

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO –
CAMPUS RIO VERDE**

MÉTODOS DE ROTULAÇÃO DE IMAGEM PARA CONTAGEM DE PEIXES

GABRIELA ALMEIDA MARQUES

**Rio Verde - Go
2025**

GABRIELA ALMEIDA MARQUES

MÉTODOS DE ROTULAÇÃO DE IMAGEM PARA CONTAGEM DE PEIXES

Trabalho de Conclusão de Curso apresentado
ao curso de Zootecnia do Instituto Federal
Goiano, Campus Rio Verde como parte da
exigência para obtenção do título de bacharel.

Orientador: Prof. Dr. Adriano C. Costa

**Rio Verde - Go
2025**

**Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema Integrado de Bibliotecas do IF Goiano - SIBi**

M357m Marques, Gabriela Almeida
Métodos de rotulação de imagem para contagem de peixes /
Gabriela Almeida Marques. Rio Verde - GO 2025.

34f. il.

Orientador: Prof. Dr. Doutor Adriano Carvalho Costa.
Tcc (Bacharel) - Instituto Federal Goiano, curso de 0220184 -
Bacharelado em Zootecnia - Integral - Rio Verde (Campus Rio
Verde).

1. Inteligência artificial. 2. Visão computacional. 3. YOLOv8.. I.
Título.

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano, a disponibilizar gratuitamente o documento no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| ☐ Tese | ☐ Artigo Científico |
| ☐ Dissertação | ☐ Capítulo de Livro |
| ☐ Monografia – Especialização | ☐ Livro |
| ☒ TCC - Graduação | ☐ Trabalho Apresentado em Evento |
| ☐ Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Gabriela Almeida Marques

Matrícula: 2021102201840238

Título do Trabalho: Métodos de rotulação de imagem para contagem de peixes.

Restrições de Acesso ao Documento

Documento confidencial: ☒ Não ☐ Sim, justifique: _____

Informe a data que poderá ser disponibilizado no RIIF Goiano: __/__/__

O documento está sujeito a registro de patente? ☐ Sim ☒ Não

O documento pode vir a ser publicado como livro? ☐ Sim ☒ Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

1. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
2. obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
3. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Documento assinado digitalmente
 **GABRIELA ALMEIDA MARQUES**
Data: 08/07/2025 09:06:32-0300
Verifique em <https://validar.iti.gov.br>

Rio Verde, 10/07/2025.
Local Data

Assinatura do Autor e/ou Detentor dos Direitos Autorais

Ciente e de acordo:



Documento assinado digitalmente

ADRIANO CARVALHO COSTA

Data: 08/07/2025 09:19:25-0300

Verifique em <https://validar.iti.gov.br>

Assinatura do(a) orientador(a)

Regulamento de Trabalho de Curso (TC) – IF Goiano - Campus Rio Verde

ANEXO V - ATA DE DEFESA DE TRABALHO DE CURSO

Aos vinte e sete dias do mês de junho de dois mil e vinte e cinco, às 16 horas, reuniu-se virtualmente (meet.google.com/pen-obds-pvg) a Banca Examinadora composta por: Adriano Carvalho Costa (orientador), Mestre em Zootecnia Alene Santos Souza (membro externo e Coorientadora), Alessa Pereira Diniz Araujo (membro interno), Elias Marques de Oliveira (membro interno) e Vitória de Vasconcelos Kretschmer (membro interno) para examinar o Trabalho de Curso (TC) intitulado “MÉTODOS DE ROTULAÇÃO DE IMAGEM PARA CONTAGEM DE PEIXES ” de Gabriela Almeida Marques, estudante do curso de Bacharelado em Zootecnia do IF Goiano – Campus Rio Verde, sob Matrícula nº 2021102201840238. A palavra foi concedida ao estudante para a apresentação oral do TC, em seguida houve arguição do candidato pelos membros da Banca Examinadora. Após tal etapa, a Banca Examinadora decidiu pela APROVAÇÃO do estudante. Ao final da sessão pública de defesa foi lavrada a presente ata, que, após apresentação da versão corrigida do TC, foi assinada pelos membros da Banca Examinadora e Mediador de TC.

Rio Verde, 27 de junho de 2025.

Adriano Carvalho Costa

Orientador e Membro da Banca Examinadora

Alene Santos Souza

Membro da Banca Examinadora e Coorientadora

Alessa Pereira Diniz Araujo

Membro da Banca Examinadora

Elias Marques de Oliveira

Membro da Banca Examinadora

Vitoria de Vasconcelos Kretschmer

Membro da Banca Examinadora

Documento assinado eletronicamente por:

- **Adriano Carvalho Costa, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 27/06/2025 17:28:33.
- **Vitória de Vasconcelos Kretschmer, 2024202310240006 - Discente**, em 27/06/2025 17:31:43.
- **Elias Marques de Oliveira, 2024102310240006 - Discente**, em 27/06/2025 17:31:54.
- **Alessa Pereira Diniz Araujo, 2024102310240010 - Discente**, em 27/06/2025 17:32:13.
- **Marco Antonio Pereira da Silva, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 27/06/2025 17:35:24.

Este documento foi emitido pelo SUAP em 27/06/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 720869

Código de Autenticação: 5923458442



AGRADECIMENTOS

A minha família por todo auxílio e incentivo durante a minha caminhada na graduação;

Ao meu orientador professor Adriano Carvalho Costa por todos os ensinamentos partilhados;

Aos meus amigos da graduação pela amizade e companheirismo;

A Mestre em Zootecnia, Alene Santos Souza, por todo auxílio no desenvolvimento desse trabalho;

A banca examinadora pelas sugestões e melhorias no trabalho;

Ao Instituto Federal Goiano – Campus Rio Verde, pela oportunidade e amparo de durante a graduação;

A todos meus colegas de curso pelos momentos vividos e que de alguma forma contribuíram em minha trajetória;

Aos professores das Zootecnia pelos ensinamentos que colaboraram em minha formação profissional;

E àqueles que de alguma forma estiveram presente durante minha jornada.

RESUMO

A contagem de alevinos na piscicultura é uma tarefa crucial para a gestão da produção, e a automação via Inteligência Artificial surge como uma alternativa promissora aos métodos tradicionais. Este trabalho teve como objetivo avaliar o impacto de dois diferentes métodos de rotulação de imagens — polígonos e caixas delimitadoras — no desempenho do algoritmo de detecção YOLOv8 para a contagem de alevinos de tilápia-do-Nilo (*Oreochromis niloticus*). Para isso, foram utilizadas aproximadamente 5.000 imagens capturadas em ambiente controlado, com densidades que variavam de 10 a 50 peixes por recipiente. Os resultados demonstraram uma clara superioridade do método de rotulação por polígonos, que manteve a precisão e o recall acima de 97% em todas as densidades avaliadas, com uma média de precisão média (mAP) de até 99%. Em contrapartida, o método com caixas delimitadoras apresentou uma queda acentuada de desempenho em altas densidades, com o recall caindo para 80,78% no cenário com 40 peixes. Conclui-se que, para a contagem automática de alevinos em condições de sobreposição, a anotação por polígonos é fundamental para garantir a robustez e a alta precisão do modelo, sendo o método mais indicado para aplicações que exigem resultados confiáveis.

Palavras-chave: Inteligência artificial; visão computacional; YOLOv8.

ABSTRACT

Fry counting in aquaculture is a crucial task for production management, and automation via Artificial Intelligence emerges as a promising alternative to traditional methods. This study aimed to evaluate the impact of two different image labeling methods—polygons and bounding boxes—on the performance of the YOLOv8 detection algorithm for counting Nile tilapia (*Oreochromis niloticus*) fry. For this purpose, approximately 5,000 images were captured in a controlled environment, with densities ranging from 10 to 50 fish per container. The results showed a clear superiority of the polygon labeling method, which maintained precision and recall above 97% across all evaluated densities, with a mean Average Precision (mAP) of up to 99%. In contrast, the bounding box method showed a sharp decline in performance at high densities, with the recall dropping to 80.78% in the 40-fish scenario. It is concluded that for the automatic counting of fry under overlapping conditions, polygon annotation is essential to ensure the robustness and high precision of the model, being the most suitable method for applications that require reliable results.

Keywords: Artificial intelligence; computer vision; YOLOv8

SUMÁRIO

1.	INTRODUÇÃO	20
2.	REVISÃO BIBLIOGRÁFICA.....	21
2.1.	Origem da tilápia	21
2.2.	Características e dados Zootécnicos	22
2.3.	Produção Nacional e Internacional.....	23
2.4.	Contagem de peixes.....	24
2.5.	Inteligência artificial na contagem de peixes.....	26
2.6.	Diferentes métodos de rotulação de imagens e como afetam o desempenho dos modelos de redes neurais	27
2.6.1.	<i>Métodos de Rotulação de Imagens e Impactos no Desempenho</i>	<i>27</i>
2.6.2.	<i>Tipos de Anotação: A Relação entre Precisão e Esforço</i>	<i>27</i>
2.6.3.	<i>Qualidade da Rotulação e o Desafio do Ruído nos Rótulos.....</i>	<i>28</i>
2.6.4.	<i>Estratégias para Otimizar o Processo de Rotulação.....</i>	<i>28</i>
3.	MATERIAIS E METÓDOS	29
3.1.	Rotulação do conjunto de imagens	30
3.2.	Rede convolucional e treinamento das bases de dados	32
3.3.	Métricas de avaliação.....	33
4.	RESULTADOS	34
4.1	Análise do gráfico de treinamento e validação para 10, 20, 30, 40 e 50 peixes marcação polígono	36
5.	DISCUSSÃO	39
5.	CONCLUSÃO	41
	REFERÊNCIAS.....	42

1. INTRODUÇÃO

Na aquicultura, realizar a contagem de peixes é uma das atividades de grande relevância. Esse processo nos permite acompanhar o crescimento, otimizar alimentação e planejar a biomassa adequadamente, fatores que influenciam nos resultados econômicos de quaisquer cultivos (Barros et al., 2025). No contexto do Brasil, a importância dessa atividade possui maior evidência ao focarmos na Tilápia do Nilo (*Oreochromis niloticus*). Em 2023, o cultivo dessa espécie representou 65,3% de toda a produção de peixes cultivados no país (PEIXEBR, 2024). Dessa forma, otimizar a contagem de alevinos que corresponde a fase juvenil da tilápia é uma necessidade estratégica para um dos setores mais importantes do agronegócio brasileiro.

Nesse contexto, os produtores historicamente recorrem a métodos de contagem tradicionais, que se mostram problemáticos. A contagem manual, por exemplo, além de ser um processo lento e suscetível a erros, causa um estresse nos animais, que pode ocasionar infecções secundárias e aumentar as taxas de mortalidade (Rehman et al., 2017). Já as estimativas por amostragem, que se baseiam em peso ou volume, frequentemente carecem de precisão devido às variações de tamanho existentes no lote (Li et al., 2021). Como alternativa a esses métodos, a Inteligência Artificial (IA) tem se destacado por permitir a automação da contagem, oferecendo um processo mais ágil, preciso e com menor estresse para os animais (Barros et al., 2025).

Os trabalhos que utilizam I.A para contagem de peixes são baseados, em sua maioria, em técnicas de visão computacional (Gonçalves et al., 2022). Nesses estudos são usadas Redes Neurais Convolucionais (RCNs), que são algoritmos de aprendizado profundo capazes de analisar imagens ou vídeos e aprender a detectar e reconhecer objetos de interesse. A rede é "treinada" com um grande volume de fotos, aprendendo as características visuais dos peixes para, depois, conseguir identificá-los e contá-los automaticamente em novas imagens (Santos, 2024; Li; Wang; Zhang, 2021).

Assim como o desempenho de uma RCN é dependente da qualidade dos dados de treinamento (Ranjan; Tsukuda; Good, 2023). Para que a máquina aprenda o que é um peixe, é fundamental que cada animal seja previamente marcado nas imagens de exemplo, em um processo chamado de rotulação (Saberioon et al., 2017). Essa etapa é um dos principais desafios, pois é trabalhosa e exige anotações exatas das regiões de interesse. O método de rotulação utilizado — seja por meio de caixas delimitadoras (retângulos ao redor do objeto) ou de polígonos (contornos precisos) — impacta diretamente a performance final do modelo.

Estudos recentes indicam que rotulações mais detalhadas apesar de mais trabalhosas tendem a produzir redes mais robustas e precisas (GARCIA et al., 2020; SÁNCHEZ et al., 2022).

Dito isso, apesar de se reconhecer a importância da rotulação, percebe-se que, embora existam estudos individuais que testam diferentes abordagens, há uma lacuna na literatura que consolide e compare esses achados de forma sistemática principalmente em organismos aquáticos. Faltam trabalhos que ofereçam uma visão panorâmica sobre o tema, sintetizando as vantagens, desvantagens e o impacto de cada método de rotulação.

Portanto o presente trabalho foi realizado com o objetivo de avaliar os diferentes métodos de rotulação de imagens, como caixas delimitadoras e polígonos, afetam o desempenho do algoritmo de detecção YOLOv8 na contagem de peixes.

2. REVISÃO BIBLIOGRÁFICA

2.1. ORIGEM DA TILÁPIA

A tilápia do Nilo (*Oreochromis niloticus*), é um peixe de água doce cultivado no mundo todo com relevância econômica, sendo inserida em mais de 100 países, tornando-se uma das espécies mais produzidas globalmente. Originária de rios e lagos da África e do Oriente Médio essa espécie apresenta facilidade de criação, aceitação do mercado, rusticidade e valor de mercado. (Behera *et al.* 2018).

Em 1981, foram introduzidas oficialmente no Brasil as tilápias vermelhas, cuja pigmentação avermelhada é resultante de uma mutação genética em populações da espécie *Oreochromis mossambicus* (tilápia de Moçambique). Em questões de relevância econômica, a tilápia GIFT (Genetically Improved Farmed Tilapia) é a linhagem mais cultivada. No Brasil, em 2005, foi realizada a introdução da linhagem GIFT através de parcerias entre instituições públicas de pesquisa, e centros internacionais, como o WorldFish Center (Santos *et al.*, 2019; Bentsen *et al.*, 1998).

O desenvolvimento das linhagens GIFT, foi consolidada através do cruzamento de oito linhagens diferentes, sendo quatro nativas da África e as demais da Ásia. O objetivo inicial do trabalho foi formar um banco de germoplasma dessa espécie na África e Ásia para o estabelecimento de uma população base (Oliveira *et al.* 2007; Bentsen *et al.*, 1998). Esse processo resultou em uma linhagem com alto potencial zootécnico, que passou por ciclos sucessivos de seleção genética voltados à produtividade e resistência a doenças, tornando-se referência global na aquicultura (Gonçalves *et al.*, 2024).

O cultivo da tilápia é realizado em sistemas de criação extensivos, semi-intensivos e intensivos, sendo o sistema semi-intensivo representado pelo cultivo em viveiros escavados.

Outro modelo é sistema de tanques-rede (gaiolas), que tem sido bastante utilizado para a produção de tilápia, no qual consiste na utilização de corpos d'água para instalação dos tanques feitos de estrutura de tela onde os peixes ficam confinados e são alimentados com dieta controlada (Filho & Schuler, 2017).

2.2. CARACTERÍSTICAS E DADOS ZOOTÉCNICOS

A tilápia se destaca como uma das espécies mais cultivadas na aquicultura, principalmente por apresentar características zootécnicas que a tornam altamente vantajosa para os criadores. Gallardo-Collí *et al.* (2019), revelaram que a tilápia-do-Nilo, *Oreochromis niloticus*, pode ser cultivada em sistemas intensivos, utilizando água reciclada, sem apresentar efeitos adversos na sobrevivência, produtividade e desempenho de crescimento. Fato este, que reforçam a viabilidade e o potencial na aquicultura ocasionado por apresentar resistência e boas características de adaptação a sistemas de criação (Filho & Schuler, 2017).

Dentre as características que levaram a tilápia a ser uma espécie de importância comercial, destaca-se, a facilidade de reprodução e obtenção dos alevinos, reversão sexual, aceitação dos diversos tipos de alimentação principalmente das dietas formuladas, grande habilidade de aproveitar alimentos naturais em viveiros, excelente conversão alimentar, bom crescimento em sistema intensivo e rápido desempenho produtivo. Com relação aos fatores sensoriais de sua carne que levam a boa aceitação pelo mercado consumidor, estão o sabor e odor suave, textura firme e coloração branca, além da ausência de espinhos em “Y” facilitando a filetagem (Moreti & Júnior, 2020).

Complementando sua notável adaptabilidade, a tilápia-do-Nilo prospera em uma faixa de temperatura ideal entre 25 °C e 32 °C, sendo este um fator crítico para seu metabolismo e crescimento. A sua rusticidade também se reflete na tolerância a diversos parâmetros de qualidade da água. O oxigênio dissolvido (OD), por exemplo, deve ser mantido preferencialmente acima de 4 mg/L para garantir um bom desenvolvimento, embora a espécie consiga sobreviver em níveis mais baixos. Além disso, tolera uma ampla faixa de pH, com o ideal situando-se entre 6.5 e 8.0. Quanto aos compostos nitrogenados, é crucial manter os níveis de amônia tóxica (NH₃) abaixo de 0,02 mg/L e os de nitrito idealmente inferiores a 0,5 mg/L. A espécie é considerada eurialina, adaptando-se a ambientes com salinidade de até 18 g/L, embora seu cultivo principal seja em água doce. Essa resiliência ambiental é acompanhada por uma alta resistência a doenças, uma característica que é constantemente aprimorada por meio de programas de melhoramento genético, como o que desenvolveu a linhagem GIFT.



Figura 1: Exemplar de *Oreochromis niloticus*. Fonte: Portal embrapa (2015).

2.3. PRODUÇÃO NACIONAL E INTERNACIONAL

O peixe mais produzido no Brasil é a tilápia segundo ministério da pesca e aquicultura. Em 2023, sua produção correspondeu a 67,5% do total de espécies produzidas, e o estado do Paraná lidera a maior produção e expansão da industrialização da tilápia no país, com mais de 34% do volume total, seguido por São Paulo, Minas Gerais, Santa Catarina e Mato Grosso (CARNEIRO *et al.*, 2022).

Segundo a Peixe br, que valoriza, fomenta e defende a cadeia da produção de peixes cultivados no Brasil, que em 2023 atingiu 887.029 toneladas, com receita de cerca de R\$ 9 bilhões. A piscicultura gera cerca de 3 milhões de empregos diretos e indiretos. O Brasil é o quarto maior produtor mundial de tilápia, espécie que representa 65% da produção do país (Peixe, BR, 2023).

A tilapicultura tem sido reconhecida como importante atividade agroindustrial, capaz de gerar grande retorno financeiro para os produtores. Segundo a edição de The State of World Fisheries and Aquaculture (2024), a produção global de pesca e aquicultura em 2022 subiu para 223,2 milhões de toneladas, um aumento de 4,4% em relação ao ano de 2020. A produção compreendeu 185,4 milhões de toneladas de animais aquáticos e 37,8 milhões de toneladas de algas.

O Brasil produziu 887.029 toneladas de peixes de cultivo em 2023, com crescimento de 3,1% sobre o resultado do ano anterior (860.355 toneladas), aponta levantamento exclusivo da Associação Brasileira da Piscicultura (Peixe BR), sendo a tilápia com 579.080 toneladas e 65,3% do total. Além das exportações que contribuíram com uma receita de US\$ 24,7 milhões.

Em 2023, a China exportou um total de cerca de 110.000 toneladas de tilápia inteira, um aumento de 47,4% em relação às 74.800 toneladas em 2022 (Globefish. 2024). Já a Indonésia, como o segundo maior produtor mundial de tilápia depois da China, mostra uma

grande contribuição para a oferta global, com a produção atingindo 1,44 milhão de toneladas até 2023. A maior parte dessa produção é para consumo doméstico, mas as exportações de tilápia da Indonésia também estão registrando números notáveis.

Em contrapartida o Egito é o maior produtor de tilápia da África, respondendo por 71% da produção de tilápia do continente e classificando-se como o terceiro maior produtor global de tilápia, depois da China e da Indonésia (Aquaculture, 2024). A produção egípcia de tilápia foi estimada em 1,1 milhão de toneladas, representando um crescimento de 6,2% em relação ao ano anterior (2022). Esse aumento reflete uma recuperação após um período de estagnação observado desde 2020, o crescimento previsto na produção de tilápia se deve em parte à estratégia do país de implementar políticas favoráveis ao mercado.

Além disso, conforme o decorrer dos anos a produção dessa espécie tem evoluído rapidamente, impulsionada por avanços genéticos, tecnológicos e de manejo, com objetivo de maior produtividade em diferentes ambientes, máxima produção com sustentabilidade (Arumugam *et al* 2023). A China se destaca como maior produtor e exportador de tilápias do mundo, contribuindo com mais de 60% das exportações globais de tilápia e exportando para cerca de 80 países ou regiões (Wang H *et al.*2014).

2.4. CONTAGEM DE PEIXES

A contagem de alevinos é uma tarefa importante na indústria da aquicultura, parte essencial da comercialização, pois pode fornecer orientação sobre como avaliar a taxa de sobrevivência, regular a densidade de reprodução, monitorar as vendas e padronização (Zhang *et al.* 2022). Portanto, o método de contagem utilizado deve ser eficiente e preciso para desenvolvimento da piscicultura.

Em geral, os métodos de contagem de alevinos incluem contagem manual, realizando assim uma média aproximada, porém alguns sistemas aquícolas mais tecnificados já estão implantando processos de contagem com mecanização ou até mesmo com IA. Os métodos de contagem são:

Tabela 1: Métodos de Contagem de Alevinos

MÉTODO	DESCRIÇÃO	FONTE
Contagem manual	Realizada a contagem de um por um, transferindo os animais de um container para outro. Este método tem como desvantagem a velocidade e está sujeito a erros humanos, já que é uma atividade monótona e repetitiva consome tempo, trabalho intensivo e é cara.	Salazar <i>et al.</i> , 2015
Por volume seco	É um método que se constitui quando há um local onde os alevinos e as pós-larvas estejam armazenados e já se sabe	Senar, 2017

	o volume dele, possibilitando a retirada de uma ou mais amostras, com a ajuda de um recipiente. A partir do valor do volume e da contagem das amostras, é realizada uma estimativa da quantidade de animais no volume total. Esse método carece de precisão, pois é afetado pelos diferentes tamanhos que um lote de animais pode ter;	
Por volume com água	É um método semelhante a anterior, porém essa estimativa é realizada com o volume dos animais juntamente com água. Ele apresenta uma desvantagem semelhante ao método anterior, acrescido da dificuldade de coleta de amostras que representem a distribuição igualitária do volume total, tendo em vista que os animais estão dispersos na água, no local em que estão armazenados;	Khantuwan e Khiripet, 2012
Comum filtro ou peneira	É conhecido o número que peixes que podem ser armazenados, onde a contagem é feita à medida que são movidos os animais de um local para outro com o instrumento;	Salazar <i>et al.</i> , 2015 Senar, 2017
Método gravimétrico	Constitui quando há a ajuda de uma balança eletrônica para encontrar uma relação entre o peso e a quantidade de animais. Esse método apresenta um fator dificultador que é o fato de nem todos os filhotes possuírem o mesmo tamanho e peso.	Khantuwan e Khiripet, 2012

Fonte: Citadas na tabela.

Com o objetivo de minimizar os problemas causados pela imprecisão da contagem manual como falhas humanas, falta de precisão e fadiga, além de fatores subjetivos durante o processo de contagem como a percepção individual, têm sido desenvolvidos contadores automáticos de peixes baseados em inteligência artificial. Essas tecnologias utilizam redes neurais capazes de identificar e quantificar os indivíduos a partir de imagens ou vídeos (Gonçalves *et al.*, 2022).

Segundo Gonçalves et al. (2022) sistemas de detecção baseados em RCNs oferecem uma alternativa para automatizar o manejo em pisciculturas, representando uma solução economicamente viável para o desenvolvimento de softwares especializados e precisos. A aplicação desses sistemas é vasta, sendo utilizados para a contagem de diferentes espécies aquáticas em diversas fases da vida, como larvas e alevinos de tilápia e pintado real. Uma das grandes vantagens é a flexibilidade da tecnologia, que permite, por exemplo, o desenvolvimento de sistemas de contagem que utilizam imagens capturadas por smartphones, tornando a ferramenta ainda mais acessível. Algoritmos de alto desempenho, como o YOLO (You Only Look Once), destacam-se pela velocidade e precisão, permitindo o reconhecimento dos animais em tempo real e otimizando o trabalho. Além da contagem, essas ferramentas de IA são aplicadas em outras tarefas essenciais da aquicultura de precisão, como a avaliação do

comportamento e da alimentação dos animais, consolidando-se como uma tecnologia central para a modernização do setor

2.5. INTELIGÊNCIA ARTIFICIAL NA CONTAGEM DE PEIXES

Neste contexto evidencia a necessidade de métodos de contagem mais eficientes e ágeis, surgindo assim a IA que não é um fenómeno novo, dado que o termo “inteligência artificial” foi cunhado pela primeira vez em 1955. No entanto, os avanços técnicos permitiram um progresso mais rápido nos últimos anos. As Nações Unidas definem a IA como um conjunto de tecnologias que permitem “máquinas capazes de imitar certas funcionalidades da inteligência humana, incluindo recursos como aprendizado, resolução de problemas, interação com a linguagem e até mesmo produção de trabalho criativo (Palomares *et al*, 2021).

A utilização da inteligência artificial na contagem de alevinos de tilápia tem sido uma ferramenta promissora para melhorar a eficiência e precisão desse processo crucial na aquicultura. Um exemplo prático dessa aplicação é o estudo de Santos (2024), que empregou uma Rede Neural Convolucional (RNC), especificamente a arquitetura YOLOv4 , para a identificação e contagem automatizada dos alevinos. No referido trabalho, o modelo demonstrou alta eficácia, alcançando uma média de precisão média (mAP@0,5) de 98,2% quando treinado com 100 épocas, e 98,1% com 150 épocas.

Dentre os métodos de aprendizagem profunda, as redes neurais convolucionais (CNNs) têm se destacado por sua eficácia na detecção de elementos visuais, utilizando camadas sequenciais e operações de convolução para extrair características relevantes das imagens, esse tipo de arquitetura é especialmente eficaz em tarefas de visão computacional, como classificação de imagens, detecção de objetos, segmentação semântica, reconhecimento facial e contagem de peixes. (Gu *et al*, 2018).

O uso de redes neurais convolucionais (CNNs), permite que algoritmos de IA identifiquem e contem alevinos em imagens capturadas em tempo real, mesmo em ambientes subaquáticos com baixa visibilidade e iluminação irregular, são camadas convolucionais que detectam padrões locais; camadas de pooling, que reduzem a dimensionalidade e melhoram a generalização; e que realizam a interpretação final das características extraídas (Fu & Yuna, 2022).

Dentre os algoritmos de detecção de objetos, o YOLO tem se destacado por revolucionar a área da visão computacional, principalmente por sua capacidade de realizar detecção em tempo real com alta precisão. Suas aplicações na contagem de animais visam automatizar e

aprimorar a gestão zootécnica, contribuindo para o bem-estar animal e para o aumento da eficiência produtiva (Li *et al.*, 2022; Oliveira *et al.*, 2021).

Modelos como o YOLO e o Faster R-CNN vêm sendo amplamente utilizados na detecção e contagem de peixes, estudos mostram que é possível alcançar 95% de acurácia, além de reduzir significativamente o tempo de processamento em comparação com métodos tradicionais (Li *et al.*, 2021). Com isso a utilização da inteligência artificial na contagem de alevinos de tilápia representa um avanço significativo na modernização da aquicultura, permitindo aos piscicultores obterem informações mais precisas e detalhadas sobre suas operações.

2.6. DIFERENTES MÉTODOS DE ROTULAÇÃO DE IMAGENS E COMO AFETAM O DESEMPNHO DOS MODELOS DE REDES NEURAIIS

2.6.1. Métodos de Rotulação de Imagens e Impactos no Desempenho

O processo de rotulação de dados é um dos principais gargalos no desenvolvimento de modelos de deep learning, especialmente em domínios especializados como o reconhecimento de peixes. A performance de uma Rede Neural Convolutacional (RNC) é diretamente dependente da qualidade e da quantidade dos dados de treinamento, e o método de anotação escolhido influencia tanto a precisão do modelo final quanto o esforço necessário para criar o dataset (MARRABLE *et al.*, 2022).

2.6.2. Tipos de Anotação: A Relação entre Precisão e Esforço

Na análise de imagens subaquáticas, diferentes técnicas de anotação podem ser empregadas, cada uma com um balanço distinto entre o tempo de execução e a riqueza de informações fornecidas ao modelo:

- **Ponto e Rótulo (Point-and-labelled):** Consiste em marcar um único pixel no corpo do peixe e associá-lo a um rótulo de espécie. É o método mais rápido, levando menos de um segundo por anotação, mas é insuficiente para treinar modelos de detecção de objetos como o YOLO, que precisam saber a localização e a extensão do alvo na imagem (MARRABLE *et al.*, 2022).
- **Caixa Delimitadora (Bounding Box):** É a técnica padrão para detecção de objetos, na qual um retângulo é desenhado ao redor de cada peixe. Este método fornece a localização espacial necessária para o treinamento, mas exige um esforço manual consideravelmente maior. Estima-se que desenhar uma caixa

delimitadora pode levar cerca de 10 segundos por peixe, um tempo significativamente maior em comparação com a anotação por ponto (MARRABLE et al., 2022).

- **Segmentação (Polígonos):** Oferece o mais alto nível de detalhe, contornando a forma exata do peixe. Embora gere dados muito precisos, o tempo necessário para desenhar polígonos manualmente é ainda mais elevado, sendo frequentemente considerado impraticável para a análise de grandes volumes de vídeo, como os de BRUVS (Baited Remote Underwater Video Station) (MARRABLE et al., 2022).

2.6.3. Qualidade da Rotulação e o Desafio do Ruído nos Rótulos

Além do tipo de anotação, a qualidade e a correção dos rótulos são cruciais. O fenômeno conhecido como ruído nos rótulos (label noise), que corresponde a rótulos incorretos, é um problema comum em datasets do mundo real (ALGAN; ULUSOY, 2021). Este ruído pode surgir por diversas razões, como a dificuldade de classificar espécies muito parecidas (mesmo para especialistas), a falta de experiência dos anotadores ou o uso de dados coletados da web com tags imprecisas (ALGAN; ULUSOY, 2021).

O ruído nos rótulos é considerado mais prejudicial ao treinamento do que o ruído nos próprios dados da imagem. Redes neurais profundas, devido à sua alta capacidade de aprendizado, tendem a memorizar os dados de treinamento, incluindo os rótulos incorretos, um fenômeno conhecido como overfitting (ALGAN; ULUSOY, 2021). Isso resulta em modelos que performam bem nos dados de treinamento (inclusive nos errados), mas que falham em generalizar seu conhecimento para novos dados, diminuindo drasticamente sua eficácia em aplicações práticas.

2.6.4. Estratégias para Otimizar o Processo de Rotulação

Para superar o gargalo do esforço manual e o problema do ruído, a comunidade científica tem desenvolvido estratégias que utilizam o próprio modelo de deep learning para auxiliar no processo de rotulação:

- **Rotulagem Assistida por Máquina:** Esta abordagem utiliza um modelo de IA pré-treinado para automatizar parcialmente a tarefa. Por exemplo, um modelo pode ser usado para gerar automaticamente as caixas delimitadoras nos peixes, exigindo do anotador humano apenas a validação e correção, em vez da criação do zero (MARRABLE et al., 2022). Essa automação acelera significativamente

o processo, permitindo que uma imagem seja anotada em cerca de 500 milissegundos pelo modelo, em comparação com os segundos ou minutos necessários para a anotação manual (MARRABLE et al., 2022).

- **Pseudo-rotulagem (Pseudo-Labeling):** É uma técnica na qual o modelo, após ser treinado em um conjunto inicial de dados rotulados, é usado para fazer previsões em dados não rotulados. As previsões que excedem um alto limiar de confiança são usadas como novos "pseudo-rótulos" para treinar o modelo novamente, aumentando o volume de dados sem esforço humano adicional (NABI et al., 2024). A eficiência dessa abordagem é notável: enquanto um anotador humano pode levar de 30 a 40 segundos para rotular uma imagem, a pseudo-rotulagem pode fazê-lo em menos de 5 segundos (NABI et al., 2024).
- **Aprendizagem Ativa (Active Learning):** Em vez de rotular dados aleatoriamente, a aprendizagem ativa seleciona de forma inteligente as amostras mais "informativas" de um conjunto de dados não rotulados e as apresenta para anotação humana (NABI et al., 2024). Amostras informativas são geralmente aquelas em que o modelo tem maior incerteza ou inconsistência. Ao focar o esforço humano onde ele é mais necessário, a aprendizagem ativa visa reduzir drasticamente o custo de anotação, alcançando um alto desempenho com um volume muito menor de dados rotulados manualmente (NABI et al., 2024).

Em conclusão, a rotulação de imagens é fundamental no desenvolvimento de sistemas de IA para reconhecimento de peixes. A escolha do método de anotação afeta diretamente o equilíbrio entre precisão e custo, enquanto a qualidade dos rótulos impacta a capacidade de generalização do modelo. Abordagens modernas, que combinam a automação, a pseudo-rotulagem e a aprendizagem ativa, são essenciais para construir datasets de alta qualidade de forma mais eficiente e escalável.

3. MATERIAL E METÓDOS

A pesquisa foi previamente aprovada pela Comissão de Ética no Uso de Animais (CEUA – IF Goiano), conforme protocolo n.º 6002300124. Os dados utilizados neste estudo foram obtidos a partir de alevinos de tilápia-do-Nilo (*Oreochromis niloticus*), provenientes da empresa Alevinos Rio Verde, localizada no município de Rio Verde, estado de Goiás, Brasil.

Para a coleta de dados, foram selecionadas aproximadamente 5.000 imagens de alevinos, com os exemplares apresentando comprimento médio entre 6 e 9 cm. O conjunto de imagens foi distribuído igualmente entre cinco diferentes densidades, resultando em 1.000 imagens para cada grupo de 10, 20, 30, 40 e 50 peixes por bandeja, respectivamente. As coletas foram realizadas em uma bandeja com dimensões de 30 x 35 x 10 cm, contendo uma lâmina de água mantida a 3 cm de altura.

A captura dos dados foi realizada através da gravação de vídeos, com a câmera posicionada para obter uma visão superior dos peixes. Utilizou-se um smartphone iPhone 12 Pro Max, com câmera de 12 megapixels e resolução de 4608×2592 pixels. Após a gravação, os vídeos foram armazenados e, em seguida, inseridos na plataforma Roboflow, onde foi aplicada uma taxa de extração de 60 quadros por segundo (frames/s) para converter os vídeos em imagens no formato JPG. Para garantir maior precisão na fase de anotação, foram selecionados para o banco de dados os momentos de menor movimentação dos animais, priorizando imagens com maior nitidez e definição.




Figura1: Esquema da plataforma de coleta de imagens. Método parado.

3.1. ROTULAÇÃO DO CONJUNTO DE IMAGENS

Após a finalização das gravações em vídeo, o material foi carregado na plataforma Roboflow, resultando em um banco de dados com aproximadamente 5.000 imagens no total. Para a anotação dos alevinos neste conjunto de imagens, foram empregados dois métodos distintos. O primeiro, a rotulação por polígono, consistiu em delinear com precisão todo o

contorno de cada peixe (Figura 2), um processo detalhado que fornece ao modelo a forma exata do objeto. Como alternativa, utilizou-se a rotulação por caixa delimitadora (bounding box), uma técnica mais rápida e simples que consiste em desenhar um retângulo ao redor de cada peixe para indicar sua localização (Figura 3).




Figura 2: Rotulação de imagens com polígono

Com as imagens extraídas, iniciou-se a rotulação utilizando polígono para contornar individualmente cada alevino. Na sequência, as mesmas imagens foram anotadas também por caixa delimitadora que consiste em desenhar um retângulo ao redor do peixe. (Figura 3). O banco de dados foi composto por: 1034 imagens com 10 peixes; 1000 imagens com 20 peixes; 1004 imagens com 30 peixes, 1050 imagens com 40 peixes e 1000 imagens com 50 peixes, todas rotuladas por ambos os métodos.




Figura 3: Rotulação de imagens com caixa delimitadoras manual

A rotulagem do conjunto de dados foi realizada de forma cooperada entre a equipes com funções distintas. Entre os componentes da equipe, alguns captaram as imagens e ficaram

responsáveis na análise visual dos alevinos, outra parte da equipe composta por duas pessoas, revisou todas as imagens, para garantir a consistência e precisão dos rótulos, e em seguida toda a equipe ficou responsável em realizar a marcação dos alevinos em ambos os métodos.

3.2. REDE CONVOLUCIONAL E TREINAMENTO DAS BASES DE DADOS

Os conjuntos de dados com 10, 20, 30, 40 e 50 alevinos em recipiente fechado de fundo branco, foram inicialmente submetidos a análise de qualidade das rotulações. Posteriormente, as bases de dados foram treinadas, sendo utilizadas mil imagens de cada quantidade de alevinos. Foi determinada 600 épocas. O número de épocas diz respeito à quantidade de vezes que o conjunto passa pela rede neural. O treinamento utilizando apenas a base de dados com rotulação por polígono foi definida após testes iniciais, sendo também verificado que nessas condições os peixes ficam mais sobrepostos e agregados, resultando em menor precisão pelo método bounding box.

Para o treinamento dos conjuntos de imagens, foi utilizada a plataforma Roboflow, que permite a anotação, o gerenciamento e a exportação de datasets para modelos baseados em redes neurais convolucionais, como o YOLOv8. O Roboflow oferece integração com ambientes de desenvolvimento como o Google Colab (<https://colab.research.google.com>, acessado em agosto de 2023), onde o processo de treino foi realizado. A base de dados foi anotada utilizando tanto caixas delimitadoras quanto polígonos, visando avaliar o impacto de diferentes formatos de rotulação na performance da contagem automática. O processamento foi realizado em um computador equipado com processador Intel Core i5-10400 (2.90GHz, 12 threads), 32GB de memória RAM e armazenamento SSD de 240GB.

Foram utilizadas no treinamento da rede neural, 700 imagens no treinamento (70%), validação 200 imagens (20%) e teste 100 (10%), para cada um dos conjuntos de dados formados com 1000 imagens. O número de interações entre os dados foi determinado em 600 épocas (Lin et al., 2022)

A arquitetura do algoritmo de detecção utilizada no estudo foi constituída por três partes principais, o backbone pré-treinado no ImageNet que faz a extração de características e recursos da imagem de entrada através de convoluções, o Neck que conecta os mapas de recurso gerados da rede backbone e os envia como entrada para as próximas camadas, denominada head, responsável pelas previsões das caixas delimitadoras ou máscaras. As camadas de normalização foram aplicadas ao final de cada camada convolucional, para regularizar as entradas das camadas anteriores.

A rede convolucional de detecção foi então composta por 415 camadas, formando o modelo profundo e complexo de detecção. As camadas convolucionais do algoritmo de detecção foram organizadas detalhadamente para o reconhecimento e detecção dos alevinos em diferentes escalas. No processo de treinamento do algoritmo, foram exploradas várias operações de convolução e concatenação para a extração das características das imagens e geração dos mapas de recursos. Para tal, a arquitetura do algoritmo foi projetado para processar todas as particularidades nas imagens, com o objetivo de tornar a detecção dos alevinos feita pela rede mais precisa e robusta.

Na tabela 2, são apresentados os principais parâmetros utilizados na configuração da rede convolucional.

Tabela 2: Parâmetros utilizados na configuração da rede convolucional.

Parâmetros definidos para o treinamento	
Treinamento	r0=0.01, lrf=0.1, momentum=0.937 weight_decay=0.0005 box=0.05, loss_ota=1 Batch size = 16 Max-epochs =600 Loss_function= BCE (Binary Cross Entropy) Input_size= 640X640 IOU_thres=0.45
Ambiente	CUDA:0 (Tesla T4, 15102.0625MB) Platform= Python 3.8 Implementation tools= PyTorch

Fonte: Autor

3.3. MÉTRICAS DE AVALIAÇÃO

Através da matriz de confusão foi possível medir o desempenho da rede neural convolucional por meio de indicadores importantes. Entre esses indicadores estão: os verdadeiros positivos (VP), quando a rede identifica corretamente o objeto; os falsos positivos (FP), nos casos em que há detecção incorreta; os verdadeiros negativos (VN), quando o modelo acerta ao indicar a ausência do objeto; e os falsos negativos (FN), que ocorrem quando a rede falha em reconhecer o objeto presente.

As métricas utilizadas para avaliar o desempenho do modelo incluíram: acurácia (A), precisão (P), recall (R) e o mAP@0,5. Essas métricas foram escolhidas para possibilitar análise mais precisa da eficácia dos modelos, com base na relação entre erros e acertos.

A recall mediu a capacidade do modelo de encontrar os peixes presentes, apontando aqueles que não foram detectados (FN). A acurácia representou a taxa total de acertos obtidos pelo modelo durante os testes. A precisão indicou a proporção de detecções corretas entre todas as identificações realizadas, ou seja, a quantidade de peixes detectados que realmente estavam presentes. Já o mAP@0,5 expressou o desempenho do modelo com base na precisão das predições, considerando limiar de IoU fixado em 0,5. A seguir a fórmula utilizada para os cálculos :

Acurácia (A) = (VP +VN)/ (VP+VN+FP+ FN)
Precisão (P) = VP/(VP+FP)
Recall (R) = VP/(VP+FN)
Média da precisão média (mAP@0,5) = $1/N \sum_{i=1}^N AP_{50}(C_i)$
F-score=2*((precisão*recall))/(precisão+recall)

A interseção das caixas delimitadoras previstas pela rede convolucional (Figura 4). Na avaliação, foi considerado acerto quando as intersecções sobre a união (IoU) das caixas previstas e demarcadas atingem o limiar (*threshold*) de 50% (mAP@0,5) (Kukil, 2022).




Figura 4: Rotulação caixa delimitadora pelo roboflow

4. RESULTADOS

Com as tabelas 2 e 3 apresentadas, é possível visualizar os comportamentos dos diferentes modelos de detecção avaliados, que foram treinados com variados métodos de marcação (polígono e caixa delimitadora) e diferentes densidades de peixes. A métrica de precisão, que indica a fração de verdadeiros positivos em relação a todas as detecções, mostrou variações significativas conforme a quantidade de peixes. Na marcação por polígono, notou-se

que, conforme o número de peixes subia de 10 para 50, houve variação, começando em 97% e alcançando um pico de 99% com 40 peixes, diminuindo levemente para 97,86% com 50 peixes.

De acordo com a tabela 2 o comportamento do recall, que mede a capacidade do modelo em encontrar todos os objetos de interesse, ou seja, o próprio peixe (verdadeiros positivos em relação ao total de positivos reais), manteve-se elevado nos modelos com marcação por polígono, atingindo valores superiores a 97% em todos os casos. Já na marcação com caixa delimitadora (marcação automática), a precisão variou de 96,03% com 10 peixes para 93,2% com 20 peixes e manteve-se em torno de 94-97% nos demais casos, indicando menor estabilidade. O recall apresentou oscilações mais acentuadas, especialmente no cenário com 40 peixes (80,78%), o que sugere que as caixas não conseguiram isolar adequadamente os indivíduos em maior densidade.

Tabela 2 – Resultados dos diferentes modelos anotados e treinados para contagem de peixe em diferentes marcações, polígono e caixa delimitadora (marcação automática).

Imagens - Especificações	Espécie	Épocas	Precisão (%)	Recall (%)
1000 imagens polígono 10 peixes na bacia	Tilápia	600	97	98
1000 imagens polígono 20 peixes na bacia	Tilápia	600	98	99
1000 imagens polígono 30 peixes na bacia	Tilápia	600	94,98	99
1000 imagens polígono 40 peixes na bacia	Tilápia	600	99	99,39
1000 imagens polígono 50 peixes na bacia	Tilápia	600	97,86	97,28
1000 imagens marcação automática 10 peixes na bacia	Tilápia	600	96,03	97,07
1000 imagens marcação automática 20 peixes na bacia	Tilápia	600	93,2	96,53
1000 imagens marcação automática 30 peixes na bacia	Tilápia	600	94,841	95,8
1000 imagens marcação automática 40 peixes na bacia	Tilápia	600	97,21	80,78
1000 imagens marcação automática 50 peixes na bacia	Tilápia	600	93,2	96,5

Fonte: Próprio autor.

A análise das métricas complementares da matriz de confusão — como mAP, acurácia e F-score — reforça esses achados. O valor de mAP (média de precisão) foi maior nos modelos com marcação por polígono em densidades mais baixas (99% com 20 e 30 peixes) e manteve-se alto até 50 peixes (98,5%). Em contrapartida, os modelos com marcação automática apresentaram mAPs inferiores, com destaque para o cenário com 40 peixes, cujo valor foi de apenas 82,4%. Essa mesma tendência foi observada na tabela 3 na acurácia (90%) e F-score (88,24%), evidenciando perda significativa de desempenho em alta densidade com marcação por caixa. O modelo com marcação automática em 50 peixes também apresentou valores inferiores nas três métricas (mAP de 97,2%, acurácia de 85% e F-score de 86,21%),

demonstrando que o modelo encontra maior dificuldade em lidar com sobreposição e contornos imprecisos.

Tabela 3 – Porcentagens das médias de precisão (mAp), acurácia e F-score respectivos para cada modelo aplicado.


Imagens - Especificações	mAp (%)	Acurácia (%)	F-score (%)
1000 imagens 10 peixes na bacia	98	97	97
1000 imagens 20 peixes na bacia	99	100	98
1000 imagens 30 peixes na bacia	99	100	98
1000 imagens 40 peixes na bacia	91,28	99	99,19
1000 imagens 50 peixes na bacia	98,5	98	97,56
1000 imagens marcação automática 10 peixes na bacia	98,41	98	96,54
1000 imagens marcação automática 20 peixes na bacia	97,2	85	97
1000 imagens marcação automática 30 peixes na bacia	97,513	97	95,32
1000 imagens marcação automática 40 peixes na bacia	82,4	90	88,24
1000 imagens marcação automática 50 peixes na bacia	97,2	85	86,21

Fonte: Próprio autor.

Em termos comparativos, é evidente que os modelos com marcação poligonal superaram aqueles com marcação por caixa delimitadora, especialmente em cenários de maior densidade. A marcação por polígonos, por fornecer contornos mais precisos dos peixes, permitiu que o modelo YOLOv8 segmentasse melhor os indivíduos, reduzindo a taxa de falsos positivos e falsos negativos, como refletido nas métricas de recall e F- score. Assim, conclui-se que, para contagem de alevinos de tilápia com tamanhos entre 6 e 9 cm em ambientes controlados, o método de anotação por polígono, apesar de mais trabalhoso, proporciona melhor desempenho na detecção e contagem automática de peixes. A escolha desse método pode ser decisiva para aplicações que exigem alta precisão, como em estudos de crescimento, manejo ou vendas por unidade.

4.1 ANÁLISE DO GRÁFICO DE TREINAMENTO E VALIDAÇÃO PARA 10, 20, 30, 40 E 50 PEIXES MARCAÇÃO POLÍGONO

A figura 6 reúne os gráficos de desempenho treinado no visual studio code com imagens anotadas por polígonos para diferentes quantidades de peixes, variando entre 10, 20, 30, 40 e 50 alevinos de tilápia. Em todos os conjuntos, observa-se redução progressiva nas perdas de treino (box_loss, cls_loss e dfl_loss) ao longo das épocas, o que indica que o modelo foi capaz de aprender as características visuais dos peixes de forma eficiente mesmo com variações na densidade dos indivíduos. Além disso, as métricas de precisão e recall apresentaram crescimento estável, alcançando valores altos em todos os casos, o que demonstra a robustez do treinamento.






Figura 6: Gráficos dos resultados de treinamento da máquina na marcação polígono. a) resultados com 10 peixes b) resultados com 20 peixes c) resultados com 30 peixes, d) resultados com 40 peixes, e) resultados com 50 peixes

Nos gráficos de validação, a tendência geral se mantém: à medida que o número de peixes aumenta, o modelo ainda consegue manter perdas relativamente baixas e desempenho

elevado nas métricas mAP50 e mAP50-95. Entretanto, nota-se leve oscilação nas curvas de validação à medida que a densidade dos peixes cresce, especialmente nos conjuntos com 40 e 50 indivíduos. Isso sugere que, embora o modelo continue generalizando bem, a complexidade crescente da tarefa (devido à sobreposição e à proximidade entre os peixes) exige mais precisão na segmentação e pode introduzir pequenos desafios na detecção individual

De modo geral, os resultados demonstram que o modelo é eficaz na contagem de peixes anotados com polígonos mesmo em cenários de alta densidade. As anotações detalhadas permitiram que o modelo alcançasse métricas superiores a 0.95 nas diferentes quantidades avaliadas, com destaque para os conjuntos de 10 a 30 peixes, que apresentaram desempenho mais estável e linear. Já os conjuntos com 40 e 50 peixes, apesar das pequenas flutuações, ainda mantêm performance excelente, evidenciando a capacidade do modelo de lidar com situações mais complexas de detecção.

5. DISCUSSÃO

Este estudo avaliou formas de anotar imagens para a contagem automatizada de alevinos de Tilápia-do-Nilo (*Oreochromis niloticus*) usando visão computacional. O principal resultado mostra que usar polígonos para marcar os peixes (segmentação de instância) é muito mais eficiente do que usar caixas delimitadoras (bounding boxes). Essa diferença de desempenho fica ainda maior em cenários com alta densidade de peixes, que é um grande desafio na aquicultura (Barreto *et al.*, 2025). Nesses ambientes, os peixes ficam muito sobrepostos, o que atrapalha a precisão da detecção visual (Roney *et al.*, 2024). A literatura até sugere outras saídas para esse problema, como criar mapas de densidade para estimar o total de peixes sem localizá-los (Zhao *et al.*, 2024) ou detectar apenas uma parte do corpo, como a cabeça (Zhang *et al.*, 2024). No entanto, a desvantagem dessas abordagens é que se perde a identificação de cada peixe individualmente (Zhang *et al.*, 2024). O método de segmentação com polígonos, que validamos aqui, se destaca justamente por conseguir manter essa individualidade.

A vantagem dos polígonos é que eles desenharam o contorno exato de cada peixe, permitindo que o modelo de deep learning YOLOv8 separe e conte cada um, mesmo quando estão parcialmente encobertos (Mind Kosh, 2024; Labellerr, 2025). Já as caixas delimitadoras, por serem retangulares, acabam juntando vários peixes sobrepostos em uma só marcação, levando a erros na contagem para menos (V2 Solutions, 2025; Remotelabeler, 2025). Isso explica os resultados deste trabalho: com 40 alevinos da espécie *Oreochromis niloticus* e um treinamento de 600 épocas, o modelo com caixas teve um recall de apenas 80,78% e um

mAP@0,5 de 82,4%. Por outro lado, o modelo com polígonos se manteve forte, com recall acima de 97% e mAP@0,5 de 98,5%, mesmo em um cenário com 50 alevinos.

Nossos resultados concordam com outros estudos. Pesquisas como as de Garcia *et al.* (2020) e Sánchez-Torres, Ceballos-Arroyo e Robles-Serrano (2018) já demonstraram que anotações detalhadas eram importantes para tarefas de alta precisão, como estimar o peso total dos peixes. A contribuição deste trabalho foi avaliar e validar essa ideia para a tarefa de contagem usando a arquitetura YOLOv8. É importante dizer, no entanto, que comparar os números exatos de desempenho com outros estudos é complicado, pois a performance de uma rede neural depende muito da sua arquitetura específica (UPGRAD, 2024), que pode ser diferente da configuração adotada neste estudo. Mesmo assim, o fato de os resultados serem parecidos reforça que a qualidade da anotação é um pilar para o sucesso da visão computacional na aquicultura.

Um ponto importante é a dificuldade prática do método. Anotar manualmente com polígonos, embora seja o mais preciso, leva muito tempo e custa caro. A literatura mostra que esse método pode ser de quatro a oito vezes mais lento e caro do que anotar com caixas delimitadoras (Mullen *et al.*, 2019; Dai *et al.*, 2022). Por isso, a validação de uma abordagem semiautomática, usando a ferramenta SmartPolygon que integra o Segment Anything Model (SAM) da Meta AI (Kirillov *et al.*, 2023), foi um ponto central deste estudo, pois ajudou a unir a precisão dos polígonos com um jeito mais rápido de trabalhar. Essa ideia de "humano no circuito" (human-in-the-loop), onde a IA faz uma pré-rotulagem e um humano valida, é vista como a melhor estratégia para equilibrar velocidade, custo e qualidade (KEYLABS, 2025). Isso torna a criação de bons bancos de dados um processo mais rápido e prático.

Na prática, os resultados deste estudo dão um norte para quem desenvolve tecnologias de contagem, mostrando que vale a pena investir em métodos de segmentação com polígonos para ter mais precisão. Os bons resultados de mAP@0,5 (acima de 98%) que encontramos estão de acordo com outros estudos de ponta. Santos (2024), por exemplo, usando rotulagem automática em tilápias, também alcançou mAP@0,5 de 98,2%. Da mesma forma, Hamzaoui *et al.* (2023), ao otimizar um modelo YOLOv5, teve um ótimo desempenho na detecção de espécies marinhas. Isso mostra que o *deep learning*, quando usa dados de alta qualidade, é um caminho seguro para a automação na aquicultura. Para o produtor, uma contagem precisa resulta em um controle de estoque mais correto e uma alimentação mais eficiente, o que melhora a conversão alimentar e, conseqüentemente, o lucro do cultivo (AQUA SIGHTLINE, 2025; ISLAM; TAREQUE, 2024).

Vale ressaltar, no entanto, as limitações do trabalho. Os testes foram feitos em um ambiente controlado, com uma bandeja de fundo branco e água limpa. A literatura já mostra que estudos em condições ideais costumam apresentar um desempenho melhor do que teriam em ambientes de produção real (Barreto *et al.*, 2025). Além disso, a pesquisa se limitou a uma única espécie, a Tilápia-do-Nilo, e a um tamanho específico (6 a 9 cm).

Para o futuro, necessita-se testar a metodologia de rotulagem com polígonos em condições de campo. Levar o sistema para tanques de cultivo reais traria desafios como água turva, mudanças de luz e sombras, que iriam testar não só o modelo, mas o próprio processo de anotação (Barreto *et al.*, 2025; Meegle, 2024). Embora existam algoritmos para melhorar imagens subaquáticas, eles podem deixar o processo mais lento ou até mesmo criar distorções que atrapalham a detecção (Wang *et al.*, 2024). Superar isso exigiria formas mais inteligentes de capturar as imagens e modelos mais capazes de se adaptar.

Outra pesquisa futura muito importante é aplicar o método para outras espécies de peixes. Fazer com que os modelos funcionem bem para peixes com formatos diferentes da tilápia é um grande desafio para a visão computacional (Saleh, 2023; Xu; Corr, 2024). Ferramentas automáticas como o SAM, que foram treinadas com dados gerais, podem não funcionar tão bem para espécies com formatos menos comuns, exigindo mais correções manuais (Ji *et al.*, 2023). Investigar como o formato da espécie afeta a eficiência da rotulagem e usar técnicas avançadas como *transfer learning* e adaptação de domínio (domain adaptation) (Singhal *et al.*, 2023; Di Maio *et al.*, 2024) será fundamental para criar um sistema de contagem que seja realmente versátil e útil para toda a aquicultura.

5. CONCLUSÃO

O estudo evidenciou que o método de rotulação de imagens influencia diretamente a precisão dos modelos de IA na contagem de alevinos de tilápia. A rotulação por polígonos mostrou-se mais eficaz que as caixas delimitadoras, especialmente em altas densidades, sendo recomendada para o desenvolvimento de ferramentas de visão computacional aplicadas à piscicultura.

REFERÊNCIAS

- AQUA SIGHTLINE. The future of fish farming: embracing precision aquaculture. **AQUAfeed**, 18 jun. 2025. Disponível em: <https://www.aquafeed.co.uk/the-future-of-fish-farming-embracing-precision-aquaculture/>. Acesso em: 18 jun. 2025.
- ARUMUGAM, M. *et al.* Avanços recentes na produção de tilápia para o desenvolvimento sustentável da aquicultura indiana e seus benefícios econômicos. **Fishes**, v. 8, n. 4, p. 176, 2023.
- BARRETO, A. *et al.* Machine Vision Applications for Welfare Monitoring in Aquaculture: Challenges and Opportunities. **Reviews in Fisheries Science & Aquaculture**, 2025.
- BARROS, L. O. *et al.* A precisão da contagem de alevino: contador de peixes na piscicultura com uso de tecnologia. **Brazilian Journal of Development**, Curitiba, v. 11, n. 4, p. 01-13, abr. 2025.
- BEHERA, B. *et al.* Surgimento do vírus do lago Tilapia associado à mortalidade de tilápias do Nilo cultivadas *Oreochromis niloticus* (Linnaeus 1758) na Índia. **Aquaculture**, v. 484, p. 168-174, 2018.
- BENTSEN, H. B. *et al.* Genetic improvement of farmed tilapias: growth performance in a complete diallel cross experiment with eight strains of *Oreochromis niloticus*. **Aquaculture**, v. 160, n. 1-2, p. 145-173, 1998.
- BESSA, W. R. B. **Soluções baseadas em redes neurais convolucionais para contagem automática de animais aquáticos**. 2022.
- CARNEIRO, C. J. *et al.* Cadeia produtiva da piscicultura: um olhar para a evolução da tilapicultura no Brasil. **Revista Perspectiva**, v. 46, n. 175, p. 25–34, 2022.
- DAI, W. *et al.* Polygon-free: A text detection system for arbitrary-shaped text with upright bounding box annotation. **arXiv preprint arXiv:2011.13307**, 2022.
- DE OLIVEIRA, E. G. *et al.* **Produção de tilápia: Mercado, espécie, biologia e recria**. Embrapa Meio-Norte, 2007.
- DI MAIO, S. *et al.* A transfer learning framework for object detection in a few-data regime through generative models. **arXiv preprint arXiv:2402.06784**, 2024.
- FAO. **The State of Food and Agriculture 2022**. Rome: FAO, 2022.
- GARCIA, R. *et al.* Automatic fish measurement using a camera and a 3D sensor, applied to a long-term experiment. **ICES Journal of Marine Science**, v. 77, n. 7-8, p. 3050–3061, 2020.
- GARCIA, R. *et al.* Automatic segmentation of fish using deep learning with application to fish size measurement. **ICES Journal of Marine Science**, v. 77, n. 4, p. 1354-1366, 2020.
- GOMES, D. S. Inteligência Artificial: conceitos e aplicações. **Revista Olhar Científico**, v. 1, n. 2, p. 234-246, 2010.

GONÇALVES, D. N. *et al.* Using a convolutional neural network for fingerling counting: A multi-task learning approach. **Aquaculture**, v. 557, p. 738334, 2022.

GONÇALVES, G. M. *et al.* Fish detection and counting using convolutional neural networks and mobile devices in aquaculture. **Aquaculture Engineering**, v. 97, p. 102257, 2022. DOI: 10.1016/j.aquaeng.2022.102257.

GONÇALVES, T. G. *et al.* Genetic parameter estimates indicate the possibility of genetic gain by selecting for reproductive traits of females from a commercial tilapia population (*Oreochromis niloticus*). **Aquaculture**, v. 586, p. 740818, 2024.

GU, J. *et al.* Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018.

HAMZAOUI, M. *et al.* An improved deep learning model for underwater species recognition in aquaculture. **Fishes**, v. 8, n. 10, p. 514, 2023.

ISLAM, M. S.; TAREQUE, M. H. Economic Implications of Information Technology in Aquaculture and Fisheries. In: BHATTA, R. (ed.). **Information Technology in Fisheries and Aquaculture**. Singapore: Springer, 2024. p. 233-251.

Jl, W. *et al.* SAM on medical images: A comprehensive study on three prompt modes. **Medical Image Analysis**, v. 87, p. 102831, 2023.

KEYLABS. Implementing Semi-Automated Labeling: Balancing Speed and Accuracy. **Keylabs Blog**, 12 mar. 2025. Disponível em: <https://keylabs.ai/blog/implementing-semi-automated-labeling-balancing-speed-and-accuracy/>. Acesso em: 18 jun. 2025.

KHANTUWAN, W.; KHIRIPET, N. Live shrimp larvae counting method using co-occurrence color histogram. In: INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING/ELECTRONICS, COMPUTER, TELECOMMUNICATIONS AND INFORMATION TECHNOLOGY, 9., 2012, [S.l.]. **Anais [...]**. [S.l.]: IEEE, 2012. p. 1–4.

KIRILLOV, A. *et al.* Segment Anything. **arXiv preprint arXiv:2304.02643**, 2023.

LABELLERR. **Guide to Image Annotation: Techniques, Tools, and Best Practices**. 2025. Disponível em: <https://www.labellerr.com/blog/guide-to-image-annotation-techniques-tools-and-best-practices/>. Acesso em: 18 jun. 2025.

LI, D. *et al.* Automatic counting methods in aquaculture: A review. **Journal of the World Aquaculture Society**, v. 52, n. 2, p. 269-283, 2021.

LI, X. *et al.* Automatic detection and counting of pigs based on improved YOLOv5 model. **Computers and Electronics in Agriculture**, v. 198, p. 107051, 2022.

LI, X. *et al.* Rede de pontos-chave de aprimoramento de deconvolução para contagem eficiente de alevinos de peixe. **Animais**, v. 14, n. 10, p. 1490, 2024.

LI, Z.; WANG, Q.; ZHANG, H. Automated fish detection and counting in aquaculture using deep learning techniques. **Computers and Electronics in Agriculture**, v. 182, p. 105985, 2021.

MEEGLE. **Computer Vision In Aquaculture**. 2024. Disponível em: https://www.meeGLE.com/en_us/topics/computer-vision/computer-vision-in-aquaculture. Acesso em: 18 jun. 2025.

MIND KOSH. **Accurate object detection with Polygon annotation**. 2024. Disponível em: <https://mindkosh.com/blog/accurate-object-detection-with-polygon-annotation/>. Acesso em: 18 jun. 2025.

MORETTI, G. A.; JÚNIOR, E. G. Desempenho zootécnico de tilápias do Nilo criadas em tanques escavados sob baixa temperatura no município de Nova Aurora/PR. **Arquivos Brasileiros de Medicina Veterinária FAG**, v. 3, n. 1, p. 220-227, 2020.

MULLEN, R. J. *et al.* Comparing the Effects of Annotation Type on Machine Learning Detection. In: PROCEEDINGS OF THE IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION WORKSHOPS, 2019, Long Beach. **Anais [...]**. Long Beach: CVF, 2019. p. 1-9.

NAÇÕES UNIDAS. **Guia de Recursos sobre Estratégias de Inteligência Artificial (IA)**. 2021. Disponível em: https://sdgs.un.org/sites/default/files/2021-04/Resource%20Guide%20on%20AI%20Strategies_April%202021_rev_. Acesso em: 21 jun. 2025.

PALOMARES, I. *et al.* Uma visão panorâmica e análise swot da inteligência artificial para alcançar os objetivos de desenvolvimento sustentável até 2030: Progresso e perspectivas. **Applied Intelligence**, v. 51, p. 6497–6527, 2021.

PEIXEBR - ASSOCIAÇÃO BRASILEIRA DA PISCICULTURA. **Anuário da Piscicultura 2024**. 2024. Disponível em: <https://www.seafoodbrasil.com.br/brasil-registra-579080-t-de-tilapia-produzidas-em-2023>. Acesso em: 21 jun. 2025.

PRABU, E. *et al.* Tilapia—an excellent candidate species for world aquaculture: a review. **Annual Research & Review in Biology**, v. 31, n. 3, p. 1-14, 2019.

RANJAN, R.; TSUKUDA, S.; GOOD, C. Effects of image data quality on a convolutional neural network trained in-tank fish detection model for recirculating aquaculture systems. **Computers and Electronics in Agriculture**, v. 205, p. 107644, 2023.

REGAL SPRINGS INDONESIA. **Boosting the economy: Indonesia's tilapia export value reaches 1.2 trillion Rupiah**. 2024. Disponível em: <https://regalsprings.co.id/en/articles/boosting-the-economy-indonesias-tilapia-export-value-reaches-1-2-trillion-rupiah>. Acesso em: 2 jun. 2025.

REHMAN, S. *et al.* Stress in aquaculture hatcheries: source, impact and mitigation. **International Journal of Current Microbiology and Applied Sciences**, v. 6, n. 10, p. 3030-3045, 2017.

REMOTELABELER. **Polygon Annotation vs. Bounding Box Annotation: Comparison**. 2025. Disponível em: <https://www.remotelabeler.com/polygon-annotation-vs-bounding-box-annotation-comparison/>. Acesso em: 18 jun. 2025.

RONEY, K. *et al.* Deep learning in sustainable aquaculture: a review of detection, prediction, and monitoring applications. **Sustainability**, v. 17, n. 11, p. 5084, 2024.

SALEH, A. **Computer vision and deep learning for fish classification in underwater environments**. 2023. Tese (Doutorado em Filosofia) – James Cook University, Townsville, 2023.

SÁNCHEZ-TORRES, G.; CEBALLOS-ARROYO, A.; ROBLES-SERRANO, S. Automatic Measurement of Fish Weight and Size by Processing Underwater Hatchery Images. **Engineering Letters**, v. 26, n. 4, p. 461–472, 2018.

SANTOS, L. C. **Inteligência Artificial na contagem de tilápias *Oreochromis niloticus***. 2024. 33 f. Trabalho de Conclusão de Curso (Bacharelado em Ciências Biológicas) – Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, 2024.

SANTOS, V. B. *et al.* Performance of Nile tilapia *Oreochromis niloticus* strains in Brazil: a comparison with Philippine strain. **Journal of Applied Animal Research**, v. 47, n. 1, p. 72–78, 2019.

SCHULTER, E. P.; VIEIRA FILHO, J. E. R. **Evolução da piscicultura no brasil: diagnóstico e desenvolvimento da cadeia produtiva da tilápia**. Brasília, DF: IPEA, 2017. (Texto para Discussão, n. 2328).

SEBRAE. **Criação de tilápias em tanques escavados**. Natal: Sebrae, 2014.

SINGHAL, P. *et al.* Domain Adaptation: Challenges, Methods, Datasets and Applications. **IEEE Access**, v. 11, p. 10144–10184, 2023.

UPGRAD. **Neural Network Architecture: Components, Types, and Key Algorithms**. 2024. Disponível em: <https://www.upgrad.com/blog/neural-network-architecture-components-algorithms/>. Acesso em: 18 jun. 2025.

V2 SOLUTIONS. **Beyond Bounding Boxes: Next-Gen Image Annotation Techniques for AI Vision Models**. 2025. Disponível em: <https://www.v2solutions.com/blogs/beyond-bounding-boxes-next-gen-image-annotation-techniques-for-ai-vision-models/>. Acesso em: 18 jun. 2025.

WANG, H. *et al.* Present status of tilapias culture in China mainland. **Open Journal of Fisheries Research**, v. 1, n. 1, p. 22–28, 2014.

WANG, J. *et al.* EnYOLO: A Real-Time Framework for Domain-Adaptive Underwater Object Detection with Image Enhancement. **arXiv preprint arXiv:2406.11029**, 2024.

WE ARE AQUACULTURE. [Título do artigo, se disponível]. We Are Aquaculture, [data de publicação, se disponível]. Disponível em: <https://weareaquaculture.com/news/aquaculture>. Acesso em: 21 jun. 2025.

XU, W.; CORR, O. Review of machine learning for aquatic species identification. **Reviews in Aquaculture**, v. 16, n. 2, p. 775–794, 2024.

YANG, H.; CHEN, S.; LIN, T. Recent advances in fish counting and classification using computer vision. **Aquacultural Engineering**, v. 93, p. 102142, 2021.

ZHANG, C. *et al.* Deconvolution Enhancement Keypoint Network for Efficient Fish Fry Counting. **Animals**, v. 14, n. 11, p. 1533, 2024.

ZHANG, J.; PANG, H.; CAI, W.; YAN, Z. Usando tecnologia de processamento de imagem para criar um novo algoritmo de contagem de alevinos. **Aquaculture and Fisheries**, v. 7, p. 441–449, 2022.

ZHAO, Y. *et al.* Hybrid Swin-CSRNet: A Dense Fish Counting Network Based on Swin Transformer and CSRNet. **Journal of Marine Science and Engineering**, v. 12, n. 10, p. 1823, 2024.