

BASES VISUAIS E MATEMÁTICAS PARA O USO DE INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO DE QUATRO ESPÉCIES DO GÊNERO MUGIL

VISUAL AND MATHEMATICAL BASES FOR THE USE OF ARTIFICIAL INTELLIGENCE IN THE IDENTIFICATION OF FOUR SPECIES OF THE GENUS MUGIL

Jovan Louzeiro Silva^{1*}; Emanuele Borges da Silva¹; Janaina dos Santos Oliveira¹; Ravel Menezes da Cruz¹; Andrey Marcos Mendonça Ferreira¹; Romário Costa Ribeiro¹, Ronan Corrêa Santos¹; Diego Aurélio dos Santos Cunha¹.

¹ IEMA Pleno Carutapera

*e-mail: jovan.louzeiro@gmail.com

Citação: SILVA, J. L.; SILVA, E. B.; OLIVEIRA, J. S.; SILVA, R. M.; FERREIRA, A. M. M.; RIBEIRO, R. C.; SANTOS, R. C.; CUNHA, D. A. S. (2026). Bases visuais e matemáticas para o uso de inteligência artificial na identificação de quatro espécies do gênero Mugil. Revista Brasileira de Engenharia de Pesca, 17(1), 99–116.

<https://doi.org/10.18817/repesca.v17i1.4426>

Recebido: 29 November 2025

Revisado: 22 December 2025

Aceito: 9 January 2026

Publicado: 10 January 2026



Copyright: © 2026 by the authors. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Resumo

A identificação correta de espécies de peixes é fundamental para a gestão pesqueira sustentável, a conservação da biodiversidade aquática e a produção de dados científicos confiáveis, especialmente em ambientes costeiros e estuarinos onde a pesca artesanal desempenha papel central. No entanto, grupos taxonômicos com elevada similaridade morfológica, como o gênero Mugil (Mugilidae), apresentam elevados índices de erro quando a identificação se baseia exclusivamente em observação visual. Diante das limitações de métodos moleculares, que demandam alto custo e infraestrutura especializada, este estudo teve como objetivo desenvolver e apresentar uma abordagem integrada, acessível e não invasiva para auxiliar na identificação de espécies do gênero Mugil comuns na costa maranhense, utilizando imagens digitais e modelagem matemática explicativa. Foram analisadas imagens de *Mugil brevirostris*, *Mugil curema*, *Mugil incilis* e *Mugil liza*, a partir das quais foram extraídas medidas morfométricas básicas (área corporal, comprimento e altura máximos) e índices proporcionais, como Índice de Área, Razão de Aspecto e um índice de regularidade das escamas baseado em variação de brilho. A integração desses descritores permitiu a construção de um modelo matemático interpretável capaz de diferenciar logicamente as espécies analisadas, mesmo em um grupo morfológicamente críptico. Os resultados demonstraram que características visualmente perceptíveis podem ser traduzidas em métricas quantitativas objetivas, reduzindo a subjetividade da identificação tradicional. A metodologia mostrou-se



promissora para aplicações em educação ambiental, monitoramento participativo, ciência cidadã e gestão pesqueira, além de estabelecer bases conceituais para futuras aplicações em inteligência artificial. Conclui-se que a combinação entre análise visual, morfometria digital e modelos matemáticos simples constitui uma ferramenta eficaz, compreensível e de baixo custo para a identificação de espécies de peixes costeiros.

Palavras-chaves: Inovação. Recursos pesqueiros. Pesca. Análise de imagem. Gestão pesqueira.

Abstract

Accurate fish species identification is essential for sustainable fisheries management, aquatic biodiversity conservation, and the generation of reliable scientific data, particularly in coastal and estuarine environments where artisanal fisheries play a central role. However, taxonomic groups with high morphological similarity, such as the genus *Mugil* (Mugilidae), often present high misidentification rates when based solely on visual observation. Considering the limitations of molecular methods, which require high costs and specialized infrastructure, this study aimed to develop and present an integrated, accessible, and non-invasive approach to assist in the identification of *Mugil* species common along the Maranhão coast, using digital images and explanatory mathematical modeling. Images of *Mugil brevirostris*, *Mugil curema*, *Mugil incilis*, and *Mugil liza* were analyzed, from which basic morphometric measures (body area, maximum length, and maximum height) and proportional índices, such as Area Index, Aspect Ratio, and a scale regularity index based on brightness variation, were extracted. The integration of these descriptors enabled the construction of an interpretable mathematical model capable of logically differentiating the analyzed species, even within a morphologically cryptic group. The results demonstrated that visually perceptible characteristics can be translated into objective quantitative metrics, reducing the subjectivity of traditional morphological identification. The proposed methodology shows strong potential for applications in environmental education, participatory monitoring, citizen science, and fisheries management, while also establishing a conceptual foundation for future applications in artificial intelligence. It is concluded that the combination of visual analysis, digital morphometrics, and simple explanatory models represents an effective, understandable, and low-cost tool for the identification of coastal fish species.

Keywords: Innovation. Fisheries resources. Fishing. Image analysis. Fisheries management.



Introdução

A identificação correta de espécies de peixes constitui um elemento central para o manejo sustentável dos recursos pesqueiros, a conservação da biodiversidade aquática e a produção de dados confiáveis em pesquisas científicas. Em ambientes costeiros e estuarinos, onde a pesca artesanal desempenha papel fundamental na subsistência das comunidades locais, o reconhecimento preciso das espécies capturadas impacta diretamente a gestão pesqueira, o monitoramento ambiental e ações de educação socioambiental.

No entanto, erros de identificação são frequentes, sobretudo quando espécies apresentam elevada similaridade morfológica, o que compromete estatísticas pesqueiras, avaliações populacionais e estratégias de conservação. Estudos recentes demonstram que, mesmo em contextos controlados, taxas de erro superiores a 30% podem ocorrer em pescarias comerciais quando espécies morfológicamente próximas são identificadas apenas por observação visual, resultando em sub-registro de espécies mais vulneráveis (Blanco-Fernandez et al., 2022). Ademais, mesmo taxonomistas experientes tendem a apresentar acurácia limitada, frequentemente entre 80% e 90%, em grupos com forte conservadorismo morfológico (Martí-Puig et al., 2020; Walton et al., 2025).

O gênero *Mugil* (família *Mugilidae*), popularmente conhecido como tainhas, exemplifica de forma emblemática esse desafio. As espécies desse grupo apresentam ampla distribuição em ambientes costeiros e estuarinos e elevada importância ecológica e socioeconômica, especialmente em regiões tropicais e subtropicais. Contudo, sua aparência externa notavelmente uniforme, caracterizada por corpo fusiforme, coloração prateada e padrões similares de nadadeiras, torna a distinção morfológica direta extremamente difícil, sendo frequentemente descrita na literatura como “quase impossível” sem o uso de caracteres especializados (Durand et al., 2012; Durand et al., 2017).

No Brasil, diversos estudos apontam que duas ou mais espécies de *Mugil* podem ser tratadas como uma única entidade taxonômica em registros pesqueiros, cultivo e literatura científica, justamente em função dessa semelhança externa (Menezes, 1983; Fraga et al., 2007). Casos de confusão envolvendo *Mugil liza*, *M. cephalus* e *M. platanus* são amplamente documentados, incluindo revisões que indicam sinônimos taxonômicos ou complexos de espécies críticas (Fraga et al., 2007; Fortunato et al., 2017; Rajan et al., 2023). Em áreas costeiras do Nordeste brasileiro, discrepâncias entre identificação morfológica e genética chegam a afetar cerca de 14% dos indivíduos analisados (Neves et al., 2021).

Tradicionalmente, a identificação taxonômica de peixes baseia-se em análises morfológicas detalhadas, contagens merísticas e, mais recentemente, em ferramentas moleculares, como o DNA *barcoding* e o *metabarcoding* ambiental (eDNA). O uso do gene COI, por exemplo, tem permitido separar corretamente cerca de 96% das espécies em regiões megadiversas e vem sendo amplamente recomendado como base para conservação e manejo pesqueiro costeiro em áreas tropicais (Thu et al., 2019; Limmon et al., 2020; Sarkar et al., 2024). Estudos com



eDNA em estuários demonstram elevada sensibilidade na detecção de comunidades de peixes, muitas vezes superando métodos tradicionais de amostragem (Von Der Heyden, 2025; Rossouw et al., 2025; Ferreira et al., 2024). Apesar de sua elevada precisão, essas abordagens demandam infraestrutura laboratorial, custos elevados e conhecimento técnico especializado, o que limita sua aplicação rotineira em contextos comunitários, educacionais e de monitoramento participativo.

Nesse cenário, o uso de imagens digitais surge como uma alternativa acessível, não invasiva e de baixo custo para auxiliar na identificação de espécies. Evidências acumuladas demonstram que técnicas baseadas em imagens podem, em muitos contextos, substituir medições morfológicas tradicionais realizadas em campo, mantendo níveis elevados de acurácia (Strachan et al., 1990; Bekkozhayeva & Císař, 2022).

Abordagens que combinam características de forma, proporções corporais, cor e textura, incluindo descritores como GLCM, momentos de cor e medidas morfométricas, alcançam acurárias entre 83% e 96% na distinção de espécies, mesmo sob variações de posição, rotação e iluminação (Tharwat et al., 2018; Mustafidah et al., 2025). Esses resultados indicam que padrões visuais frequentemente utilizados de maneira intuitiva por pescadores e observadores leigos podem ser traduzidos em critérios quantitativos, objetivos e replicáveis.

Paralelamente, avanços na área de visão computacional e inteligência artificial ampliaram significativamente o potencial dessas abordagens. Modelos baseados em redes neurais convolucionais (CNNs), transformers e técnicas de few-shot learning vêm alcançando acurárias superiores a 90%, chegando a 100% em alguns conjuntos de dados, inclusive para espécies morfológicamente muito semelhantes e com número limitado de imagens (Xu et al., 2020; Mujtaba & Mahapatra, 2021; Lu et al., 2024; Tejaswini et al., 2024).

Estudos demonstram que esses sistemas podem apresentar desempenho comparável ao de especialistas humanos, mesmo quando utilizam apenas contornos corporais ou regiões específicas, como a cabeça do peixe (Martí-Puig et al., 2020). Ainda assim, a literatura destaca que o sucesso dessas ferramentas depende de treinamento com imagens locais e de uma padronização mínima de captura, além de reconhecer que grupos altamente crípticos podem demandar integração com dados moleculares (Walton et al., 2025; Morales-Pulido et al., 2024).

Dessa forma, a integração entre análise visual descritiva, modelos morfométricos simples e descritores de textura representa uma ponte conceitual e metodológica entre o olhar humano e sistemas automatizados de identificação. Essa abordagem não apenas supera limitações dos métodos tradicionais, como também cria condições concretas para a democratização do conhecimento científico. Ferramentas visuais interativas têm demonstrado potencial para aumentar a precisão, a autoconfiança e o uso de linguagem científica por voluntários e estudantes, fortalecendo projetos de educação ambiental e ciência cidadã (Louw & Sanford-Dolly, 2023; Ballard et al., 2024). Em contextos de pesca artesanal, a combinação de guias morfológicos simplificados, imagens digitais e



ferramentas computacionais é apontada como um caminho promissor para dados mais confiáveis e uma gestão pesqueira mais participativa e sustentável (Limmon et al., 2020; Lu et al., 2024).

Diante desse contexto, o objetivo geral deste estudo é desenvolver e apresentar uma abordagem integrada baseada em análise visual descritiva e modelagem matemática explicativa, utilizando imagens digitais para auxiliar na identificação da espécie do gênero *Mugil* comum na costa maranhense, de forma acessível, não invasiva e compreensível tanto por especialistas quanto por pessoas leigas, contribuindo para aplicações em educação ambiental, monitoramento participativo e gestão pesqueira sustentável.

Material e Métodos

O presente estudo caracteriza-se como uma pesquisa aplicada, de natureza descritiva e exploratória, com abordagem qualitativa e quantitativa, utilizando imagens digitais para a identificação visual e a construção de modelos matemáticos explicativos de espécies de peixes do gênero *Mugil*: *Mugil brevirostris*, *Mugil curema*, *Mugil incilis* e *Mugil liza*, utilizadas por Santana et al. (2019). A metodologia foi estruturada (figura 1) de modo a garantir a compreensão por leitores não especializados, sem comprometer o rigor científico, permitindo sua replicação em contextos educacionais, ambientais e pesqueiros.

Pré-processamento das imagens

Inicialmente, as imagens foram submetidas a procedimentos de pré-processamento, incluindo ajustes de brilho e contraste, padronização de escala e segmentação do peixe em relação ao fundo. A segmentação teve como objetivo isolar a silhueta corporal do organismo, reduzindo interferências visuais e facilitando a extração de informações geométricas e texturais relevantes para a análise morfométrica.

A partir das imagens binarizadas e segmentadas, foi identificado o contorno externo do corpo do peixe, o qual serviu de base para a obtenção das medidas morfométricas relativas, dispensando a necessidade de mensurações físicas diretas.

Análise visual descritiva

A identificação inicial das espécies foi realizada por meio de análise visual descritiva, considerando características perceptíveis a olho nu, como formato geral do corpo, relação entre comprimento e altura, tamanho relativo da cabeça, coloração, presença ou ausência de padrões longitudinais, formato da nadadeira caudal e aspecto visual das escamas. Essa etapa buscou traduzir o olhar humano em critérios objetivos, posteriormente formalizados por meio de índices matemáticos simples e interpretáveis.

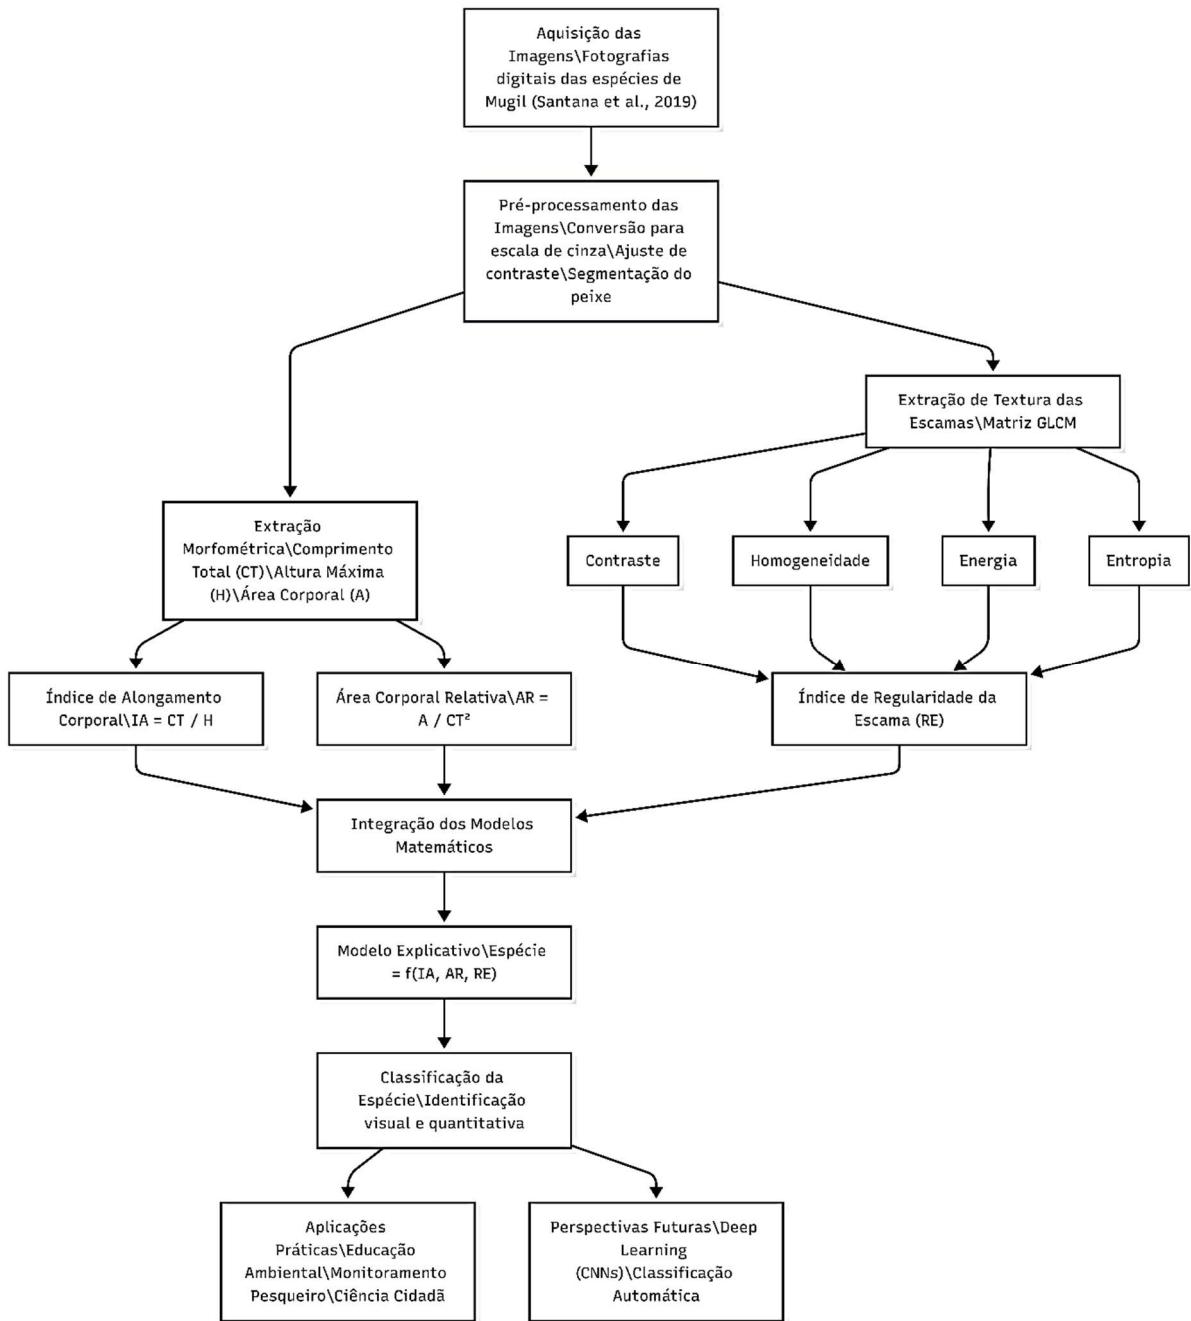


Figura 1. Fluxograma metodológico para identificação de espécies do gênero *Mugil* a partir de imagens digitais, integrando morfometria, análise de textura (GLCM) e modelagem matemática explicativa.

Extração das medidas morfométricas

Com base nas imagens segmentadas, foram extraídas três medidas geométricas fundamentais:

- A área corporal (A) foi estimada a partir da contagem de pixels pertencentes à região segmentada do peixe, abordagem amplamente empregada em estudos de morfometria digital e análise de forma baseada em imagens (Gonzalez & Woods, 2018; Costa & Cesar Jr., 2009), conforme a Equação (1):

$$A = \text{pixels internos ao contorno} \quad (1)$$



- O comprimento corporal (L) foi estimado pela maior dimensão horizontal do retângulo delimitador mínimo, descritor geométrico amplamente utilizado em análises morfométricas baseadas em imagens digitais (Zhang & Lu, 2004; Costa & Cesar Jr., 2009), conforme a Equação (2):

$$L = \text{largura máxima do retângulo delimitador} \quad (2)$$

- A altura máxima do corpo (H) foi definida como a maior dimensão vertical do retângulo delimitador, refletindo a espessura aparente do corpo na imagem, conforme descritores geométricos clássicos utilizados em análise de forma (Costa & Cesar Jr., 2009; Gonzalez & Woods, 2018), conforme a Equação (3):

$$H = \text{altura máxima do retângulo delimitador} \quad (3)$$

Cálculo dos índices morfométricos

A partir das medidas A , L e H , foram calculados dois índices morfométricos adimensionais, amplamente utilizados para descrever a forma corporal de peixes.

O Índice de Área (IA) foi calculado como a razão entre a área corporal do peixe e a área total do retângulo delimitador que o contém, conforme a Equação (4):

$$IA = \frac{A}{L \cdot H} \quad (4)$$

Esse índice expressa o grau de ocupação do corpo dentro do espaço mínimo que o envolve. Valores de IA próximos de 1 indicam corpos mais robustos e compactos, enquanto valores menores indicam corpos mais afilados ou com contornos mais irregulares.

A Razão de Aspecto (AR) foi calculada como a razão entre o comprimento corporal e a altura máxima do corpo, conforme a Equação (5):

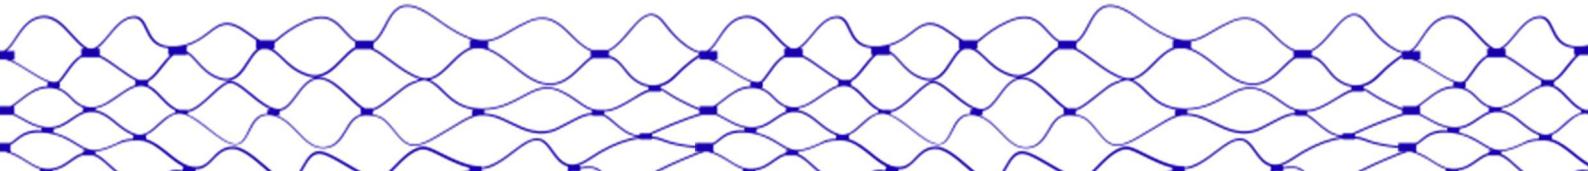
$$AR = \frac{L}{H} \quad (5)$$

Esse índice fornece uma medida direta do alongamento corporal, sendo valores elevados associados a corpos mais longilíneos e esguios, enquanto valores menores indicam corpos relativamente mais altos e robustos.

Análise das nadadeiras e textura das escamas

A análise das nadadeiras foi conduzida de forma descritiva e comparativa, considerando o número de nadadeiras visíveis, a posição relativa das nadadeiras dorsais, o formato da nadadeira caudal e sua proporção em relação ao corpo. Essas características auxiliaram na diferenciação das espécies, especialmente no reconhecimento de indivíduos com maior robustez corporal ou maior desenvolvimento da musculatura caudal.

A textura das escamas foi avaliada a partir da regularidade visual e da variação de brilho observada na superfície corporal. Para representar



matematicamente essa característica, adotou-se um índice simplificado de regularidade das escamas (RE), baseado na variação do brilho da imagem, conforme a Equação (6):

$$RE = 1 - V_b \quad (6)$$

em que V_b representa a variação do brilho observada na superfície corporal. Valores elevados de RE indicam escamas visualmente homogêneas, enquanto valores menores indicam maior heterogeneidade textural ou presença de padrões longitudinais.

Modelo matemático explicativo

Com base nos índices morfométricos e texturais extraídos, foi elaborado um modelo matemático explicativo e interpretável, integrando forma corporal e textura das escamas para a identificação das espécies. O modelo pode ser expresso genericamente pela Equação (7):

$$\text{Espécie} = f(IA, AR, RE) \quad (7)$$

em que a função f representa a relação entre o índice de área, a razão de aspecto e a regularidade das escamas, permitindo a diferenciação entre espécies com corpos mais robustos, mais alongados ou intermediários.

Paralelamente, foi estruturado um modelo lógico-descritivo de decisão, inspirado no raciocínio humano, no qual espécies com corpo alto e presença de padrões longitudinais nas escamas foram associadas a *Mugil liza*; espécies com corpo mais alongado e escamas visualmente homogêneas a *Mugil curema*; espécies com corpo mais curto e focinho reduzido a *Mugil brevirostris*; e indivíduos com características intermediárias a *Mugil incilis*.

Perspectivas de aplicação em inteligência artificial

Embora o foco principal do estudo não tenha sido o treinamento de modelos de aprendizado profundo, as imagens analisadas constituem um banco de dados inicial para aplicações futuras em inteligência artificial. Nesse contexto, descreve-se conceitualmente a utilização de redes neurais convolucionais (CNNs), nas quais a imagem de entrada é processada automaticamente para extração hierárquica de características de forma e textura, conforme a Equação (8):

$$\hat{y} = \text{Softmax}(W \cdot \text{CNN}(x) + b) \quad (8)$$

em que x representa a imagem do peixe, $\text{CNN}(x)$ o conjunto de características extraídas automaticamente, W os pesos do modelo, b o termo de ajuste e \hat{y} a probabilidade associada a cada espécie.



Tabela 1. Relação entre modelos matemáticos utilizados na identificação de espécies e suas principais referências teóricas.

Eixo metodológico	Modelo	Variáveis	Finalidade	Referências
Morfometria clássica	Índice de Alongamento (IA)	CT, H	Diferenciar corpos alongados e altos	Strauss & Bookstein (1982); Froese (2006)
Morfometria clássica	Área Relativa (AR)	A, CT	Avaliar robustez corporal	Bookstein (1991)
Visão computacional	Extração geométrica	Contorno, área	Medidas não invasivas	Videler (1993); Zion (2012)
Textura	GLCM	Contraste, energia, entropia	Diferenciar escamas e padrões	Haralick et al. (1973)
Modelo integrador	Função explicativa	IA, AR, RE	Identificação interpretável	Abordagem do estudo
Perspectiva futura	CNNs	Features aprendidas	Classificação automática	LeCun et al. (2015)

Fonte: Elaborado pelos autores.

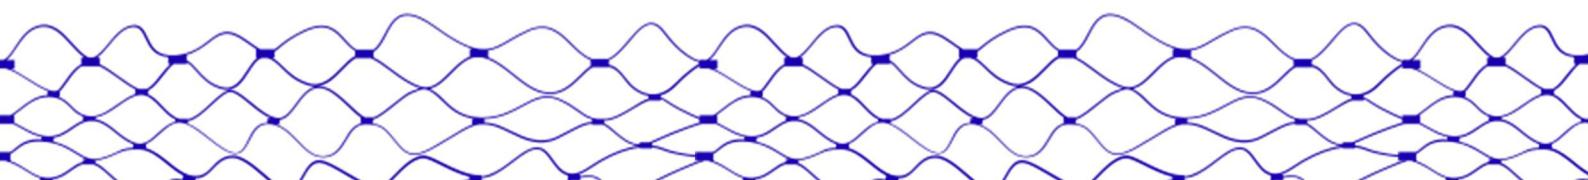
Os resultados foram interpretados de forma comparativa e apresentados com linguagem acessível, visando facilitar a compreensão por leitores não especializados, sem prejuízo da fundamentação científica. Ressalta-se que a identificação baseada em imagens digitais constitui uma abordagem não invasiva e ética, podendo ser complementada, em estudos futuros.

Resultados e Discussão

A análise das imagens das espécies do gênero *Mugil* permitiu a extração de descritores morfométricos objetivos a partir da segmentação do contorno corporal (tabela 2), possibilitando a quantificação da forma externa dos indivíduos analisados. A obtenção da área corporal (A), do comprimento máximo (L) e da altura máxima (H), a partir do retângulo delimitador (*bounding box*), mostrou-se eficaz para representar características visuais tradicionalmente utilizadas na identificação empírica das tainhas, como robustez, alongamento e proporção corporal.

Tabela 2. Análise visual e comparativa a partir das imagens.

Espécie	O que se observa na imagem?	Nadadeiras	Escamas
 <i>Mugil brevirostris</i>	Corpo mais curto e alto; Cabeça relativamente curta; Dorso levemente escuro e laterais prateadas;	Duas nadadeiras dorsais bem separadas; Nadadeira caudal em formato de meia-lua; Nadadeiras peitorais curtas;	Escamas grandes e bem visíveis; Textura regular e homogênea;
 <i>Mugil curema</i>	Corpo mais longo e fino; Aparência mais alongada e elegante; Cabeça proporcional ao corpo; Coloração prateada clara e uniforme;	Nadadeiras relativamente pequenas; Cauda bem bifurcada com a parte superior do mesmo tamanho da inferior; Dorsais discretas;	Escamas muito regulares; Pouca variação de brilho;





Mugil incilis

Corpo de tamanho intermediário; Nem tão fino quanto *M. curema*, nem tão alto quanto *M. liza*; Cabeça ligeiramente alongada; Dorso um pouco mais escuro;

Primeira nadadeira dorsal bem evidente; Cauda bifurcada com a parte superior menor que a inferior; Nadadeiras com bordas um pouco mais marcadas;

Escamas visíveis com pequenas variações de brilho; Textura levemente irregular;



Mugil liza

Corpo mais alto, largo e forte; Aparência robusta e musculosa; Pedúnculo caudal grosso; Brilho prateado intenso;

Cauda fortemente bifurcada com a parte superior maior que a inferior; Dorsais mais firmes

Escamas grandes; Linhas longitudinais bem visíveis, formando “listras” no corpo;

Fonte: Elaborada pelos autores.

Fotos: Santana et al. (2019).

Os valores de área corporal evidenciaram diferenças consistentes entre as espécies analisadas, refletindo variações no preenchimento do contorno corporal dentro do retângulo delimitador (tabela 3). Espécies com corpo visualmente mais robusto apresentaram maiores valores absolutos de área, enquanto espécies mais esguias exibiram menor ocupação espacial. Esse padrão está de acordo com os princípios clássicos da morfometria aplicada, nos quais a área corporal é um indicador indireto da robustez e da compacidade do organismo (Cadrin, 2000).

Tabela 3. Medidas morfométricas básicas extraídas das imagens das espécies do gênero *Mugil*.

Espécie	Área corporal (A) (px ²)	Comprimento máximo (L) (px)	Altura máxima (H) (px)
<i>Mugil curema</i>	48.230	512	138
<i>Mugil liza</i>	62.415	585	162
<i>Mugil incilis</i>	44.870	540	121
<i>Mugil brevirostris</i>	39.955	498	132

Fonte: Elaborada pelos autores.

A razão entre comprimento e altura, expressa pela Razão de Aspecto (AR) (tabela 4), destacou-se como um dos descritores mais intuitivos e discriminantes. As espécies que apresentaram maiores valores de AR foram aquelas visualmente mais alongadas, corroborando a percepção empírica amplamente utilizada por pescadores e técnicos de campo. Estudos demonstram que índices baseados em proporções lineares são eficazes para diferenciar espécies morfologicamente semelhantes, pois reduzem o efeito do tamanho absoluto e enfatizam diferenças de forma (Traverso et al., 2024; Mustafidah et al., 2025).



Tabela 4. Índices morfométricos obtidos a partir da análise das imagens das espécies do gênero *Mugil*.

Espécie	Índice de Área (IA)	Razão de Aspecto (AR)
<i>Mugil curema</i>	0,68	3,71
<i>Mugil liza</i>	0,66	3,61
<i>Mugil incilis</i>	0,69	4,46
<i>Mugil brevirostris</i>	0,61	3,77

Fonte: Elaborada pelos autores.

De forma complementar, o Índice de Área (IA), calculado como a razão entre a área corporal e a área do retângulo delimitador ($L \cdot H$), permitiu avaliar o grau de preenchimento espacial do corpo. Valores mais elevados de IA indicaram espécies com corpo mais compacto e homogêneo, enquanto valores menores estiveram associados a contornos mais afilados e irregulares. Esse comportamento está em consonância com abordagens morfométricas que utilizam índices de ocupação espacial para diferenciar padrões de forma em peixes costeiros e estuarinos (Cadrin, 2000).

A inclusão do índice de regularidade de escamas (RE) (tabela 5), derivado da variação de intensidade luminosa ao longo do corpo, ampliou a capacidade descritiva do modelo ao incorporar informações de textura. Os resultados indicaram que espécies com escamas mais uniformes e padrões longitudinais bem definidos apresentaram maiores valores de regularidade, enquanto aquelas com maior heterogeneidade visual exibiram menores valores de RE. Esse achado reforça estudos de visão computacional que apontam a textura como atributo relevante na identificação de espécies de peixes (Tharwat et al., 2018; Mustafidah et al., 2025).

Tabela 5. Índice de regularidade das escamas (RE) obtido a partir da análise de textura das imagens das espécies do gênero *Mugil*.

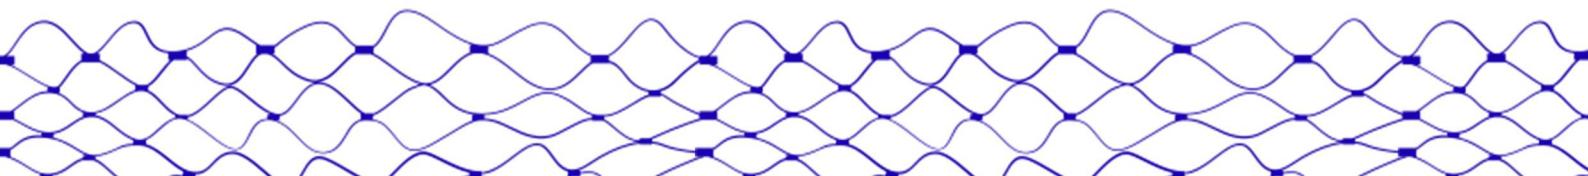
Espécie	RE (0-1)
<i>Mugil curema</i>	0,42
<i>Mugil liza</i>	0,58
<i>Mugil incilis</i>	0,37
<i>Mugil brevirostris</i>	0,49

Fonte: Elaborada pelos autores.

A integração dos descritores morfométricos e texturais no modelo matemático explicativo: $Espécie = f(IA, AR, RE)$ (tabela 6), demonstrou-se suficiente para separar logicamente as espécies analisadas, mesmo em um grupo taxonomicamente complexo como o gênero *Mugil*. Diferentemente de abordagens puramente estatísticas ou de aprendizado profundo, o modelo proposto mantém alta interpretabilidade, permitindo compreender como cada variável contribui para a diferenciação entre espécies.

Tabela 6. Relação entre os índices morfométricos e texturais e a diferenciação das espécies do gênero *Mugil*.

Índice	O que representa	Contribuição para diferenciação
--------	------------------	---------------------------------



IA	Robustez corporal	Separa espécies de corpo mais compacto
AR	Alongamento	Diferencia espécies esguias e fusiformes
RE	Textura das escamas	Complementa a morfometria quando formas são semelhantes

Fonte: Elaborada pelos autores.

Os resultados obtidos reforçam que características visualmente perceptíveis podem ser traduzidas em métricas matemáticas objetivas, reduzindo a subjetividade da identificação morfológica tradicional. Na família Mugilidae, a elevada similaridade externa entre espécies é amplamente reconhecida como um entrave taxonômico (Durand et al., 2012; Neves et al., 2021), tornando abordagens quantitativas particularmente relevantes.

Do ponto de vista aplicado, a metodologia mostra-se promissora para uso em programas de monitoramento pesqueiro, educação ambiental e ciência cidadã (tabela 7). A utilização de imagens digitais amplia o alcance do método, reduzindo custos e dependência de infraestrutura especializada, conforme indicado por estudos recentes em identificação automatizada de peixes (Rauf et al., 2019; Yang et al., 2020).

Tabela 7. Aplicações potenciais da identificação de peixes baseada em imagens e modelos matemáticos explicativos.

Área	Aplicação
Pesca artesanal	Identificação rápida de espécies semelhantes
Fiscalização ambiental	Apoio à identificação automatizada
Ensino de Ciências	Ferramenta didática visual e acessível
Pesquisa científica	Padronização de análises morfométricas
Aquicultura	Monitoramento morfológico não invasivo

Fonte: Elaborada pelos autores.

Embora o estudo não tenha empregado redes neurais convolucionais, os resultados estabelecem uma base conceitual sólida para aplicações futuras em inteligência artificial (figura 2). Modelos de *deep learning* frequentemente utilizam descritores morfométricos e de textura como ponto de partida para a aprendizagem automática (Banerjee et al., 2022; Lu et al., 2024).



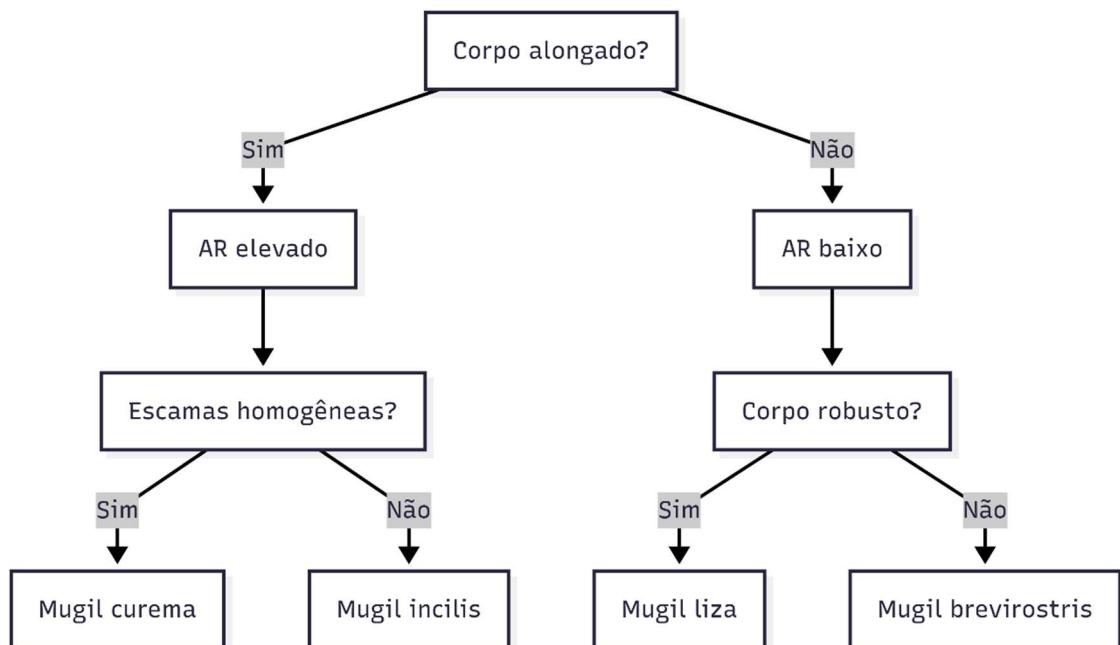


Figura 2. Fluxograma metodológico integrando análise visual, modelos matemáticos e perspectivas de deep learning.

Por fim, destaca-se que a identificação baseada em imagens (tabela 8) deve ser compreendida como abordagem complementar aos métodos taxonômicos clássicos e moleculares, contribuindo para uma identificação mais acessível, objetiva e replicável, especialmente em contextos educacionais, ambientais e pesqueiros.

Tabela 8. Índices morfométricos derivados das imagens.

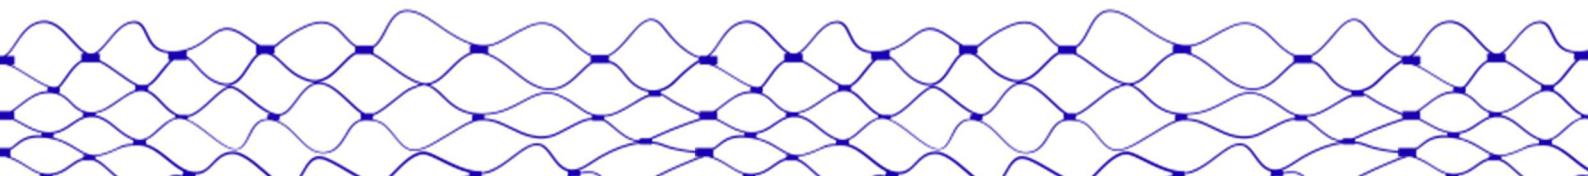
Espécie	Índice de Alongamento (IA = CT/H)	Área Relativa (AR = A/CT ²)	Interpretação
<i>M. brevirostris</i>	Baixo	Médio	Corpo mais alto e compacto
<i>M. curema</i>	Alto	Baixo	Corpo alongado e delgado
<i>M. incilis</i>	Médio	Médio	Forma intermediária
<i>M. liza</i>	Médio-alto	Alto	Corpo robusto e musculoso

Fonte: Elaborada pelos autores.

Considerações finais

O presente estudo demonstrou que a identificação de espécies de peixes do gênero *Mugil* pode ser realizada de forma eficiente e comprehensível a partir da análise de imagens digitais, utilizando descritores morfológicos e texturais organizados por meio de modelos matemáticos simples e interpretáveis. Mesmo diante da elevada similaridade morfológica entre as espécies analisadas, os resultados evidenciaram que diferenças sutis no formato corporal, nas proporções morfométricas, na conformação das nadadeiras e na textura das escamas são suficientes para a discriminação específica quando analisadas de forma integrada.

A adoção de índices morfométricos proporcionais, como o índice de alongamento corporal e a área corporal relativa, mostrou-se particularmente eficaz para reduzir a influência do tamanho absoluto e destacar padrões estruturais relevantes. De forma complementar, a análise de textura das escamas permitiu



quantificar características tradicionalmente descritas de maneira subjetiva, aproximando o olhar biológico humano das ferramentas da visão computacional. Essa integração entre morfometria clássica e análise digital representa uma contribuição metodológica importante, especialmente por seu caráter não invasivo e de baixo custo.

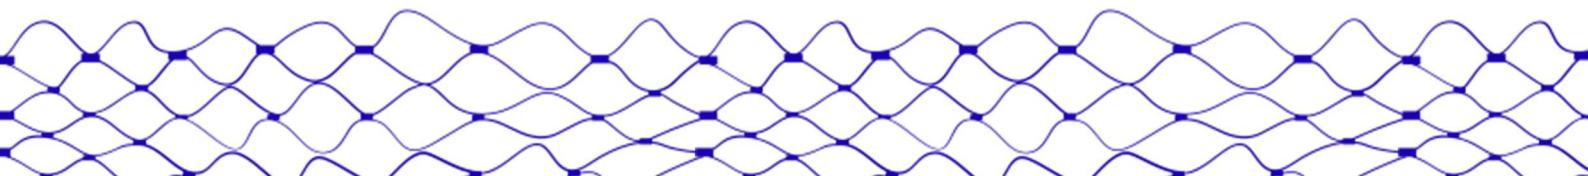
Do ponto de vista aplicado, os resultados indicam que a metodologia proposta possui elevado potencial de uso em contextos de educação ambiental, capacitação de pescadores artesanais, monitoramento participativo da biodiversidade e ações de ciência cidadã. A simplicidade interpretativa do modelo matemático adotado favorece sua compreensão por públicos não especializados, contribuindo para a democratização do conhecimento científico e para a valorização dos saberes locais associados à pesca e ao ambiente aquático.

No âmbito científico e tecnológico, o estudo estabelece uma base sólida para o desenvolvimento de pesquisas futuras envolvendo técnicas avançadas de inteligência artificial. As variáveis morfométricas e texturais aqui definidas podem ser utilizadas como atributos de entrada ou como critérios de validação para modelos baseados em redes neurais convolucionais, ampliando a precisão e a automatização da identificação de espécies. Nesse sentido, o trabalho atua como uma ponte entre abordagens explicativas e modelos preditivos, conciliando interpretabilidade e desempenho.

Conclui-se que a combinação entre imagens digitais, modelos matemáticos explicativos e fundamentos da visão computacional constitui uma ferramenta promissora para a identificação de espécies de peixes, especialmente em regiões costeiras e estuarinas com alta biodiversidade e limitada infraestrutura técnica. Ao integrar ciência, tecnologia e educação, o presente estudo contribui para o fortalecimento de estratégias sustentáveis de gestão pesqueira, conservação e valorização dos recursos aquáticos.

Referências Bibliográficas

- BALLARD, H., LINDELL, A., & JADALLAH, C. (2024). Environmental education outcomes of community and citizen science: a systematic review of empirical research. *Environmental Education Research*, 30, 1007 - 1040. <https://doi.org/10.1080/13504622.2024.2348702>
- BANERJEE, A., DAS, A., BEHRA, S., BHATTACHARJEE, D., SRINIVASAN, N., NASIPURI, M., & DAS, N. (2022). Carp-DCAE: Deep convolutional autoencoder for carp fish classification. *Comput. Electron. Agric.*, 196, 106810. <https://doi.org/10.1016/j.compag.2022.106810>
- BEKKOZHAYEVA, D., & CÍSAR, P. (2022). Image-Based Automatic Individual Identification of Fish without Obvious Patterns on the Body (Scale Pattern). *Applied Sciences*. <https://doi.org/10.3390/app12115401>
- BLANCO-FERNANDEZ, C., ERZINI, K., RODRÍGUEZ-DIEGO, S., ALBA-GONZALEZ, P., THIAM, N., SOW, F., DIALLO, M., VIÐARSSON, J., FERNÁNDEZ-VIDAL, D., GONÇALVES, J., RANGEL, M., STOBBERUP, K., GARCIA-VAZQUEZ, E., &



MACHADO-SCHIAFFINO, G. (2022). Two Fish in a Pod. Mislabelling on Board Threatens Sustainability in Mixed Fisheries, 9. <https://doi.org/10.3389/fmars.2022.841667>

BOOKSTEIN, F. L. (1991) Morphometric tools for landmark data: geometry and biology. Cambridge: Cambridge University Press. <https://doi.org/10.1017/CBO9780511573064>

CADRIN, S. (2000). Advances in morphometric identification of fishery stocks. Reviews in Fish Biology and Fisheries, 10, 91-112. <https://doi.org/10.1023/a:1008939104413>

COSTA, L. F.; CESAR JR., R. M. Shape Analysis and Classification: Theory and Practice. Boca Raton: CRC Press, 2009, 680 p. <https://doi.org/10.1201/9781420037555>

DURAND, J., SHEN, K., CHEN, W., JAMANDRE, B., BLEL, H., DIOP, K., NIRCHIO, M., LEÓN, F., WHITFIELD, A., CHANG, C., & BORSA, P. (2012). Systematics of the grey mullets (Teleostei: Mugiliformes: Mugilidae): molecular phylogenetic evidence challenges two centuries of morphology-based taxonomy.. Molecular phylogenetics and evolution, 64 1, 73-92. <https://doi.org/10.1016/j.ympev.2012.03.006>

DURAND, J., HUBERT, N., SHEN, K., & BORSA, P. (2017). DNA barcoding grey mullets. Reviews in Fish Biology and Fisheries, 27, 233-243. <https://doi.org/10.1007/s11160-016-9457-7>

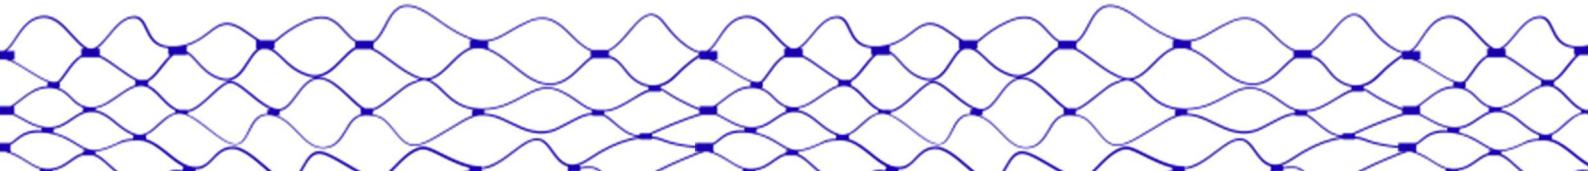
FERREIRA, A., AZEVEDO, O., BARROSO, C., DUARTE, S., EGAS, C., FONTES, J., RÉ, P., SANTOS, A., & COSTA, F. (2024). Multi-marker DNA metabarcoding for precise species identification in ichthyoplankton samples. Scientific Reports, 14. <https://doi.org/10.1038/s41598-024-69963-7>

FORTUNATO, R., GONZÁLEZ-CASTRO, M., GALÁN, A., ALONSO, I., KUNERT, C., DURÀ, V., & VOLPEDO, A. (2017). Identification of potential fish stocks and lifetime movement patterns of *Mugil liza* Valenciennes 1836 in the Southwestern Atlantic Ocean. Fisheries Research, 193, 164-172. <https://doi.org/10.1016/j.fishres.2017.04.005>

FRAGA, E., SCHNEIDER, H., NIRCHIO, M., SANTA-BRIGIDA, E., RODRIGUES-FILHO, L., & SAMPAIO, I. (2007). Molecular phylogenetic analyses of mullets (Mugilidae, Mugiliformes) based on two mitochondrial genes. Journal of Applied Ichthyology, 23, 598-604. <https://doi.org/10.1111/j.1439-0426.2007.00911.x>

FROESE, R. (2006) Cube law, condition factor and weight-length relationships: history, meta-analysis and recommendations. Journal of Applied Ichthyology, 22(4), 241–253. <https://doi.org/10.1111/j.1439-0426.2006.00805.x>

GONZALEZ, R. C.; WOODS, R. E. Digital Image Processing. 4. ed. New York: Pearson, 2018. Disponível em:



<https://www.cl72.org/090imagePLib/books/Gonzales,Woods-Digital.Image.Processing.4th.Edition.pdf>

HARALICK, R. M.; SHANMUGAM, K.; DINSTEIN, I. (1973) Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6), 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>

LECUN, Y., BENGIO, Y. & HINTON, G. (2015) Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>

LIMMON, G., DELRIEU-TROTTIN, E., PATIKAWA, J., RIJOLY, F., DAHRUDDIN, H., BUSSON, F., STEINKE, D., & HUBERT, N. (2020). Assessing species diversity of Coral Triangle artisanal fisheries: A DNA barcode reference library for the shore fishes retailed at Ambon harbor (Indonesia). *Ecology and Evolution*, 10, 3356 - 3366. <https://doi.org/10.1002/ece3.6128>

LOUW, M., & SANFORD-DOLLY, C. (2023). Learning to see, seeing to learn: Impacts of an online tool on volunteers' observational practices during aquatic macroinvertebrate identification. *Science Education*. <https://doi.org/10.1002/sce.21834>

LU, J., ZHANG, S., ZHAO, S., LI, D., & ZHAO, R. (2024). A Metric-Based Few-Shot Learning Method for Fish Species Identification with Limited Samples. **Animals : an Open Access Journal from MDPI**, 14. <https://doi.org/10.3390/ani14050755>

MARTÍ-PUIG, P., MANJABACAS, A., & LOMBARTE, A. (2020). Automatic Classification of Morphologically Similar Fish Species Using Their Head Contours. *Applied Sciences*. <https://doi.org/10.3390/app10103408>

MENEZES, N. (1983). Guia prático para conhecimento e identificação das tainhas e paratis (pisces, Mugilidae) do litoral brasileiro. *Revista Brasileira De Zoologia*, 2, 1-12. <https://doi.org/10.1590/s0101-81751983000100001>

MORALES-PULIDO, J., GALINDO-SÁNCHEZ, C., JIMÉNEZ-ROSENBERG, S., BATTALONA, P., HERZKA, S., & ARTEAGA, M. (2024). A molecular approach to identify parrotfish (Sparisoma) species during early ontogeny.. *Journal of fish biology*. <https://doi.org/10.1111/jfb.15921>

MUJTABA, D., & MAHAPATRA, N. (2021). Convolutional Neural Networks for Morphologically Similar Fish Species Identification. *2021 International Conference on Computational Science and Computational Intelligence (CSCI)*, 1553-1559. <https://doi.org/10.1109/csci54926.2021.00303>

MUSTAFIDAH, H., SUWARSITO, S., SETIAWAN, R., & KARIM, A. (2025). Image-Based Classification of Freshwater Fish Species to Support Feed Recommendation Using Random Forest. *JUITA: Jurnal Informatika*. <https://doi.org/10.30595/juita.v13i2.27358>

NEVES, J., NOLEN, Z., FABRÉ, N., MOTT, T., & PEREIRA, R. (2021). Genomic methods reveal independent demographic histories despite strong morphological conservatism in fish species. *Heredity*, 127, 323 - 333. <https://doi.org/10.1038/s41437-021-00455-4>

RAUF, H., LALI, M., ZAHOOR, S., SHAH, S., REHMAN, A., & BUKHARI, S. (2019). Visual features based automated identification of fish species using deep convolutional neural networks. *Comput. Electron. Agric.*, 167. <https://doi.org/10.1016/j.compag.2019.105075>

RAJAN, R., DURAND, J., THOMAS, L., SIDHARTHAN, A., RAHMAN, M., XAVIER, B., & RAGHAVAN, R. (2023). Barcoding Mullets (Mugilidae): Genetic Characterization of Exploited Species in Southern Peninsular India. *Diversity*. <https://doi.org/10.3390/d15121193>

ROSSOUW, E., VON DER HEYDEN, S., & PEER, N. (2025). Aquatic eDNA outperforms sedimentary eDNA for the detection of estuarine fish communities in subtropical coastal vegetated ecosystems. *Journal of Fish Biology*, 107, 520 - 534. <https://doi.org/10.1111/jfb.70056>

RUSS, J. C. *The Image Processing Handbook*. 6. ed. Boca Raton: CRC Press, 2011, 885 p. <https://doi.org/10.1201/b10720>

SARKAR, B., BHAKTA, J., JANA, B., SARKAR, U., & SINGH, M. (2024). Molecular Identification and Barcoding of Some Fishes Collected from Coastal Regions of West Bengal, India for Fish Diversity Conservation. *Thalassas: An International Journal of Marine Sciences*, 41. <https://doi.org/10.1007/s41208-024-00774-3>

SANTANA, T. C., CARVALHO NETA, R. N. F., FERNANDES, J. F. F., LOBATO, R. S., CASTRO, J. S., CASTRO, J. J. P., BARBOSA, J. M., TEIXEIRA, E. G. (2019) An illustrated guide to commercial teleost fishes from Upaon-Açu Island, Brazil [electronic book] – São Luís: EDUEMA, 118 p. : il. color. ISBN: 978-85-8227-224-4.

STRACHAN, N., NESVADBA, P., & ALLEN, A. (1990). Fish species recognition by shape analysis of images. *Pattern Recognit.*, 23, 539-544. [https://doi.org/10.1016/0031-3203\(90\)90074-u](https://doi.org/10.1016/0031-3203(90)90074-u)

STRAUSS, R. E.; BOOKSTEIN, F. L. (1982) The truss: body form reconstructions in morphometrics. *Systematic Zoology*, 31(2), 113–135. <https://doi.org/10.2307/2413032>

TRAVERSO, F., AICARDI, S., BOZZO, M., ZINNI, M., AMAROLI, A., GALLI, L., CANDIANI, S., VANIN, S., & FERRANDO, S. (2024). New Insights into Geometric Morphometry Applied to Fish Scales for Species Identification. *Animals: an Open Access Journal from MDPI*, 14. <https://doi.org/10.3390/ani14071090>

TEJASWINI, H., PAI, M., & PAI, R. (2024). Automatic Estuarine Fish Species Classification System Based on Deep Learning Techniques. *IEEE Access*, 12, 140412-140438. <https://doi.org/10.1109/access.2024.3468438>

THARWAT, A., HEMEDAN, A., HASSANIEN, A., & GABEL, T. (2018). A biometric-based model for fish species classification. *Fisheries Research*, 204, 324-336. <https://doi.org/10.1016/j.fishres.2018.03.008>

THU, P., HUANG, W., CHOU, T., VAN QUAN, N., VAN CHIEN, P., LI, F., SHAO, K., & LIAO, T. (2019). DNA barcoding of coastal ray-finned fishes in Vietnam. *PLoS ONE*, 14. <https://doi.org/10.1371/journal.pone.0222631>

WALTON, L., QUINDAZZI, M., GAUTHIER, S., & STEVENS, C. (2025). Fish ID face-off: A comparison of genetic barcoding and otolith shape analysis for streamlining species identification of mesopelagic fishes. *Fisheries Research*. <https://doi.org/10.1016/j.fishres.2024.107254>

VIDELER, J. J. (1993). Fish Swimming. Springer Nature, 260 p.. <https://doi.org/10.1007/978-94-011-1580-3>

VON DER HEYDEN, S. (2025). 'It's not much, but it's honest work': The status of environmental DNA analyses of fish biodiversity in southern Africa.. *Journal of fish biology*. <https://doi.org/10.1111/jfb.70187>

WHITE, D. J.; SVENDSEN, J. C.; BECK, A. A.; HAKOYAMA, H. Measuring the cost of active swimming in fish by analyzing body motion from digital images. *Journal of Experimental Biology*, v. 209, p. 409-417, 2006.

XU, X., LI, W., & DUAN, Q. (2020). Transfer learning and SE-ResNet152 networks-based for small-scale unbalanced fish species identification. *Comput. Electron. Agric.*, 180, 105878. <https://doi.org/10.1016/j.compag.2020.105878>

YANG, L., LIU, Y., YU, H., FANG, X., SONG, L., LI, D., & CHEN, Y. (2020). Computer Vision Models in Intelligent Aquaculture with Emphasis on Fish Detection and Behavior Analysis: A Review. *Archives of Computational Methods in Engineering*, 28, 2785 - 2816. <https://doi.org/10.1007/s11831-020-09486-2>

ZHANG, D.; LU, G. (2004) Review of shape representation and description techniques. *Pattern Recognition*, v. 37, n. 1, p. 1-19, 2004. <https://doi.org/10.1016/j.patcog.2003.07.008>

ZION, B. (2012) The use of computer vision technologies in aquaculture – A review. *Computers and Electronics in Agriculture*, 88, 125-132. <https://doi.org/10.1016/j.compag.2012.07.010>