

VISÃO COMPUTACIONAL PARA CONTAGEM AUTOMATIZADA DE PEIXES EM PISCICULTURA: UMA REVISÃO NARRATIVA

**COMPUTER VISION FOR AUTOMATED FISH COUNTING IN AQUACULTURE:
A NARRATIVE REVIEW**

Engenharias • 09/08/2026

REGISTRO DOI: [10.70773/revistatopicos/786228078](https://doi.org/10.70773/revistatopicos/786228078)

Eduardo Mizael Clemente¹

Geraldo Andrade de Oliveira²

Leonardo Garcia Marques³

RESUMO

A revisão bibliográfica orientada por buscas mapeia avanços recentes na contagem automatizada de peixes em sistemas de piscicultura, com foco em técnicas de visão computacional e aprendizado profundo. O levantamento teve caráter narrativo e empregou termos de busca, critérios de inclusão e exclusão e agrupamento temático dos trabalhos, sem pretensão de constituir uma revisão sistemática exaustiva. Os estudos analisados convergem para três eixos principais: (1) aprimoramentos arquiteturais, como mecanismos de atenção, convoluções deformáveis e estratégias de fusão multiescala; (2) integração entre detecção e rastreamento para reduzir contagens duplicadas; e (3) otimização para dispositivos de borda. Em contextos de alta densidade, abordagens baseadas em mapas de densidade aparecem como alternativa à detecção individual, enquanto sensores complementares, anotação assistida e aumentos de dados ampliam as possibilidades de aquisição e treinamento. Os resultados reportados são promissores, mas dependem dos conjuntos de dados, das espécies, das condições de captura e das métricas adotadas em cada estudo.

Palavras-chave: contagem automatizada de peixes; visão computacional; aprendizado profundo; YOLO; piscicultura; rastreamento multi-objeto.

ABSTRACT

This search-oriented literature review maps recent advances in automatic fish counting for aquaculture systems, focusing on computer vision and deep learning techniques. The survey followed a narrative approach supported by search terms, inclusion and exclusion criteria, and thematic grouping, without claiming to be an exhaustive systematic review. The analyzed studies converge on

three main directions: (1) architectural enhancements such as attention mechanisms, deformable convolutions, and multi-scale feature fusion; (2) integrated detection-tracking pipelines designed to reduce duplicate counts; and (3) optimization for edge devices. In high-density scenarios, density-map approaches provide an alternative to individual detection, while complementary sensors, assisted annotation, and data augmentation broaden acquisition and training strategies. The reported results are promising, but remain dependent on the datasets, species, acquisition conditions, and evaluation metrics adopted in each study.

Keywords: automatic fish counting; computer vision; deep learning; YOLO; aquaculture; multi-object tracking.

1. INTRODUÇÃO

A piscicultura intensiva representa um pilar importante para a segurança alimentar global, com uma produção aquática que ultrapassou 120 milhões de toneladas em 2022, segundo dados da FAO (Food and Agriculture Organization of the United Nations). Nesse contexto, a contagem de peixes apoia o manejo de estoques, o planejamento do arrastoamento e a comercialização. Tradicionalmente, essa tarefa é realizada de forma manual, o que introduz variabilidade humana, demanda tempo operacional e pode aumentar a manipulação e o estresse dos animais. Com o avanço das tecnologias digitais, a visão computacional e o aprendizado de máquina passaram a ser investigados como alternativas para apoiar a contagem, com resultados que variam conforme o ambiente, a espécie, a qualidade das imagens e o protocolo de avaliação.

Esta seção apresenta uma revisão bibliográfica orientada por buscas sobre contagem automatizada de peixes em sistemas de

piscicultura, com ênfase em visão computacional e aprendizado profundo. O objetivo é identificar abordagens, contribuições e limitações relevantes para o desenvolvimento experimental desta dissertação. O foco recai sobre detecção de objetos, rastreamento multiobjeto, mapas de densidade e otimização para dispositivos de borda, considerando desafios como turbidez, baixa iluminação, oclusões, reflexos e variações comportamentais dos peixes.

A revisão fornece a base conceitual para o processo desenvolvido nos capítulos seguintes. Os estudos selecionados, publicados entre 2017 e 2025 e localizados em fontes como ScienceDirect, IEEE Xplore, arXiv e Google Scholar, indicam tendências como arquiteturas mais leves, mecanismos de atenção, integração entre detecção e rastreamento e uso complementar de sensores ópticos, infravermelhos e acústicos. Também evidenciam lacunas relacionadas à diversidade dos conjuntos de dados, à comparação entre protocolos e à avaliação em condições produtivas.

A estrutura do capítulo separa o protocolo de busca e seleção, apresentado em Material e métodos, da síntese crítica dos trabalhos agrupados por contribuição temática, apresentada em Resultados e discussão. A conclusão relaciona os achados às escolhas do equipamento e do pipeline computacional desenvolvidos nesta pesquisa.

2. MATERIAL E MÉTODOS

2.1. Definição do Processo de Revisão Bibliográfica

A presente revisão bibliográfica foi orientada por buscas realizadas nas fontes **ScienceDirect**, **IEEE Xplore**, **arXiv** e **Google Scholar**, priorizando trabalhos publicados entre **2017 e 2025**. O levantamento

teve caráter narrativo: os registros preservados permitem identificar os termos empregados e os estudos selecionados, mas não reconstituir com segurança o número de resultados, duplicatas e exclusões em cada etapa. Por isso, o procedimento não é apresentado como revisão sistemática nem como levantamento exaustivo. O foco recaiu sobre visão computacional, aprendizado de máquina, redes neurais profundas e processamento de imagens aplicados à detecção, ao rastreamento ou à contagem de organismos aquáticos.

Foram adotados os seguintes critérios de seleção:

- **Inclusão:** artigos em inglês ou português; publicados em periódicos com revisão por pares ou preprints relevantes (arXiv); que tratem de detecção, rastreamento ou contagem de organismos aquáticos por meio de visão computacional; e que apresentem validação experimental com métricas quantitativas.
- **Exclusão:** estudos puramente teóricos sem validação experimental; trabalhos focados exclusivamente em ecologia marinha sem componente tecnológico de detecção/contagem; e artigos duplicados ou versões preliminares de trabalhos já incluídos em suas versões finais.

A seleção final priorizou trabalhos com relevância direta para o contexto de piscicultura intensiva, considerando a aplicabilidade das técnicas propostas a cenários de tanques, viveiros e canaletas de passagem.

2.2. Orientação das Buscas

A busca exploratória inicial utilizou a expressão “**contagem de peixe**”. A leitura dos títulos e resumos ajudou a reconhecer termos recorrentes e a delimitar o foco tecnológico do levantamento.

2.3. Análise Exploratória dos Resumos

Como apoio exploratório ao refinamento dos termos, os resumos (*abstracts*) preservados na etapa inicial foram submetidos a uma contagem de frequência de palavras, apresentada na Tabela 1. Os registros disponíveis não permitem estabelecer com segurança o tamanho total do universo originalmente recuperado; consequentemente, as frequências são usadas apenas para documentar a orientação temática das buscas, e não como resultado bibliométrico ou evidência de cobertura exaustiva.

Tabela 1. Frequência dos termos mais recorrentes nos abstracts analisados.

Termo	Frequência
fish	113
detection	27
learning	19
deep	17
identification	14
neural	11
tracking	8
network	7
counting	5

resumos, palavras-chave e referências dos estudos considerados pertinentes.

2.5. Seleção e Revisão dos Artigos

Os trabalhos selecionados por pertinência temática foram analisados quanto às contribuições metodológicas, aos conjuntos de dados, às métricas reportadas e à aplicabilidade ao problema estudado. A síntese é narrativa e não atribui pesos estatísticos aos resultados de estudos conduzidos sob protocolos diferentes.

3. RESULTADOS E DISCUSSÃO

3.1. Aprimoramentos Arquiteturais para Detecção Subaquática

A família YOLO consolidou-se como base predominante para detecção de peixes, com sucessivas adaptações voltadas a superar desafios de ambientes aquáticos — turbidez, baixa luminosidade, reflexos, oclusões e alta densidade de indivíduos.

No âmbito do YOLOv3, Muksit et al. (2022) propuseram o YOLO-Fish, incorporando um módulo Spatial Pyramid Pooling (SPP) e ajuste do upsample step size para elevar a sensibilidade a peixes pequenos em cenas densas, atingindo desempenho comparável ao YOLOv4 com menor custo computacional. Os autores disponibilizaram dois datasets públicos (DeepFish e OzFish), contribuindo para a reprodutibilidade da área. Ainda com YOLOv3, Loulidi et al. (2022) validaram a detecção em vídeos da costa atlântica do Marrocos, reportando precisão média média (mAP, do inglês mean Average Precision) de aproximadamente 91,3% após técnicas de aumento de dados e avaliação sob ruído e iluminação adversa, evidenciando capacidade de generalização para ambientes naturais distintos.

Avanços mais recentes concentram-se no YOLOv8. Yi, Han e Lai (2025) propuseram o YOLOv8n-DDSW, integrando convoluções deformáveis (C2f-DCN), mecanismo de atenção duplo (DPSE), camada para pequenas detecções e Wise-IOU loss, obtendo aumento de 7,7% na mAP50-95 em cenários de aquicultura densa. Na mesma direção, Liu et al. (2025) apresentaram o UWYOLO com módulo Large Separable Kernel Attention (LSKA), melhorando a extração de características de forma e atingindo 84,9% de mAP em dataset próprio de quatro categorias marinhas. Já Jiang, X. et al. (2025) integraram atenção multi-escala (C2f-EMA), backbone compacto via PWConv, fusão ponderada (WFPN) e upsampling ciente de conteúdo (CARAFE), reportando ganhos de mAP@0.5 nos benchmarks URPC2019/2020.

Contribuições baseadas em YOLOv5 incluem o DCM-ATM-YOLOv5 de Li, H. et al. (2022), que incorpora Deformable Convolution Module e Adaptive Threshold Module (limiar dinâmico por grau de oclusão), alcançando AP de 97,53% e Recall de 98,09% em dados reais de viveiros. Xu et al. (2025) propuseram o IMC-YOLO para detecção de moluscos em ambientes de maré, combinando atenção por canal e convoluções deformáveis para lidar com alto ruído de fundo e visibilidade reduzida — estratégias transferíveis a tanques de piscicultura.

Propostas voltadas especificamente a viveiros incluem o AquaYOLO (Vijayalakshmi; Sasithradevi, 2025), que adapta a família YOLO para ambientes com água turva, reflexos, bolhas e superlotação, introduzindo camadas de atenção e cabeças para alvos pequenos para reduzir falsos negativos.

Esses aprimoramentos arquiteturais são diretamente relevantes para a contagem automatizada de peixes em tanques, onde oclusões, deformações corporais e condições ópticas adversas constituem os principais desafios para a detecção precisa.

3.2. Detecção, Rastreamento e Contagem

Em sistemas de contagem contínua, a detecção isolada por frame é insuficiente: é necessário rastrear indivíduos ao longo dos quadros para evitar contagens duplicadas. Diversos trabalhos abordam a integração detecção–rastreamento–contagem como pipeline unificado.

No contexto de benchmarks, Dawkins et al. (2024) contribuíram com o FishTrack23, um grande dataset de rastreamento multi-objeto subaquático integrando vídeos de diversas fontes com anotações de detecção e tracking. O dataset permite avaliar detectores (YOLOv8, ByteTrack) sob iluminação variável e comportamento coletivo, sendo fundamental para validação temporal de sistemas de contagem.

Já Lin et al. (2024) propuseram o DVE-YOLO (Detecção–Validação–Estimação), pipeline que adiciona um módulo de validação entre a detecção e a estimativa de cardume/biomassa, reduzindo falsos positivos sob turbidez, variação de iluminação e sobreposição. A abordagem demonstra desempenho favorável em cenários reais de produção.

Para a contagem de peixes por passagem em canaletas inclinadas, a combinação destes elementos — detecção robusta, rastreamento guiado por confiança e régua virtual — constitui o *pipeline* de referência, cuja estabilidade depende criticamente da qualidade do rastreador frente a quedas de desempenho do detector.

3.3. Contagem por Densidade em Cenários de Alta Ocupação

Quando a densidade de indivíduos é muito elevada (alevinos, cardumes compactos), detectores baseados em bounding boxes tendem a falhar por sobreposição e oclusão severa. Nesse contexto, abordagens por regressão de mapa de densidade oferecem alternativa robusta.

Em contrapartida, Bukas et al. (2024) conduziram uma comparação rigorosa entre oito abordagens (detecção vs. mapas de densidade) em cenário industrial RAS com 1.379 imagens anotadas, cobrindo ampla faixa de densidades, alturas de câmera (80/120 cm) e espectros de iluminação (branca/azul). Os modelos de detecção (YOLOv5m6 e Faster R-CNN) superaram os de densidade; o melhor YOLOv5m6 obteve erros médios inferiores ao padrão humano (20%) e próximos da meta de 5% para adoção em fazenda. Embora o estudo trate de camarões, a engenharia experimental — variação controlada de luz, distância e densidade, com avaliação por erro médio absoluto (MAE), erro percentual absoluto médio (MAPE) e erro percentual absoluto médio simétrico (sMAPE) — é diretamente transferível para definir metas operacionais e diretrizes de aquisição de imagens em piscicultura.

Esses resultados sugerem que, para densidades moderadas, detectores por bounding box são suficientes e até superiores, enquanto a regressão de densidade torna-se vantajosa em picos de cardume com sobreposição extrema — justificando uma estratégia de comutação adaptativa no pipeline.

3.4. Classificação de Espécies e Sensores Complementares

Quando a contagem precisa ser estratificada por espécie, métodos de classificação e arranjos sensoriais alternativos ampliam as capacidades do sistema.

No eixo de sensores complementares, Li, Z. et al. (2024) demonstraram a viabilidade de câmeras infravermelhas posicionadas acima da água em gaiolas oceânicas profundas. Com dataset de 400 imagens (2.830 peixes), o melhor arranjo (Faster R-CNN com EfficientNetB0 e FPN) atingiu AP50 de 0,85, validando monitoramento de superfície com custo inferior a USD 2.000/ano. Essa configuração acima d'água evita bioincrustação e perda de campo visual, oferecendo uma alternativa de baixa manutenção para cenários onde a câmera submersa é impraticável.

3.5. Otimização para Dispositivos de Borda e Curadoria de Dados

A implantação de sistemas de contagem diretamente no ambiente produtivo exige modelos leves, capazes de operar em hardware restrito (Jetson, Raspberry Pi), e estratégias eficientes de preparação de dados.

No âmbito da piscicultura brasileira, Cabral e Martins (2023) aplicaram YOLO/Darknet treinado com dados do laboratório do IF Goiano (Rio Verde) para acelerar contagem no empacotamento, demonstrando que a automação reduz tempo, diminui estresse dos peixes e melhora a precisão frente à contagem manual.

Quanto à curadoria de dados, Vijiyakumar, Govindasamy e Akila (2024) propuseram um pipeline que combina anotação automática com Faster R-CNN (backbone Inception v2) e rastreador DCF-CSRT para gerar e assistir anotações, reduzindo o esforço manual de rotulagem. Para sistemas de contagem em tanques, onde o custo

de anotação é um gargalo, o esquema de anotação assistida por rastreador permite ciclos mais rápidos de treino — pode-se empregar o CSRT para pré-marcar passagens em vídeos de canaletas e, em seguida, revisar antes do treino do detector.

3.6. Síntese Comparativa dos Estudos Revisados

A Tabela 2 sintetiza os principais estudos analisados nesta revisão, organizados por eixo temático. Para cada trabalho, são indicados o método central, a tarefa abordada, o conjunto de dados utilizado, a métrica principal reportada e a plataforma-alvo de implantação.

Tabela 2. Síntese comparativa dos estudos revisados sobre detecção e contagem de peixes.

Estudo	Método	Tarefa	Dataset	Métrica principal	Plat.
Aprimoramentos arquiteturais para detecção subaquática					
(Muksit et al., 2022)	YOLOv3 + SPP	Detecção	DeepFish, OzFish	mAP > YOLOv3	GPU
(Yi; Han; Lai, 2025)	YOLOv8n + DCN + DPSE + Wise-IOU	Detecção	Próprio (denso)	mAP50-95 +7,7%	GPU

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/visao-computacional-para-contagem-automatizada-de-peixes-em-piscicultura-uma-revisao-narrativa?noblockage>

Fonte: elaborada pelo autor (2026).

4. CONCLUSÃO

4.1. Síntese dos Achados

A revisão bibliográfica orientada por buscas mostra a presença recorrente de detectores baseados em aprendizado profundo, sobretudo da família YOLO e suas derivações (Muksit et al., 2022; Jiang, X. et al., 2025; Yi; Han; Lai, 2025; Jiang, L. et al., 2024; Vijayalakshmi; Sasithradevi, 2025), em propostas de contagem automatizada de peixes. Nos estudos selecionados, três linhas de avanço aparecem com frequência:

- aprimoramentos arquiteturais (atenção multi-escala, fusão ponderada, convoluções deformáveis, upsampling guiado por conteúdo) que elevam a sensibilidade a alvos pequenos e parcialmente visíveis;
- desenho de pipelines completos de detecção e rastreamento com régua/linha virtual para evitar dupla contagem e reduzir ID-switch, inclusive com estratégias guiadas por confiança (Mandel et al., 2023) e validações em benchmarks dedicados (Dawkins et al., 2024); e
- otimização para borda, com modelos leves (Jiang, H. et al., 2025; Jiang, L. et al., 2024) que mantêm FPS alto em Jetson/Raspberry, possibilitando monitoramento contínuo diretamente no tanque.

Em cenários de superlotação e sobreposição intensa, nos quais bounding boxes perdem eficácia, abordagens por mapa de densidade (Li, X. et al., 2024) surgem como complemento valioso, reduzindo a dependência de grandes bases anotadas e oferecendo

estimativas estáveis de fluxo/biomassa. A literatura também indica que o multissensoriamento (óptico e sonar DIDSON; câmeras infravermelhas acima d'água) aumenta a robustez quando a imagem degrada (Kandimalla et al., 2022; Li, Z. et al., 2024), enquanto métodos de classificação consciente de desbalanceamento (Alaba et al., 2022) viabilizam contagem estratificada por espécie sem penalizar classes raras, útil para manejo, rastreabilidade e conformidade ambiental.

No plano metodológico, estudos aplicados em fazendas, ainda que com camarões (Bukas et al., 2024), evidenciam que detectores modernos já alcançam erros médios próximos de metas operacionais de adoção ($\leq 5\%$), com ganhos práticos ao padronizar aquisição (altura de câmera, espectro de iluminação) e métricas de avaliação (MAE/MAPE/sMAPE para contagem; mAP/HOTA/MOTA para detecção-rastreamento). Em paralelo, surgem infraestruturas para seleção de modelos guiada pelo domínio (p. ex., benchmarks unificados e seleção assistida por CLIP), apontando um caminho mais sistemático para adequar o detector ao habitat e às condições específicas.

4.2. Abordagens de Integração Identificadas

Do ponto de vista de aplicação em piscicultura, os trabalhos selecionados permitem identificar componentes que podem ser combinados conforme o problema e os recursos disponíveis:

1. um detector leve em borda para triagem contínua e disparo de eventos;
2. um detector robusto/atento (ou fusões com deformáveis) em servidor para quadros difíceis;

3. tracking por trilhas com linha de contagem e uso explícito da confiança para estabilizar decisões; e
4. comutação para regressão de densidade (Li, X. et al., 2024) em picos de cardume.

Esses componentes não formam uma arquitetura universal. Classificação por espécie, fusão de sensores, aprendizado ativo, anotação assistida, aumento de dados e adaptação de domínio são alternativas cuja utilidade precisa ser verificada em cada ambiente. No processo desta dissertação, foram priorizados aquisição controlada, detecção, rastreamento e linha virtual, sem implementar toda a combinação descrita na literatura.

4.3. Lacunas e Direções Futuras

Persistem lacunas relevantes: padronização de benchmarks específicos para tanques de piscicultura (com métricas de contagem fim-a-fim), quantificação de incerteza e calibração de probabilidades para decisões críticas (manejo/arraçoamento), avaliação de custo total de propriedade (energia, manutenção de sensores, bioincrustação) e diretrizes abertas para privacidade, bem-estar animal e sustentabilidade.

Em conjunto, os estudos fornecem evidências de viabilidade técnica em cenários específicos e indicam benefícios potenciais para manejo, rastreabilidade e tomada de decisão. Entretanto, a diversidade de espécies, ambientes, conjuntos de dados e métricas impede concluir, apenas a partir desta revisão, pela viabilidade econômica ou pela prontidão para implantação confiável em escala. As abordagens identificadas funcionam como referências para

projeto e avaliação, que precisam ser novamente verificadas no domínio de aplicação.

REFERÊNCIAS BIBLIOGRÁFICAS

ALABA, S. Y. et al. Class-aware fish species recognition using deep learning for an imbalanced dataset. *Sensors*, v. 22, n. 21, p. 8268, 2022. DOI: 10.3390/s22218268.

BUKAS, C. et al. Robust deep learning based shrimp counting in an industrial farm setting. *Journal of Cleaner Production*, v. 468, p. 143024, 2024. DOI: 10.1016/j.jclepro.2024.143024.

CABRAL, I. T.; MARTINS, Y. S. Detecção de peixes utilizando redes neurais convolucionais. Rio Verde: [s. n.], 2023. Trabalho de Conclusão de Curso.

DAWKINS, M. et al. FishTrack23: An ensemble underwater dataset for multi-object tracking. In: *IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. [S. l.: s. n.], 2024.

JIANG, Hanyu et al. Mobile-YOLO: A Lightweight Object Detection Algorithm for Four Categories of Aquatic Organisms. *Fishes*, v. 10, n. 7, p. 348, 2025. DOI: 10.3390/fishes10070348.

JIANG, Linhua et al. Improved YOLOv7-TINY Network for Sea Bream Detection. *Journal of Computing and Electronic Information Management*, 2024. DOI: 10.54097/c6kqnn36.

JIANG, X. et al. EPBC-YOLOv8: An efficient and accurate improved YOLOv8 underwater detector based on an attention mechanism. *arXiv preprint*, 2025. arXiv:2502.05788.

KANDIMALLA, V. et al. Automated detection, classification and counting of fish in fish passages with deep learning. *Frontiers in Marine Science*, v. 8, 2022. DOI: 10.3389/fmars.2021.823173.

LI, H. et al. Robust detection of farmed fish by fusing YOLOv5 with DCM and ATM. *Aquacultural Engineering*, v. 99, p. 102301, 2022. DOI: 10.1016/j.aquaeng.2022.102301.

LI, Ximing et al. LDNet: High Accuracy Fish Counting Framework using Limited Training Samples with Density Map Generation Network. *Journal of King Saud University – Computer and Information Sciences*, v. 36, n. 7, p. 102143, 2024. DOI: 10.1016/j.jksuci.2024.102143.

LI, Z. et al. Deep learning-based fish detection using above-water infrared camera for deep-sea aquaculture: a comparison study. *Sensors*, v. 24, n. 8, p. 2430, 2024. DOI: 10.3390/s24082430.

LIN, F. et al. Machine vision approach for monitoring and quantifying fish school using DVE-YOLO. *Ecological Indicators*, 2024. DOI: 10.1016/j.ecolind.2024.112769.

LIU, Y. et al. Research on underwater object detection method based on deep learning. *International Journal of New Developments in Engineering and Society*, v. 9, n. 2, p. 78–83, 2025. DOI: 10.25236/IJNDES.2025.090213.

LOULIDI, A. et al. Automatic fish detection from different marine environments video using deep learning. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. [S. l.: s. n.], 2022. XLVI-4/W3-2021. DOI: 10.5194/isprs-archives-XLVI-4-W3-2021-191-2022.

MANDEL, T. et al. Detection confidence driven multi-object tracking to recover reliable tracks from unreliable detections. *Pattern Recognition*, v. 135, p. 109107, 2023. DOI: 10.1016/j.patcog.2022.109107.

MUKSIT, A. A. et al. YOLO-Fish: A robust fish detection model to detect fish in realistic underwater environment. *Ecological Informatics*, v. 72, p. 101847, 2022. DOI: 10.1016/j.ecoinf.2022.101847.

RATHI, D.; JAIN, S.; INDU, S. Underwater fish species classification using convolutional neural network and deep learning. In: *IEEE International Conference*. [S. l.: s. n.], 2017.

VIJAYALAKSHMI, M.; SASITHRADEVI, A. AquaYOLO: Advanced YOLO-based Fish Detection for Optimized Aquaculture Pond Monitoring. *Scientific Reports*, 2025. DOI: 10.1038/s41598-025-89611-y.

VIJAYAKUMAR, K.; GOVINDASAMY, V.; AKILA, V. An effective object detection and tracking using automated image annotation with Inception-based Faster R-CNN model. *International Journal of Cognitive Computing in Engineering*, v. 5, p. 343–356, 2024. DOI: 10.1016/j.ijcce.2024.07.006.

XU, J. et al. IMC-YOLO: a detection model for assisted razor clam fishing in the mudflat environment. *PeerJ Computer Science*, v. 11, e2614, 2025. DOI: 10.7717/peerj-cs.2614.

YI, J.; HAN, W.; LAI, F. YOLOv8n-DDSW: An efficient fish target detection network for dense underwater scenes. *PeerJ Computer Science*, v. 11, e2798, 2025. DOI: 10.7717/peerj-cs.2798.

¹ Mestrando no Programa de Pós-Graduação em Engenharia Aplicada e Sustentabilidade, Instituto Federal Goiano – Campus Rio Verde. Servidor do IFG – Campus Itumbiara (Tecnologia da Informação).

² Orientador. Prof. Dr., Programa de Pós-Graduação em Engenharia Aplicada e Sustentabilidade, Instituto Federal Goiano – Campus Rio Verde.

³ Coorientador. Prof. Dr., Programa de Pós-Graduação em Engenharia Aplicada e Sustentabilidade, Instituto Federal Goiano – Campus Rio Verde. E-mail: [acesse o artigo original para visualizar o e-mail](#).