa de aprendizado inicial foi definida em 0.01, ajustada progressivamente durante o treinamento, com momentum de 0.937 para estabilizar as atualizações dos pesos, e weight decay de 0.0005 para minimizar riscos de overfitting. O treinamento foi conduzido em uma GPU NVIDIA A100 no Google Colab PRO, aproveitando a alta capacidade de processamento para lidar com o grande volume de imagens e os cálculos necessários. Durante o processo, as perdas monitoradas incluíram box loss (localização dos bounding boxes), class loss (classificação das espécies) e segmentation loss (segmentação das áreas de interesse).

## 2.8. Métricas de avaliação Utilizadas

### 2.8.1. Precisão

A precisão mede a proporção de detecções corretas em relação ao total de detecções realizadas pelo modelo. É dada pela fórmula:

$$\text{Precision} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Positives (FP)}}$$

Um valor alto de precisão indica que o modelo tem baixo número de falsos positivos, ou seja, ele evita "confundir" outras classes com a classe alvo.

### 2.8.2. Recall

O recall mede a proporção de instâncias da classe correta que foram identificadas pelo modelo. É dado pela fórmula:

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Negatives (FN)}}$$

Um recall alto indica que o modelo consegue detectar a maioria das instâncias relevantes, mas não considera o número de falsos positivos.

### 2.8.3. F1-Score

O F1-score é a média harmônica entre precisão e recall, balanceando os dois aspectos:

$$\text{F1-Score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

### 2.9. mAP (mean Average Precision)

O mAP é a média da precisão calculada em diferentes níveis de limites no modelo:

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \text{AP}_i$$

Essa metríca é responsável por avaliar a performance global do modelo ao longo de várias classes. Já mAP50 é a precisão média considerando um limite de IoU (Intersection over Union)  $\geq 0.5$ .

$$\text{mAP} = \frac{1}{N} \sum_{t=1}^T \frac{1}{C} \sum_{i=1}^C \text{AP}_{i,t}$$

para que uma predição seja válida, deve haver pelo menos 50% de sobreposição entre as áreas.

O IoU (Intersection over Union) mede a sobreposição entre as predições e o ground truth (dados reais anotados manualmente, como caixas delimitadoras), sendo calculado pela razão entre a área de interseção e a área de união.

### 2.10. Regressão Linear

A regressão linear foi utilizada para modelar a relação entre o número de instâncias e o F1-Score. A equação da regressão linear é dada por:

$$y = a \cdot x + b$$

Onde:

- $y$  é o F1-Score previsto.
- $x$  é o número de instâncias.

- $a$  é o coeficiente angular (inclinação da reta), que indica o aumento esperado no F1-Score para cada instância adicional.
- $b$  é o coeficiente linear (intercepto), que representa o valor esperado do F1-Score quando o número de instâncias é zero.

### 2.11. Avaliação do Impacto do Porte das Espécies sobre o Desempenho do Modelo

Para comparar o desempenho entre espécies classificadas como de tamanho grande e as espécies dos grupos médio e pequeno combinados, foi aplicado o teste T de Welch.

## 3. Resultados

### 3.1. Métricas de Desempenho por Espécie

Os resultados obtidos para as métricas de precisão, cobertura e F1-Score, juntamente com o número de instâncias para cada espécie no conjunto de dados, são apresentados na Tabela 2. Estas métricas avaliam o desempenho do modelo na identificação de diferentes espécies de peixes presentes no conjunto de dados. Observa-se que as espécies *Phractocephalus hemiliopterus* e *Cichla melaniae* apresentaram os melhores desempenhos, com F1-Scores de 91% e 87%, respectivamente. Esse resultado reflete a eficácia do modelo em detectar e classificar espécies com características visuais bem definidas e representativas no conjunto de treinamento. Por outro lado, espécies como *Leporinus friderici* e *Leporinus sp2* apresentaram os menores F1-Scores, 52% e 55%, indicando desafios na diferenciação dessas classes, possivelmente devido à baixa variabilidade visual ou insuficiência de dados. Em relação à diferença de tamanhos, não foi observada diferença estatisticamente significativa entre os grupos ( $t = 0,55$ ;  $p = 0,59$ ), o que corrobora achados anteriores e sugere que o porte das espécies não afeta de forma relevante o desempenho do modelo.

De forma geral, o modelo alcançou desempenho consistente para a maioria das espécies, com valores de F1-Score acima de 70% para 12 das 19 classes analisadas. O estudo ainda mostrou que, com técnicas de aumento de dados, como a adição de ruído e desfoque, foi possível melhorar o F1-Score para até 86%, reforçando que valores acima de 70% são um bom ponto de partida para modelos de detecção e classificação.

Tabela 2: Métricas para diferentes espécies de peixes com seus respectivos tamanhos e número total de instâncias, ordenado pelo F1-Score.

Espécie	Tamanho	Precisão (%)	Recall (%)	F1-Score (%)	Total de Instâncias
<i>Phractocephalus hemiliopterus</i>	Grande	92	90	91	103
<i>Cichla melaniae</i>	Grande	90	85	87	217
<i>Pinirampus pirinampu</i>	Grande	88	82	85	171
<i>Hydrolycus armatus</i>	Grande	85	80	82	159
<i>Brycon falcatus</i>	Médio	85	80	82	104
<i>Brycon aff. pesu adiposa hialina</i>	Pequeno	82	78	80	154
<i>Tometes kranponhah</i>	Grande	80	75	77	146
<i>Boulengerella cuvieri</i>	Grande	80	75	77	49
<i>Leporinus tigrinus</i>	Pequeno	78	72	75	142
<i>Leporinus maculatus</i>	Pequeno	75	70	72	12
<i>Leporinus faciatus</i>	Médio	75	70	72	94
<i>Prochilodus nigricans</i>	Grande	72	68	70	93
<i>Panaque armbrusteri</i>	Médio	70	65	67	30
<i>Myleus schomburgkii</i>	Grande	68	62	65	20
<i>Serrasalmus rhombeus</i>	Grande	65	60	62	19
<i>Aphonotorus emarginatus</i>	Médio	62	58	60	9
<i>Leporinus nattereri</i>	Grande	60	55	57	9
<i>Leporinus sp2</i>	Pequeno	58	52	55	8
<i>Leporinus friderici</i>	Grande	55	50	52	6

### 3.2. Relação entre o Número de Instâncias e o F1-Score

A Figura 5 apresenta a relação entre o número de instâncias por espécie e o F1-score, observando-se uma tendência crescente. A regressão linear ajustada ( $R^2 = 0.68$ ) sugere que 68% da variação do F1-score pode ser explicada pelo número de instâncias. O modelo indica que, para cada instância adicional, espera-se um aumento médio de 0.136 pontos no F1-score, com um valor-p de **0.0009**, indicando que essa relação é estatisticamente significativa. Isso reforça a importância da quantidade de dados para a qualidade da classificação automática.




Figura 5: Regressão linear entre o número de instâncias por espécie e o F1-Score.

### 3.3. Curvas de Aprendizado

Durante o treinamento do modelo, as perdas monitoradas incluíram box loss, class loss e segmentation loss, registradas tanto para o conjunto de treinamento quanto para o de validação. As curvas de aprendizado mostram uma redução consistente dessas perdas ao longo das 119 épocas, refletindo o progresso do modelo em aprender as características das classes de peixes.

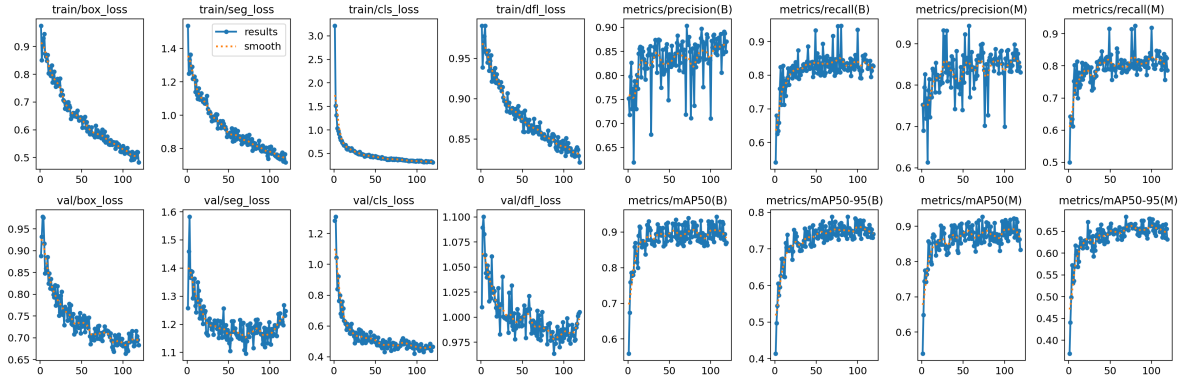


Figura 6: Resultados ao longo das épocas.

### 3.4. Exemplos de Detecções

As Figuras 7, 8 e 9 apresentam exemplos das detecções realizadas pelo modelo durante o processo de validação, utilizando imagens subaquáticas coletadas tanto em períodos diurnos quanto noturnos, abrangendo diferentes momentos entre os anos de 2023 e 2024. Essas imagens evidenciam claramente a precisão dos bounding boxes, bem como a correta classificação das espécies de peixes amazônicos. Adicionalmente, é possível observar que o modelo mantém um desempenho consistente mesmo sob condições ambientais adversas, incluindo alta turbidez da água, reflexos decorrentes da iluminação artificial utilizada no sistema de captura e variações na luminosidade, reforçando assim seu potencial para uso no monitoramento automatizado da biodiversidade em ambientes aquáticos complexos.



Figura 7: Resultados das predições 1

A Figura 7 ilustra a diversidade de espécies detectadas pelo modelo em condições variadas de visibilidade, com detecções que incluem *Hydrolycus armatus*, *Tometes kranponhah*, *Brycon aff. pesu adiposa hialina*, *Cichla melaniae*. Destaca-se a capacidade do modelo em identificar corretamente diferentes espécies em um mesmo quadro, evidenciando sua robustez na distinção de características morfológicas entre os indivíduos presentes na passagem de peixes.



Figura 8: Resultados das predições 2

A Figura 8 apresenta instantes do monitoramento em que há um número expressivo de detecções simultâneas, com peixes de diferentes portes e comportamentos. As espécies *Leporinus tigrinus*, *Prochilodus nigricans*, *Brycon falcatus*, *Boulengerella cuvieri*, *Panaque armbrusteri*, *Tomates kranponhah* e *Cichla melaniae* foram corretamente classificadas, mesmo em cenários onde há sobreposição de indivíduos e reflexos na coluna d'água. Essa capacidade de detecção simultânea é essencial para a análise da dinâmica de movimentação das espécies no Sistema de Transposição de Peixes.

A Figura 9 evidencia o bom desempenho do modelo em condições de baixa luminosidade, com detecções feitas durante o período noturno, onde a iluminação artificial pode gerar desafios adicionais devido a reflexos intensos e contraste reduzido. Ainda assim, as espécies foram corretamente identificadas, demonstrando que o modelo mantém sua precisão mesmo quando submetido a diferentes padrões de iluminação e variação nas condições ambientais.




Figura 9: Resultados das predições 3

#### 4. Discussão

A regressão linear realizada ( $R^2 = 0,68$ ;  $p < 0,001$ ) demonstrou que 68% da variação no F1-Score pode ser explicada pelo número de instâncias por espécie (Figura 5). Esse resultado está alinhado com estudos anteriores em ecossistemas aquáticos, onde a representatividade dos dados mostrou-se relevante para o desempenho de modelos de detecção baseados em aprendizado profundo [11]. A equação obtida ( $y = 0,136x + 63,34$ ) indica que cada instância adicional aumenta o F1-Score em 0,136 pontos, um achado com implicações práticas diretas para programas de monitoramento em larga escala.

Por outro lado espécies com características distintas, como *Phractocephalus hemiliopterus* (F1-Score: 91%), apresentaram desempenho superior mesmo com menor representatividade (103 instâncias). Esse fenômeno pode ser atribuído a traços únicos como padrões

de coloração contrastantes, consistentemente reconhecidos por redes neurais convolucionais em ambientes subaquáticos [15]. Além disso, o tamanho corporal também desempenha um papel importante, conforme indicado no estudo de [22], que demonstra que o tamanho dos objetos influencia diretamente o desempenho do modelo.

As curvas de aprendizado do modelo (Figura 6) demonstraram uma redução consistente nas perdas de box loss (localização dos bounding boxes) e class loss (classificação das espécies) ao longo das 119 épocas de treinamento, indicando que o modelo convergiu adequadamente sem sinais evidentes de overfitting. Essa estabilização foi possível devido ao critério de early stopping (paciência de 50 épocas), que interrompeu o treinamento quando não houve melhoria significativa nas métricas de validação. A ausência de divergência entre as curvas de treinamento e validação reforça a eficácia das técnicas de data augmentation (rotação, translação, ajuste de saturação), que garantiram a generalização do modelo para diferentes condições ambientais capturadas no conjunto de dados.

O desempenho do modelo em condições ambientais adversas, como alta turbidez e variações de iluminação, mostrou-se como um importante ponto a ser levado em consideração, em razão da possibilidade de prejudicar o desempenho das identificações. Dessa forma, o uso de técnicas de *data augmentation* — incluindo variação de saturação ( $hsv\_s = \pm 70\%$ ) e brilho ( $hsv\_v = \pm 40\%$ ) — permitiu simular cenários complexos, como águas carregadas de sedimentos durante o período de chuvas intensas na bacia do Xingu.

Os resultados deste estudo têm implicações diretas para políticas de conservação na Amazônia. A capacidade de monitorar principalmente espécies migratórias oferece subsídios para ajustes operacionais nas usinas hidrelétricas, como a modulação do fluxo de água nas passagens durante períodos de pico migratório. Isso é particularmente relevante diante de projeções que indicam a construção de novas barragens na bacia amazônica até 2030 [13], o que exigirá ferramentas eficientes para equilibrar geração de energia e preservação ecológica. Além disso, a detecção automatizada reduz a necessidade de métodos invasivos, como captura e marcação, que representam riscos para espécies ameaçadas.

#### 4.1. Limitações

Apesar dos avanços, o processo ainda apresenta limitações que demandam atenção no desenvolvimento do projeto. A flutuação sazonal, por exemplo, exige a coleta contínua de dados ao longo de múltiplos ciclos hidrológicos para garantir a generalização do modelo, um aspecto crucial para abranger a diversidade de espécies que transitam anualmente pelo canal da usina. No estudo atual, as imagens foram selecionadas com base na viabilidade de identificação visual das espécies, mas, em um sistema de aplicação prática, é essencial que o modelo mantenha precisão mesmo em cenários de baixa visibilidade da água, evitando distorções que comprometam a integridade dos dados.

Outro desafio reside no tempo de treinamento do modelo. A utilização da GPU NVIDIA A100 via Google Colab Pro, ainda que eficaz para o banco de dados reduzido deste estudo, revela obstáculos de escalabilidade. Em cenários futuros, com a expansão do volume de dados ou do número de câmeras, a infraestrutura atual poderá se tornar insuficiente. Além disso, a seleção manual de quadros com atividade de peixes consome tempo significativo, o que sugere a exploração de alternativas para automatizar essa etapa, como algoritmos preliminares de detecção de movimento, otimizando assim o processo.

Para aplicações práticas, recomenda-se a integração do modelo ao sistema de monitoramento do STP do sítio pimental como ferramenta complementar. A automatização permitiria

a geração de relatórios em tempo real sobre a frequência de passagem de espécies migratórias, como *Prochilodus nigricans*, cujos padrões de movimento são críticos para avaliar a eficácia das escadas de peixes. A escalabilidade da abordagem, contudo, depende de adaptações locais, como ajustes na resolução das câmeras e calibração sazonal do modelo, garantindo seu desempenho em diferentes condições operacionais.

## REFERÊNCIAS

- [1] Abdulghani, A.; Abdulghani, M.; Walters, W.; Abed, K. Data Augmentation with Noise and Blur to Enhance the Performance of YOLO7 Object Detection Algorithm. In: Congress in Computer Science, Computer Engineering, & Applied Computing (CSCE). Las Vegas, NV, USA: IEEE, 2023. p. 180–185. DOI: 10.1109/CSCE60160.2023.00034.
- [2] Aburass, S. Quantifying Overfitting: Introducing the Overfitting Index. 2023. DOI: 10.48550/arXiv.2308.08682.
- [3] Antonelli, A.; Dhanjal-Adams, K.; Silvestro, D. Integrating machine learning, remote sensing and citizen science to create an early warning system for biodiversity. *Plants, People, Planet*, volume 5, number 3, pages 307–316, 2022. DOI: 10.1002/ppp3.10337.
- [4] Bizzotto, P. M.; Godinho, A. L.; Vono, V.; Kynard, B.; Godinho, H. P. Influence of seasonal, diel, lunar, and other environmental factors on upstream fish passage in the Igarapava Fish Ladder, Brazil. *Ecology of Freshwater Fish*, volume 18, pages 461–472, 2009. DOI: 10.1111/j.1600-0633.2009.00361.x.
- [5] Blemel, H.; Bennett, A.; Hughes, S.; Wienhold, K.; Flanigan, T.; Lutcavage, M.; Lam, C. H.; Tam, C. Improved fish tagging technology: field test results and analysis. In: OCEANS 2019-Marseille. Marseille: IEEE, 2019. pages 1–6. DOI: 10.1109/OCEANSE.2019.8867259.
- [6] Blanco, G. I.; Manners, R.; Varela-Ortega, C.; Tarquis, A. M.; Martorano, L. G.; Toledo, M. Examining the sustainability and development challenge in agricultural-forest frontiers of the Amazon Basin through the eyes of locals. *Natural Hazards Earth System Sciences*, volume 20, pages 797–813, 2020. DOI: 10.5194/nhess-20-797-2020.
- [7] Chaudhari, S. N.; Pokhrel, Y. Alteration of river flow and flood dynamics by existing and planned hydropower dams in the Amazon River Basin. *Water Resources Research*, volume 58, number 5, 2022. DOI: 10.1029/2021WR030555.
- [8] Deneu, B.; Servajean, M.; Bonnet, P.; Botella, C.; Munoz, F.; Joly, A. Convolutional neural networks improve species distribution modelling by capturing the spatial structure of the environment. *PLoS Computational Biology*, volume 17, number 4, e1008856, 2021. DOI: 10.1371/journal.pcbi.1008856.
- [9] Hilborn, R.; Amoroso, R. O.; Anderson, C. M.; Baum, J. K.; Branch, T. A.; Costello, C.; De Moor, C. L.; Faraj, A. D.; Hively, J.; Jensen, O. P.; Kurota, H.; Little, L. R.; Mace, P. T.; McClanahan, M. C.; Melnychuk, C.; Minto, G. C.; Osio, A. M.; Parma, M.; Pons, S.; Segurado, C. S.; Szuwalski, J. R.; Wilson, J.; Ye, Y. Effective fisheries management instrumental in improving fish stock status. *Proceedings of the National Academy of Sciences of the United States of America*, volume 117, number 4, pages 2218–2224, 2020. DOI: 10.1073/pnas.1909726116.
- [10] Jocher, G.; Qiu, J.; Chaurasia, A. Ultralytics YOLO. Version 8.0.0, January 2023. Available at: <https://github.com/ultralytics/ultralytics>.
- [11] Kandimalla, V.; Richard, M.; Smith, F.; Quirion, J.; Torgo, L.; Whidden, C. Automated detection, classification and counting of fish in fish passages with deep learning. *Frontiers in Marine Science*, volume 8, 823173, 2022. DOI: 10.3389/fmars.2021.823173.

- [12] Latrubesse, E. M.; Arima, E. Y.; Dunne, T.; Park, E.; Baker, V. R.; D’Horta, F. M.; Stevaux, J. C. Damming the rivers of the Amazon basin. *Nature*, volume 546, number 7658, pages 363–369, 2017. DOI: 10.1038/nature22333.
- [13] Lees, A. C.; Peres, C. A.; Fearnside, P. M.; Schneider, M.; Zuanon, J. A. Hydropower and the future of Amazonian biodiversity. *Biodiversity and Conservation*, volume 25, pages 451–466, 2016. DOI: 10.1007/s10531-016-1072-3.
- [14] Norte Energia SA. Perguntas e Respostas (FAQ) - UHE Belo Monte. 2023.
- [15] Rathi, D.; Jain, S.; Indu, S. Underwater fish species classification using convolutional neural network and deep learning. In: *Ninth International Conference on Advances in Pattern Recognition (ICAPR)*. Bangalore, India: IEEE, 2017. pages 1–6. DOI: 10.1109/ICAPR.2017.8593044.
- [16] Santos, R. E.; Pinto-Coelho, R. M.; Drumond, M. A.; Fonseca, R.; Zanchi, F. B. Damming Amazon Rivers: Environmental impacts of hydroelectric dams on Brazil’s Madeira River according to local fishers’ perception. *Ambio*, volume 49, number 10, pages 1612–1628, 2020. DOI: 10.1007/s13280-020-01316-w.
- [17] Silva, A. T.; Lucas, M. C.; Castro-Santos, T.; Katopodis, C.; Baumgartner, L. J.; Thiem, J. D.; Cooke, S. J. The future of fish passage science, engineering, and practice. *Fish and Fisheries*, volume 19, number 2, pages 340–362, 2018. DOI: 10.1111/faf.12258.
- [18] Strelnikova, D.; Paulus, G.; Käfer, S.; Anders, K.-H.; Mayr, P.; Mader, H.; Scherling, U.; Schneeberger, R. Drone-based optical measurements of heterogeneous surface velocity fields around fish passages at hydropower dams. *Remote Sensing*, volume 12, number 3, 384, 2020. DOI: 10.3390/rs12030384.
- [19] V7 Labs. Image Annotation. 2023.
- [20] VIDEOLAN. VLC media player. 2023.
- [21] Xu, J.; Sang, W.; Dai, H.; Lin, C.; Ke, S.; Mao, J.; Wang, G.; Shi, X. A detailed analysis of the effect of different environmental factors on fish phototactic behavior: Directional fish guiding and expelling technique. *Animals*, volume 12, number 3, 240, 2022.
- [22] Yang, Y.; Feng, F.; Liu, G.; Di, J. MEL-YOLO: A Novel YOLO Network With Multi-scale, Effective and Lightweight Methods for Small Object Detection in Aerial Images. 2024, p. 1. DOI: 10.1109/ACCESS.2024.3517663.
- [23] Xuan, F.; Yanmin, C. A review on the impact of vertical slotted fish passages on fish populations in river basins. *International Journal for Research in Applied Science & Engineering Technology*, volume 12, number IX, page 540, 2024. DOI: 10.22214/ijraset.2024.64196.
- [24] Zhang, J. Classification and comparison of data augmentation techniques. *Transactions on Computer Science and Intelligent Systems Research*, volume 6, pages 180–187, 2024. DOI: 10.62051/7e91md96.