

Prova de conceito para reconhecimento de peixes em piscicultura utilizando YOLO

Eduardo Mizael Clemente^{*†}, Leonardo Garcia Marques^{*‡}, Gesmar de Paula Santo Júnior^{*‡}, Geraldo Andrade de Oliveira[†]

^{*}Instituto Federal de Goiás, Itumbiara, Goiás, 75524-245

{eduardo.mizael, leonardo.garcia, gesmar.junior}@ifg.edu.br

[†]Instituto Federal Goiano, Rio Verde, Goiás 75901-970

gerandr@gmail.com

[‡]Universidade Federal de Uberlândia, 38408-902

Abstract—This paper reports a proof of concept using computer vision to detect fish in aquaculture videos. A small set of lambari videos was sampled into frames and manually labeled with Label Studio. A YOLO11 detector was trained on a personal computer and achieved promising results (precision 0.86; recall 0.82; mAP@50 0.81). Although the first video application showed false positives, software-side improvements—ByteTrack-based tracking, dynamic thresholds, polygonal ROI, and geometric filters—stabilized detections and reduced spurious results. The findings indicate feasibility and outline avenues for scaling.

Keywords—computer vision; aquaculture; YOLO; fish counting; object detection.

Resumo ou Resumen— Este artigo apresenta uma prova de conceito do uso de visão computacional para detecção de peixes em piscicultura. Um conjunto reduzido de vídeos de lambaris foi convertido em frames e rotulado manualmente no Label Studio. Um detector YOLO11 foi treinado em computador pessoal e obteve métricas promissoras (precisão 0,86; recall 0,82; mAP@50 0,81). Apesar de falsos positivos na aplicação inicial em vídeo, melhorias na camada de software—tracking com ByteTrack, limiares dinâmicos, ROI poligonal e filtros geométricos—tornaram as detecções mais estáveis e confiáveis. Os resultados evidenciam viabilidade e sugerem caminhos para expansão.

Palavras-chave—visão computacional; piscicultura; YOLO; contagem de peixes; detecção de objetos.

I. INTRODUÇÃO

A contagem de peixes é central no manejo aquícola, impactando planejamento alimentar, sanidade e produtividade. Procedimentos manuais são morosos e suscetíveis a erro, além de potencialmente estressantes aos organismos. Soluções baseadas em visão computacional oferecem a possibilidade de automatizar este processo de forma não invasiva. Dentre as técnicas de visão computacional, o aprendizado profundo permite uma automação não invasiva, com a biblioteca YOLO (You Only Look Once) destacando-se pela detecção em tempo real e boa relação custo-desempenho [1], [2], sendo promissores para aplicação em cenários de aquicultura.

Este trabalho conduz um experimento preliminar para avaliar o YOLO11 na detecção de peixes em vídeos simples, discutindo desempenho de treinamento e o papel de adaptações na camada de aplicação para uso prático em tempo real.

II. MATERIAIS E MÉTODOS

A. Coleta e anotação de dados

Foram gravados vídeos curtos de lambaris (*Astyanax* spp.) em ambiente controlado, sobre fundo claro, com câmera de celular (720×1080 px). Frames foram extraídos e anotados manualmente no Label Studio, definindo caixas delimitadoras (bounding boxes) sobre cada peixe [3].

B. Modelo e treinameto

Utilizou-se YOLO11 na configuração padrão [2]. O dataset foi particionado em treino e validação, em proporções aproximadas de respectivamente 80% e 20%. O treinamento conduzido por 100 épocas, com monitoramento das métricas de precisão, recall e mAP.

As curvas de evolução (Fig. 1) e os gráficos de precisão–recall (Fig. 2) e F1-score (Fig. 3) foram utilizados para análise de aprendizado e overfitting.




Fig. 1. Evolução das métricas de treinamento.

C. Aplicação e pós-processamento

Para uso em vídeo, implementou-se um aplicativo que:

- Integra tracking ByteTrack para associação temporal de detecções dos peixes;
- Adota limiar duplo de confiança e confirmação temporal de IDs;
- Permite ROI poligonal interativa para restringir o campo útil;
- Aplica filtros geométricos opcionais (área/aspecto) e oferece ajustes em tempo real.

A primeira versão, com detecções brutas, resultou em muitos falsos positivos; a inclusão dos mecanismos acima reduziu ruídos e estabilizou as trilhas..




Fig. 2. Curva de Precisão x Recall do modelo.




Fig. 3. Evolução do F1-score ao longo do treinamento.

- **mAP@50-95: 0,41**

Tais valores, obtidos com dataset limitado, indicam aprendizado de padrões relevantes, com margem para ganho de generalização via mais dados e diversificação de cenários (iluminação, turvação, espécies). A matriz de confusão normalizada (Fig. 4) aponta baixa dispersão em falsos positivos/negativos. Exemplos visuais da detecção dos peixes são ilustrados na Fig. 5.

B. Papel da camada de aplicação

Na aplicação inicial em vídeo, falsos positivos afetavam a experiência. A combinação de tracking, limiares dinâmicos, ROI e filtros geométricos mitigou o problema, estabilizando IDs e evitando contagens espúrias. O resultado reforça que, além do score bruto do detector, o design do pipeline de pós-processamento influencia diretamente a confiabilidade percebida em campo.




Fig. 4. Matriz de confusão normalizada.

III. RESULTADOS E DISCUSSÃO

A. Desempenho do modelo

Após 100 épocas, os indicadores no conjunto de validação foram:

- **Precisão: 0,86**
- **Recall: 0,82**
- **mAP@50: 0,81**




Fig. 5. Exemplo de predição do YOLO11 em frame de validação.

REFERÊNCIAS

- [1] A. Bochkovskiy, C. Wang, and H. M. Liao, “Yolov4: Optimal speed and accuracy of object detection,” CoRR, vol. abs/2004.10934, 2020.
[Online]. Disponível em: <https://arxiv.org/abs/2004.10934>.
- [2] Ultralytics. (2025) Documentação ultralytics yolo. Ultralytics. Disponível em: <https://docs.ultralytics.com/pt/>.
- [3] M. Tkachenko, M. Malyuk, A. Holmanyuk, and N. Liubimov, “Label Studio: Data labeling software,” 2020–2022, open source software available from <https://github.com/heartexlabs/label-studio>.

IV. CONCLUSÃO

A prova de conceito confirmou a viabilidade do YOLO11 na detecção de peixes em vídeos de piscicultura com recursos modestos, alcançando métricas promissoras. Mostrou-se também que aprimoramentos no software reduzem falsos positivos e tornam o sistema mais robusto para uso em tempo real.

Os trabalhos futuros incluem: expansão do dataset com diferentes espécies e condições ambientais; validações mais rigorosas; e um estudo de implantação em hardware embarcado para operação contínua.

AGRADECIMENTOS

Agradecemos ao Instituto Federal de Goiás – Câmpus Itumbiara, pelo apoio institucional, infraestrutura e incentivo; ao Instituto Federal Goiano, pela troca de conhecimentos ao longo do desenvolvimento; e à Universidade Federal de Uberlândia, pelo acesso a recursos bibliográficos e ambientes de pesquisa.